



Tecnológico Nacional de México
Centro Nacional de Investigación y Desarrollo Tecnológico

Tesis de Maestría

Estimación del desempeño de un convertidor CD-CD usando redes neuronales artificiales inversas aplicado a cosecha de energía

presentada por

Ing. Ireti Ticatame Rojas Arredondo

como requisito para la obtención del grado de
Maestro en Ciencias en Ingeniería Electrónica

Director de tesis

Dr. Jarniel García Morales

Codirector de tesis

Dr. Rodolfo Amalio Vargas

Cuernavaca, Morelos, México. Septiembre de 2024.

Cuernavaca, Mor.,

No. de Oficio:

Asunto:

12/SEPTIEMBRE/2024

DIE/137/2024

Aceptación de documentos de tesis

DR. CARLOS MANUEL ASTORGA ZARAGOZA
SUBDIRECTOR ACADÉMICO
PRESENTE

Por este conducto, los integrantes de Comité Tutorial del **C. IRETI TICATAME ROJAS ARREDONDO**, con número de control **M21CE087** de la Maestría en Ciencias en Ingeniería Electrónica, le informamos que hemos revisado el trabajo de tesis profesional titulado **"Estimación del Desempeño de un Convertidor CD-CD Usando Redes Neuronales Artificiales Inversas Aplicado a Cosecha de Energía"**, y hemos encontrado que se han realizado todas las correcciones y observaciones que se le indicaron, por lo que hemos acordado aceptar el documento de tesis y le solicitamos la autorización de impresión definitiva.

DIRECTOR DE TESIS



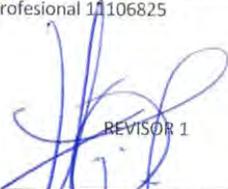
Dr. Jarniel García Morales
Doctor en Ciencias en Ingeniería Electrónica
Cédula profesional 11106825

CODIRECTOR DE TESIS



Dr. Rodolfo Amalio Vargas Méndez
Doctor en Ciencias en Ingeniería Electrónica
Cédula profesional 9526506

REVISOR 1



Dr. Víctor Hugo Olivares Peregrino
Doctor en Ciencias en Ingeniería Electrónica
Cédula profesional 5999002

REVISOR 2



Dr. Jesús Aguayo Alquicira
Doctor en Ciencias en Ingeniería Electrónica
Cédula profesional 4706315

C.p. M.T.I. Maria Elena Gómez Torres. Jefa del Departamento de Servicios Escolares
Estudiante
JGM/kmq

Cuernavaca, Mor., 13/septiembre/2024
No. De Oficio: SAC/317/2024
Asunto: Autorización de impresión de tesis

IRETI TICATAME ROJAS ARREDONDO
CANDIDATO AL GRADO DE MAESTRO EN CIENCIAS
EN INGENIERÍA ELECTRÓNICA
P R E S E N T E

Por este conducto, tengo el agrado de comunicarle que el Comité Tutorial asignado a su trabajo de tesis titulado **“Estimación del Desempeño de un Convertidor CD-CD Usando Redes Neuronales Artificiales Inversas Aplicado a Cosecha de Energía”**, ha informado a esta Subdirección Académica, que están de acuerdo con el trabajo presentado. Por lo anterior, se le autoriza a que proceda con la impresión definitiva de su trabajo de tesis.

Esperando que el logro del mismo sea acorde con sus aspiraciones profesionales, reciba un cordial saludo.

ATENTAMENTE

Excelencia en Educación Tecnológica®
“Conocimiento y tecnología al servicio de México”



CARLOS MANUEL ASTORGA ZARAGOZA
SUBDIRECTOR ACADÉMICO

C. c. p. Departamento de Ingeniería Electrónica
Departamento de Servicios Escolares

CMAZ/lmz

Resumen

Esta tesis se enfoca en el desarrollo y evaluación de un algoritmo para el seguimiento del punto de máxima potencia (MPPT) en sistemas fotovoltaicos, utilizando redes neuronales artificiales inversas (ICANNi). A partir de un análisis exhaustivo del estado del arte, se identificaron las principales limitaciones de los métodos tradicionales como Perturbar y Observar (P&O). Aunque el P&O es ampliamente utilizado por su simplicidad, presenta problemas significativos como las oscilaciones alrededor del punto de máxima potencia y un menor rendimiento en condiciones variables de irradiancia. En este contexto, se diseñó el algoritmo ICANNi, que combina las ventajas de las redes neuronales con una arquitectura eficiente, para superar las deficiencias de los métodos convencionales.

Mediante simulaciones detalladas realizadas en Simulink y Matlab, el ICANNi demostró su superioridad frente al P&O, eliminando las oscilaciones en estado estacionario y mejorando la precisión del seguimiento del punto de máxima potencia. Aunque el tiempo de estabilización del ICANNi es ligeramente mayor, esta desventaja se ve compensada por su capacidad para maximizar la extracción de energía, lo que lo hace especialmente adecuado para su implementación en sistemas fotovoltaicos de mayor escala. Los resultados obtenidos validan la eficacia del ICANNi, sugiriendo su viabilidad para aplicaciones prácticas en entornos de energía solar, contribuyendo así a un uso más eficiente y sostenible de la energía solar.

Abstract

This thesis focuses on the development and evaluation of an advanced algorithm for Maximum Power Point Tracking (MPPT) in photovoltaic systems, using inverse artificial neural networks (ICANNi). Through an exhaustive analysis of the state of the art, the main limitations of traditional methods such as Perturb and Observe (P&O) were identified. Although P&O is widely used due to its simplicity, it presents significant issues such as oscillations around the maximum power point and lower performance under variable irradiance conditions. In this context, the ICANNi algorithm was designed, combining the advantages of neural networks with an efficient architecture, to overcome the shortcomings of conventional methods.

Through detailed simulations conducted in Simulink and Matlab, the ICANNi demonstrated its superiority over P&O by eliminating steady-state oscillations and improving maximum power point tracking accuracy. Although the ICANNi's stabilization time is slightly longer, this disadvantage is offset by its ability to maximize energy extraction, making it particularly suitable for implementation in larger-scale photovoltaic systems. The results obtained validate the effectiveness of ICANNi, suggesting its viability for practical applications in solar energy environments, thus contributing to a more efficient and sustainable use of solar energy.

Dedicatoria

A **mis padres y hermanos**, quienes han sido mi mayor apoyo y motivación. Su amor incondicional y su ejemplo han sido la base de mi esfuerzo y dedicación.

A **Selina**, por estar siempre a mi lado, compartiendo alegrías y dificultades. Tu amor y compañía me han dado fuerzas para superar cada obstáculo.

A **mis padrinos, Bertha y Luis**, quienes hoy atraviesan desafíos que parecen infinitos. Su coraje y su fe, aun en los momentos más difíciles, me llenan de admiración y me recuerdan la importancia de nunca rendirse.

A **mis queridos sobrinos, Horacio, Vale, Isis y Victoria**. Los quiero con todo mi corazón, y espero que algún día encuentren en este trabajo una inspiración para perseguir sus sueños y contribuir al desarrollo de nuestro país.

Finalmente, a **mi querido pueblo de Xochitepec**, siempre presente en mi mente y mi corazón, por ser la raíz que me sostiene y el horizonte que me guía.

Agradecimientos

Quiero expresar mi más sincero agradecimiento al **Consejo Nacional de Humanidades, Ciencia y Tecnología (CONAHCYT)** por su apoyo financiero, que hizo posible la realización de este trabajo. También extendo mi gratitud al **Tecnológico Nacional de México/Centro Nacional de Investigación y Desarrollo Tecnológico (TECNM/CENIDET)**, institución que me proporcionó las herramientas y el entorno necesarios para mi formación académica y profesional.

A mi asesor, el Dr. **Jarniel García Morales**, mis palabras de gratitud no alcanzan a expresar todo lo que su guía, paciencia y apoyo incondicional han significado para mí. Su compromiso y sabiduría me han inspirado a enfrentar cada desafío con determinación y perseverancia.

A mi coasesor, el Dr. **Rodolfo Amalio Vargas**, gracias por su constante disposición y por compartir conmigo su vasto conocimiento. Sus consejos fueron el faro que me permitió navegar en los momentos de duda.

A mis revisores, los doctores **Víctor Hugo Olivares Peregrino** y **Jesús Aguayo Alquicira**, su rigor académico y sus valiosos comentarios fueron clave para enriquecer esta tesis. Estoy profundamente agradecido por su tiempo, dedicación y aportaciones.

A mi **familia** ha sido un verdadero regalo. Su amor incondicional, paciencia y confianza en mí fueron la fuerza que me impulsó en los momentos más desafiantes.

A mis **amigos**, cuya compañía, ánimo y consejos oportunos hicieron que este camino fuera más ligero. A todos ustedes, les agradezco profundamente por ser parte de este proceso y por contribuir de manera invaluable a la realización de este logro.

Contenido

Contenido	ix
Listado de Tablas	xi
Listado de Figuras	xii
Listado de Acrónimos y Símbolos	xiv
CAPÍTULO 1. INTRODUCCIÓN	1
1.1. Antecedentes	2
1.2. Planteamiento del problema	4
1.3. Objetivos	4
1.3.1. Objetivo general	4
1.3.2. Objetivos específicos	4
1.4. Metas	5
1.5. Justificación	5
1.6. Alcance	6
1.7. Hipótesis	6
1.8. Estructura de tesis	7
CAPÍTULO 2. MARCO TEÓRICO	8
2.1. Sistema fotovoltaico	9
2.2. Modelado del panel fotovoltaico	10
2.2.1. Modelado matemático de una celda fotovoltaica	11
2.3. Convertidores CD-CD en el seguimiento del punto de máxima potencia (MPPT) por sus siglas en inglés	12
2.4.1. Convertidor Boost para el seguimiento del punto de máxima potencia (MPPT) relación de impedancias	13
2.4.2. Convertidor Buck en el seguimiento del punto de máxima potencia (MPPT) relación de impedancias	14
2.4.3. Convertidor Buck-Boost en el seguimiento del punto de máxima potencia (MPPT) relación de impedancias	16
2.5. Algoritmos de seguimiento del punto de máxima potencia	17
2.5.1. Perturbar y observar (P&O)	17
2.5.2. RCC (Ripple Correlation Control)	19
2.5.3. Método de la tensión en circuito abierto (V_{oc})	19
2.5.4. Conductancia incremental (IncCond)	21
2.5.5. Controlador Difuso (FLC)	23
2.5.6. Redes Neuronales Artificiales (RNA)	24
CAPÍTULO 3. ESTADO DEL ARTE	36
3.1. Algoritmos de seguimiento del punto de máxima potencia en línea	37

3.2. Algoritmos de seguimiento de máxima potencia fuera de línea	38
3.3. Algoritmos de seguimiento de máxima potencia híbridos	40
<i>CAPÍTULO 4. METODOLOGÍA</i>	43
4.1. Simulación del módulo fotovoltaico EPCOM – EPL32024 en SIMULINK	44
4.2. Diseño del convertidor CD-CD elevador (boost)	45
4.3. Obtención del algoritmo ICANNi	47
4.3.1. Obtención de la red neuronal artificial representativa del sistema fotovoltaico	48
4.3.2. Obtención de la red neuronal artificial inversa (ANNi)	52
4.3.3. Modelo de referencia	53
4.3.4. Ley de control integral (IC)	55
<i>CAPÍTULO 5. PRUEBAS Y RESULTADOS</i>	56
5.1. Variación de irradiancia y temperatura constante de 25°C para el algoritmo perturbar y observar (P&O)	57
5.1.1. Error de seguimiento del punto de máxima potencia del algoritmo P&O	58
5.1.2. Respuesta del algoritmo P&O ante irradiancia real.	59
5.1.3. Índice de desempeño y eficiencia del algoritmo P&O	60
5.2. Variación de irradiancia y temperatura constante de 25°C para el algoritmo ICANNi	61
5.2.1. Error de seguimiento del algoritmo ICANNi	61
5.2.2. Respuesta del algoritmo ICANNi ante irradiancia real	62
5.2.3. Índice de desempeño y eficiencia del algoritmo ICANNi	63
<i>CAPÍTULO 6. CONCLUSIONES Y TRABAJOS FUTUROS</i>	68
6.1. Conclusión	69
6.2. Trabajos futuros	71
<i>REFERENCIAS</i>	72
<i>Anexo A. Hoja de datos del panel EPL32024</i>	77

Listado de Tablas

Tabla 1. Comparación dinámica de los algoritmos en línea.	37
Tabla 2. Comparación dinámica de los algoritmos fuera de línea.	39
Tabla 3. Comparación dinámica de los algoritmos híbridos.	41
Tabla 4. Características eléctricas del panel EPL32024.	44
Tabla 5. Parámetros del convertidor boost.	45
Tabla 6. Relación teórica entre los parámetros de máxima potencia y el ciclo de trabajo del convertidor boost.	47
Tabla 7. Valores de los pesos (w) y sesgos (b) de la red neuronal artificial característica del sistema fotovoltaico.	52
Tabla 8. Índice de desempeño del algoritmo P&O.	60
Tabla 9. Eficiencia promedio del sistema con el algoritmo P&O.	60
Tabla 10. Índice de desempeño del algoritmo ICANNi.	64
Tabla 11. Eficiencia promedio del sistema con el algoritmo ICANNi.	64
Tabla 12. Comparación del algoritmo P&O y el algoritmo ICANNi en terminos de eficiencia.	65
Tabla 13. Comparación del algoritmo P&O y el algoritmo ICANNi en terminos de los indices de desempeño.	66

Listado de Figuras

Figura 1. AIE, Proporción de capacidad de potencia acumulada por tecnología, 2010-2027, AIE, París https://www.iea.org/data-and-statistics/charts/share-of-cumulative-power-capacity-by-technology-2010-2027 , AIE. Licencia: CC BY 4.0.....	3
Figura 2. Circuito representativo de la celda fotovoltaica.....	10
Figura 3. Puntos característicos de las curvas de potencia fotovoltaicas.....	11
Figura 4. Curva de potencia de un sistema fotovoltaico.....	12
Figura 5. Topología del convertidor Boost.....	13
Figura 6. Topología del convertidor Buck.....	14
Figura 7. Topología del convertidor Buck-Boost.....	16
Figura 8. Diagrama de flujo del algoritmo perturbar y observar (P&O).....	18
Figura 9. Diagrama de flujo del algoritmo conductancia incremental IncCond.....	22
Figura 10. Diagrama de bloques del algoritmo FLC.....	24
Figura 11. Esquema básico de una red neuronal artificial (RNA).....	26
Figura 12. (a) función de activación escalón, (b) función de activación escalón simétrica o bipolar.	27
Figura 13. Función de activación lineal.....	27
Figura 14. Función de activación sigmoide.....	28
Figura 15. Función de activación tangente hiperbólica.....	29
Figura 16. Esquema de una red neuronal feed-forward simple.....	30
Figura 17. Esquema de una red feed-forward multicapa con una única capa oculta.....	30
Figura 18. Red neuronal recurrente con conexiones bidireccionales. John J. Hopfield. Neural networks and physical systems with emergent collective computational abilities. Proceedings of the National Academy of Sciences, 79(8):2554–2558, 1982. URL http://www.pnas.org/content/79/8/2554	31
Figura 19. Proceso de entrenamiento de una red neuronal artificial [28].	32
Figura 20. Desempeño de los diferentes algoritmos para el seguimiento del punto de máxima potencia.....	42
Figura 21. Curvas características V-I del módulo fotovoltaico EPL32024.....	45
Figura 22. Relación de impedancia bajo diferentes irradiancias.....	46
Figura 23. ANN característica del sistema fotovoltaico.....	48
Figura 24. Ciclo de trabajo utilizado como variable de entrada para el entrenamiento de la red.....	50
Figura 25. Corriente de máxima potencia utilizada como variable de entrada para el entrenamiento de la red.....	50
Figura 26. Voltaje de máxima potencia utilizado como variable de entrada para el entrenamiento de la red.....	51
Figura 27. Irradiancia del panel utilizada como variable de salida para el entrenamiento de la red.	51
Figura 28. Esquema de la red neuronal inversa.....	53
Figura 29. Salida deseada del ciclo de trabajo frente a los valores predichos por la red.....	54
Figura 30. Diagrama esquemático de las interconexiones del sistema fotovoltaico con el algoritmo ICANNi.....	55
Figura 31. Diagrama esquemático de las interconexiones del sistema fotovoltaico con el algoritmo P&O.....	57
Figura 32. Seguimiento del punto de máxima potencia con el algoritmo P&O.....	58
Figura 33. Error del seguimiento del algoritmo P&O.....	58
Figura 34. Irradiancia incidida en Cuernavaca en las fechas 01-12-2019 – 01-12-2019.....	59

Figura 35. Seguimiento del punto de máxima potencia con el algoritmo P&O con irradiancia real.
..... 60

Figura 36. Seguimiento del punto de máxima potencia con el algoritmo ICANNi. 61

Figura 37. Error del seguimiento del algoritmo ICANNi..... 62

Figura 38. Seguimiento del punto de máxima potencia con el algoritmo ICANNi e irradiancia real.
..... 63

Listado de Acrónimos y Símbolos

Acrónimos

ACO	Algoritmo de optimización de colonias de hormigas
ANNi	Artificial Neural Network Inverse (Red neuronal artificial inversa)
CD – CD	Corriente Directa a Corriente Directa
CO_2	Dióxido de Carbono
FLC	Fuzzy Logic Control (Controlador Difuso)
FVoc	Voltaje Fraccional
HHO	Harris Hawk Optimization
IC	Integral Control
IncCond	Conductancia incremental
MAPE %	Error porcentual absoluto medio
MPC	Modelo de control predictivo
MPPT	Maximum Power Point Tracking (Seguimiento del punto de máxima potencia)
MRFO	Algoritmo de optimización de forrajeo de la mantarraya
MSE	Error cuadrático medio
PID	Control proporcional integral derivativo
P&O	Perturb and Observe (Perturbar y observar)
PMP	Punto de Máxima Potencia
PSO	Algoritmo de optimización de enjambre de partículas
PWM	Pulse Width Modulation (Modulación por ancho de pulso)
RNA	Redes Neuronales Artificiales
ROA	Algoritmo de optimización de la rémora
SFA	Sistema fotovoltaico autónomo
SSO	Algoritmo de optimización de salpas
<i>TWh</i>	Teravatios hora

Símbolos

A	Factor de Idealidad
C	Capacitor
$D1$	Diodo uno
D_{max}	Ciclo de trabajo máximo
D_{min}	Ciclo de trabajo mínimo
$D_{inicial}$	Ciclo de trabajo inicial
$D(k)$	Ciclo de trabajo en el instante k
$D(k - 1)$	Ciclo de trabajo en el instante anterior
$D(k + 1)$	Ciclo de trabajo en el instante siguiente
G	Irradiancia solar
I	Corriente
I_L	Corriente fotogenerada
$I(k)$	Corriente en el instante k
$I(k - 1)$	Corriente en el instante anterior
$I(k + 1)$	Corriente en el instante siguiente
I_{mp}	Corriente del punto de máxima potencia
I_o	Corriente de saturación inversa
I_{pv}	Corriente del panel
I_{sc}	Corriente en cortocircuito
K_{oc}	Constante de proporcionalidad
L	Inductor
M	Ganancia del convertidor
f	Frecuencia de conmutación
$f(\cdot)$	Función de activación
k	Constante de Boltzmann
P_{pv}	Potencia del panel
P_o	Potencia de salida
P_{in}	Potencia se entrada
R	Resistor
R_S	Resistencia en serie
R_{SH}	Resistencia en paralelo
T_c	Temperatura de la celda
$Tanh$	Tangente hiperbólica
$u(t)$	Entrada total (suma ponderada de entradas)
V_{in}	Voltaje de entrada
$V(k)$	Voltaje en el instante k
$V(k - 1)$	Voltaje en el instante anterior
$V(k + 1)$	Voltaje en el instante siguiente
V_{mp}	Voltaje del punto de máxima potencia
V_o	Voltaje de salida
V_{oc}	Voltaje en circuito Abierto
V_{pv}	Voltaje del panel
Z_{in}	Impedancia de entrada
Z_o	Impedancia de salida

i_L	Corriente del Inductor
K	Constante de Boltzmann
K_{oc}	Constante de proporcionalidad
n_c	Eficiencia teórica del convertidor
n_{ce}	Eficiencia de conversión energética
n_t	Eficiencia total del sistema
x_{jmin}	Dato de entrada mínimo
x_{jmax}	Dato de entrada máximo
y_{ann}	Salida de la red
z	Gradiente escalar
θ	Sesgo $bi(s)$
Δd	Variación del ciclo de trabajo
ΔP	Variación de la potencia
ΔV_c	Variación en el voltaje del capacitor (rizo)
Δi_L	Variación en la corriente del inductor (rizo)
ΔI	Variación de corriente
ΔV	Variación de voltaje

CAPÍTULO 1.

INTRODUCCIÓN

El cambio climático y la escasez de recursos fósiles han provocado una transición energética global hacia fuentes de energía renovables y sostenibles. La energía solar fotovoltaica emerge como una solución prometedora debido a su capacidad para reducir las emisiones de dióxido de carbono y por su creciente competitividad económica. México, gracias a su ubicación geográfica posee un gran potencial para la producción de energía solar fotovoltaica. Sin embargo, los sistemas fotovoltaicos enfrentan desafíos de eficiencia debido a múltiples condiciones operativas que limitan su rendimiento.

Este documento se centra en el diseño y evaluación de un convertidor CD-CD (corriente directa a corriente directa), que será controlado mediante un algoritmo basado en redes neuronales artificiales. En esta investigación, se explora una nueva estrategia para mejorar la eficiencia de los sistemas fotovoltaicos en el contexto de la energía solar en México. A través de simulaciones, se ha observado que el algoritmo propuesto mejora significativamente la extracción de energía en estos sistemas. Además, su aplicación podría extenderse a sistemas de paneles fotovoltaicos de mayor escala, con el potencial de contribuir a la sostenibilidad energética del país.

1.1. Antecedentes

La generación de energía por medio de la quema de recursos tiene un impacto ambiental significativo desde la extracción en la mina o yacimiento, su transporte y procesamiento, hasta su uso final. Los altos volúmenes de CO_2 que produce el hombre son el mayor causante de impactos ambientales. Las grandes cantidades de este gas ya no son absorbidas de forma natural por la tierra, lo que provoca que las ondas de radiación infrarroja regresen a la superficie terrestre, ocasionando el calentamiento de los océanos y del aire cercano [1].

En la actualidad, el uso de energías renovables a detonado de forma muy importante, no solamente por los compromisos internacionales para frenar el calentamiento global, sino también por la escasa reserva que se tiene del combustible fósil y el aumento del costo de importación que la escasez y la guerra causan. Sin embargo, estos altos precios a los combustibles fósiles mejoran la competitividad de la energía solar fotovoltaica frente a otros combustibles. En consecuencia, la cosecha de energía fotovoltaica se vuelve

atractiva debido a las propiedades que esta ofrece; disminución de las emisiones de efecto invernadero, alta fiabilidad, mayor flexibilidad, bajo costo de generación y su alta eficiencia en comparación con los sistemas de generación de energía basados en fuentes convencionales.

El crecimiento récord en la producción de energía fotovoltaica de 179 TWh en 2021 representa un crecimiento del 22% en comparación al 2020. Este tipo de generación representa el 3.6% de la generación mundial de electricidad, y es la tercera forma de cosecha renovable más grande imponiéndose ante ella la hidroeléctrica y la eólica [2]. En la Figura 1, se observa el incremento de la generación de energía renovable en los últimos años, y la proyección para el 2027.

La proyección estima que la generación de energía fotovoltaica supere a la del carbón en el 2027 y esta se convierta en la proporción más grande del mundo. Esta proyección representa un aumento a la promoción y desarrollo de metodologías técnicas que nos permita diseñar sistemas de cosecha que aprovechen al máximo la capacidad del sistema fotovoltaico [2].

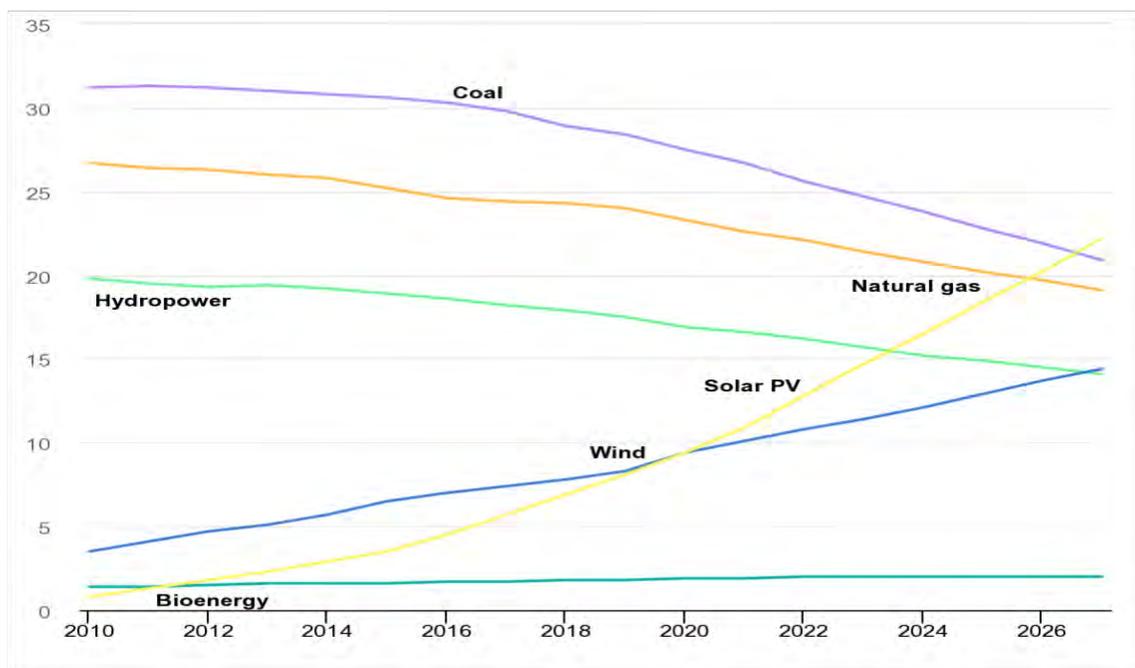


Figura 1. AIE, Proporción de capacidad de potencia acumulada por tecnología, 2010-2027, AIE, París <https://www.iea.org/data-and-statistics/charts/share-of-cumulative-power-capacity-by-technology-2010-2027>, AIE. Licencia: CC BY 4.0

1.2. Planteamiento del problema

México posee una localización geográfica favorable para la producción de energía eléctrica por medio de sistemas fotovoltaicos, sin embargo, estos sistemas tienen una baja eficiencia es por eso por lo que requerimos extraer la máxima potencia de los paneles, y de esta manera aprovechar en su totalidad la energía generada por el panel [3, 4].

Los paneles poseen curvas características que describen su comportamiento en diferentes condiciones de operación, esta curva se ve afectada por la radiación solar, la temperatura del panel, y la resistencia de carga. La potencia de los paneles está dada por el producto de la tensión y corriente de salida. Dentro de la curva de " $I - V$ " existirá un punto donde la potencia suministrada por el panel será máxima, a este punto le llamaremos "Punto máximo de potencia". La cosecha de energía fotovoltaica enfrenta problemas para mantener el mejor rendimiento en diferentes condiciones de operación, las características de corriente–tensión, y potencia–tensión son irregulares debido a los cambios en las condiciones meteorológicas. Esta no linealidad del sistema requiere la implementación de algoritmos de seguimiento del punto de máxima potencia (MPPT) que permitan la correcta predicción del punto de máxima potencia (PMP). [5, 6].

1.3. Objetivos

1.3.1. Objetivo general

Diseñar y evaluar el desempeño de un convertidor CD-CD que permita extraer la máxima potencia de un sistema de cosecha de energía utilizando como herramienta principal redes neuronales artificiales inversas.

1.3.2. Objetivos específicos

- Proponer un convertidor CD-CD que cumpla con las características del sistema de cosecha de energía (sistema fotovoltaico).
- Obtener una red neuronal artificial adecuada que sea representativa del sistema fotovoltaico.
- Obtener una red neuronal artificial inversa que nos permita extraer el punto de máxima potencia.

- Obtener el desempeño del sistema fotovoltaico aplicando la metodología de redes neuronales artificiales para el seguimiento del punto de máxima potencia.

1.4. Metas

- Obtener un algoritmo de seguimiento de máxima potencia basado en redes neuronales artificiales inversas.
- Obtener el desempeño del convertidor con el algoritmo de seguimiento propuesto.

1.5. Justificación

El incremento de temperatura en nuestro globo terráqueo, la escasez global de recursos fósiles y la fractura diplomática entre las naciones de primer mundo abren una posibilidad económica, viable y sustentable de cosecha energética. Se estima que para un futuro próximo la generación de energía fotovoltaica supere a la del carbón, estas proyecciones no solo son positivas para el medio ambiente, sino que representan un gran reto para las naciones, ya que requieren de mayores esfuerzos tecnológicos para mejorar el rendimiento de estos sistemas.

El desarrollo de algoritmos de seguimiento del punto de máxima potencia ha experimentado un crecimiento exponencial en las últimas décadas. Una manera efectiva de mejorar la eficiencia de los sistemas fotovoltaicos es a través de un convertidor CD-CD que es controlado por ancho de pulso (PWM) por medio de un algoritmo de seguimiento, que permite al sistema estar en el punto de máxima potencia (PMP). El desarrollo de estos algoritmos es un tema fundamental para el diseño e implementaciones de los sistemas fotovoltaicos. Sin embargo, cada uno presenta sus propias ventajas y desventajas. Por ejemplo, el algoritmo de *Incremental Conductance* (IncCond) y el algoritmo de *Perturb and Observe* (P&O) son sencillos de implementar, pero ambos pueden causar oscilaciones alrededor del punto de máxima potencia y enfrentan dificultades en condiciones de sombreado parcial. Por otro lado, los algoritmos de optimización y las redes neuronales están ganando terreno debido a su capacidad para adaptarse a condiciones variables y gestionar de manera más efectiva situaciones de sombreado parcial, aunque su implementación es más compleja y requiere un mayor costo computacional.

Con este proyecto se busca incorporar un algoritmo basado en redes neuronales artificiales inversas para el seguimiento del punto de máxima potencia la cual presenta una arquitectura sencilla, que no requiere de un alto coste computacional y pueda competir con los algoritmos que presentan desempeños altos, con bajas oscilaciones, que tienen un coste computacional alto. De esta manera creamos un algoritmo que se pueda implementar de manera sencilla, y cuente con un desempeño mayor a los algoritmos convencionales.

1.6. Alcance

Se propone el desarrollo de un algoritmo de seguimiento que contenga las siguientes características:

- a) Diseño y simulación de un convertidor CD-CD.
- b) Caracterización de un panel fotovoltaico con herramientas de Matlab.
- c) Diseño y simulación de una red neuronal artificial representativa del sistema fotovoltaico.
- d) Obtención de la red neuronal artificial inversa.
- e) Simulación de la red neuronal artificial inversa para el seguimiento del punto de máxima potencia.
- f) Comparación del algoritmo propuesto con el algoritmo perturbar y observar P&O.

1.7. Hipótesis

Es posible que el algoritmo de seguimiento del punto de máxima potencia ICANNi reducirá significativamente las oscilaciones en la salida del sistema fotovoltaico y mejorará su desempeño en comparación con los algoritmos convencionales existentes. Para probar esta hipótesis, se pueden realizar pruebas comparativas entre el desempeño del algoritmo de seguimiento del punto de máxima potencia ICANNi y el algoritmo convencional P&O en diferentes condiciones de operación del sistema fotovoltaico. Se pueden medir las oscilaciones en la salida del sistema y comparar la eficiencia energética y producción de energía de ambos algoritmos para evaluar su desempeño.

1.8. Estructura de tesis

1.8.1. Capítulo 1. Introducción:

En este capítulo se presenta el contexto general de la investigación, incluyendo la importancia de la energía fotovoltaica y la necesidad de optimizar los sistemas de cosecha de energía solar. Se plantean los objetivos, metas, justificación y alcance del estudio, así como la hipótesis que guiará la investigación.

1.8.2. Capítulo 2. Marco Teórico:

Este capítulo ofrece una revisión detallada de los conceptos fundamentales relacionados con los sistemas fotovoltaicos y los convertidores CD-CD. Se analizan los principios de funcionamiento de las celdas solares, los diferentes tipos de convertidores y los algoritmos de seguimiento del punto de máxima potencia (MPPT).

1.8.3. Capítulo 3. Estado del Arte:

Aquí se realiza una revisión exhaustiva de la literatura existente sobre los algoritmos de MPPT, destacando las tecnologías y métodos más avanzados y eficaces. Se comparan diferentes algoritmos y se evalúan sus ventajas y desventajas en términos de eficiencia y adaptabilidad.

1.8.4. Capítulo 4. Método de Solución:

En este capítulo se describe el diseño y la simulación del sistema propuesto. Se detallan los pasos seguidos para modelar y simular el convertidor CD-CD y el sistema fotovoltaico utilizando herramientas como Matlab y Simulink. Se explica la implementación del algoritmo ICANNi.

1.8.5. Capítulo 5. Pruebas y Resultados:

Se presentan los resultados de las simulaciones y pruebas realizadas. Se comparan los desempeños de los algoritmos P&O e ICANNi bajo diferentes condiciones de irradiancia y temperatura. Los resultados se analizan y se discute la eficiencia y precisión del algoritmo ICANNi en comparación con los métodos convencionales.

1.8.6. Capítulo 6. Conclusiones Generales:

El capítulo final resume los hallazgos clave de la investigación, destacando la superioridad del algoritmo ICANNi. Se discuten las implicaciones de estos resultados para el futuro de la energía fotovoltaica y se ofrecen recomendaciones para investigaciones futuras y desarrollos tecnológicos adicionales.

CAPÍTULO 2. MARCO TEÓRICO

2.1. Sistema fotovoltaico

Los sistemas fotovoltaicos son una forma cada vez más popular de generación de energía renovable que utiliza paneles solares para convertir la luz del sol en electricidad. Estos sistemas aprovechan la energía solar, una fuente abundante y limpia de energía, para proporcionar electricidad de manera sostenible. Constan principalmente de paneles solares, convertidores CD-CD y otros componentes eléctricos necesarios para capturar y transformar la energía solar en electricidad utilizable. Los paneles solares están compuestos por células fotovoltaicas, que son dispositivos semiconductores que generan electricidad cuando la luz del sol incide sobre ellos.

Existen varias variables clave que influyen en el rendimiento y la eficiencia de un sistema fotovoltaico. A continuación, se presentan algunas de las variables más importantes y cómo afectan al sistema:

- *Radiación solar*: La cantidad de radiación solar incidente en un lugar determinado es fundamental para la generación de electricidad. Lugares con mayor exposición solar tendrán un mayor potencial de producción de energía.
- *Ángulo y orientación de los paneles solares*: La inclinación y orientación de los paneles solares pueden maximizar la captación de radiación solar. Un ángulo óptimo y una orientación adecuada hacia el sol pueden aumentar significativamente la eficiencia del sistema.
- *Eficiencia de los paneles solares*: La eficiencia de las células fotovoltaicas determina la cantidad de electricidad generada por una determinada cantidad de luz solar. Paneles solares más eficientes pueden generar más electricidad en el mismo espacio.
- *Sombreado*: El sombreado parcial o total de los paneles solares puede reducir drásticamente la generación de energía. Incluso una pequeña sombra en un panel puede afectar el rendimiento de todo el sistema, por lo que es esencial evitar o minimizar cualquier obstrucción.
- *Temperatura ambiente*: Las células fotovoltaicas son sensibles a la temperatura, y un aumento en la temperatura puede disminuir la eficiencia de los paneles

solares. Por lo tanto, mantener una temperatura adecuada es importante para optimizar el rendimiento.

- **Mantenimiento y limpieza:** Los sistemas fotovoltaicos requieren un mantenimiento regular, que incluye la limpieza de los paneles solares para eliminar cualquier acumulación de suciedad o polvo. La suciedad en los paneles puede reducir su eficiencia y disminuir la cantidad de energía generada.

Estas variables son fundamentales para comprender el rendimiento y la eficiencia de los sistemas fotovoltaicos. Al tener en cuenta estos factores y optimizarlos, es posible aprovechar al máximo la energía solar y maximizar la producción de electricidad renovable.

2.2. Modelado del panel fotovoltaico

Se han desarrollado diferentes modelos matemáticos que describen de manera gráfica el comportamiento de una celda. Estos modelos normalmente se basan en la relación de corriente-voltaje que se manifiesta en el diodo (D1) [7]. El circuito equivalente de una celda fotovoltaica se representa por una fuente de corriente fotogenerada por acción de la radiación solar, un diodo, una resistencia en paralelo y una resistencia en serie. La fuente de corriente fotogenerada modela la corriente producida por la celda al recibir la radiación solar. El diodo representa la unión p-n de la celda, capturando la relación no lineal entre corriente y voltaje. La resistencia en paralelo simboliza las pérdidas por fugas de corriente dentro de la celda, mientras que la resistencia en serie refleja las pérdidas internas debido a la resistencia del material semiconductor y los contactos. A continuación, se muestra un circuito representativo de la celda [8-10]:

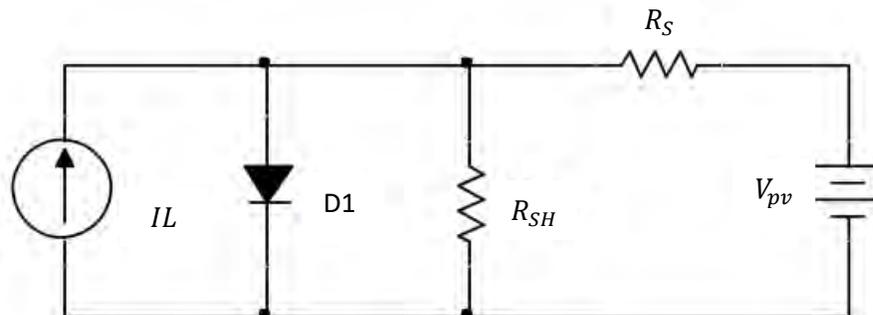


Figura 2. Circuito representativo de la celda fotovoltaica.

A partir de la representación eléctrica de la celda podemos obtener el modelo matemático, el modelo está en función de la radiación y la temperatura de la celda. La temperatura juega un papel crucial en este modelo, ya que influye directamente en el comportamiento del diodo y la resistencia en serie y paralelo, afectando así la eficiencia y el rendimiento de la celda.

2.2.1. Modelado matemático de una celda fotovoltaica

Las características representativas de una celda se representan por medio de gráficas de voltaje-corriente y voltaje-potencia. En la figura 3, se presentan los puntos característicos de las curvas, como son: la corriente en corto circuito (I_{SC}). El voltaje de circuito abierto (V_{OC}), el punto de máxima potencia (MPP), el voltaje en el punto de máxima potencia (V_{MPP}), la corriente del punto de máxima potencia (I_{MPP}) y la potencia en el punto de máxima potencia (P_{MPP}) [8-10].

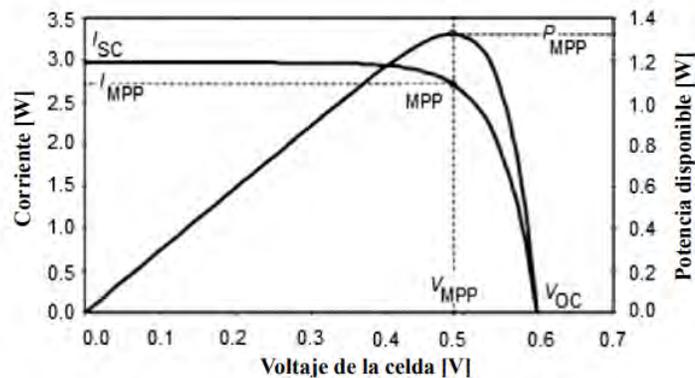


Figura 3. Puntos característicos de las curvas de potencia fotovoltaicas.

La curva voltaje-corriente en la celda se describe por medio de la ecuación 1:

$$I_{pv} = I_L - I_0 \left[e^{\frac{q(V+R_S I_{pv})}{a}} - 1 \right] - \frac{V_{pv} + R_S I_{pv}}{R_{SH}} \quad (1)$$

Donde:

I_L : Es la corriente fotogenerada.

I_0 : Es la corriente de saturación inversa.

R_S : Es la resistencia en serie.

R_{SH} : Es la resistencia en paralelo.

V_{pv} : Es el voltaje del panel.

q : Es la carga del electrón ($1.6 \times 10^{-19} C$).

a : parámetro dado por la ecuación 2:

$$a = kT_c A \quad (2)$$

Donde:

k : Es la constante de Boltzmann ($1.38 \times 10^{-23} \frac{J}{K}$).

T_c : Es la temperatura de la celda.

A : Es el factor de idealidad.

2.3. Convertidores CD-CD en el seguimiento del punto de máxima potencia (MPPT) por sus siglas en inglés

Los sistemas fotovoltaicos utilizan un convertidor de voltaje, generalmente del tipo CD-CD, para elevar o reducir la tensión según las necesidades del sistema. El convertidor más comúnmente utilizado para elevar el voltaje es el boost, mientras que el Buck se utiliza para reducirlo. Otras opciones incluyen los convertidores buck-boost, cúk, sepic y zeta. El objetivo principal del convertidor es maximizar la potencia operativa del sistema fotovoltaico y mantener el seguimiento del punto de máxima potencia. La literatura se centra en el uso del boost y el buck. La curva I-V de los paneles fotovoltaicos tiene dos regiones de operación: una como fuente de corriente y otra como fuente de voltaje, y el punto de máxima potencia siempre se encuentra en el codo de la curva. Este punto es el lugar en el que se maximiza la potencia fotovoltaica generada y se determina a partir de las condiciones dinámicas de los paneles [11, 12]. En la Figura 4, se presentan estas regiones:

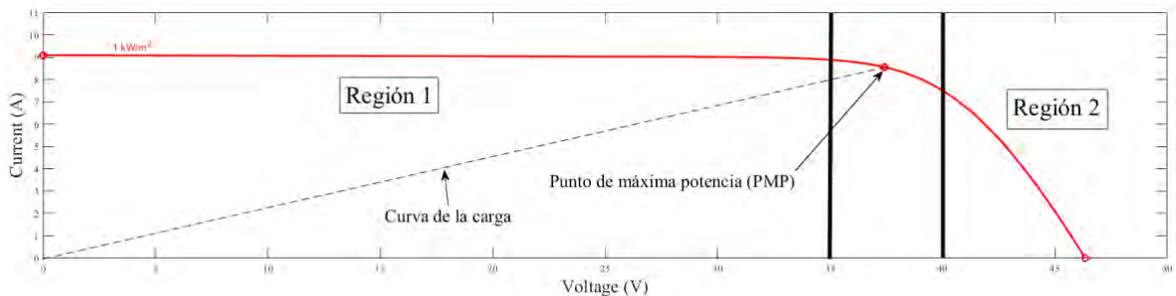


Figura 4. Curva de potencia de un sistema fotovoltaico.

En la búsqueda del punto de máxima potencia en los paneles fotovoltaicos, es importante optimizar el flujo de potencia hacia la carga y para ello se utiliza el algoritmo de MPPT. La configuración comúnmente utilizada para este algoritmo implica modificar la impedancia de entrada del convertidor para maximizar la potencia de salida del panel. Es esencial que exista una impedancia de entrada que permita la máxima transferencia de potencia para extraer la potencia máxima. Sin embargo, la impedancia de entrada en un convertidor CD-CD depende del ciclo de trabajo y de la impedancia de carga, lo que implica que no todos los convertidores pueden utilizarse como seguidores del punto de máxima potencia, a menos que se establezcan adecuadamente sus límites de operación [11, 12].

2.4.1. Convertidor Boost para el seguimiento del punto de máxima potencia (MPPT) relación de impedancias

La literatura menciona al convertidor boost como una opción común para realizar el seguimiento del punto de máxima potencia, sin embargo, la aplicación del convertidor dependerá de las necesidades que el sistema demande en esta etapa de conversión energética. La topología del convertidor boost se presenta en la Figura 5, la ecuación 3 y 4 corresponden a las ecuaciones dinámicas del convertidor:

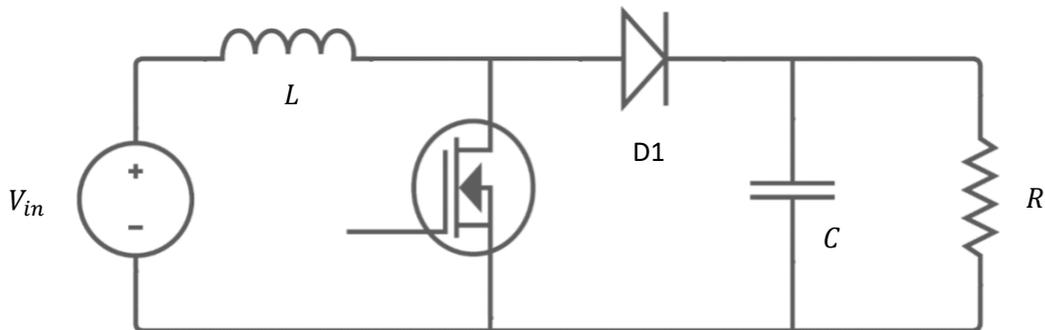


Figura 5. Topología del convertidor Boost.

$$\frac{di_L}{dt} = -\frac{1-d}{L} V_o + \frac{V_{in}}{L} \quad (3)$$

$$\frac{dV_o}{dt} = \frac{1-d}{C} i_L - \frac{V_o}{RC} \quad (4)$$

Para obtener la relación de impedancias entre la impedancia de entrada (Z_{in}) y la impedancia de salida (Z_{out}) iniciamos con la relación de ganancia del convertidor que se muestra en la ecuación 5:

$$M = \frac{V_o}{V_{in}} = \frac{1}{1-d} \quad (5)$$

Si se considera que el sistema no tiene pérdidas por conmutación, consideramos que la potencia de entrada P_{in} debe ser igual a la potencia de salida P_o , como se presenta en la ecuación 6.

$$i_{in}(V_{in}) = i_{out}(V_{out}) \quad (6)$$

Si la igualdad la expresamos en función de la impedancia se obtiene la ecuación 7:

$$\frac{V_{in}^2}{Z_{in}} = \frac{V_o^2}{Z_o} \quad (7)$$

Acomodando la expresión y sustituyendo la ecuación 5 en la ecuación 7 y despejando la impedancia de entrada se obtiene una expresión que depende del ciclo de trabajo, la ecuación 8, describe lo antes dicho:

$$Z_{in} = Z_o(1-d)^2 \quad (8)$$

2.4.2. Convertidor Buck en el seguimiento del punto de máxima potencia (MPPT) relación de impedancias

En aplicaciones donde se requiera un convertidor reductor, normalmente se utiliza el convertidor Buck (reductor). En la Figura 6, se presenta la topología del convertidor, así como sus ecuaciones dinámicas (ecuación 8 y 9).

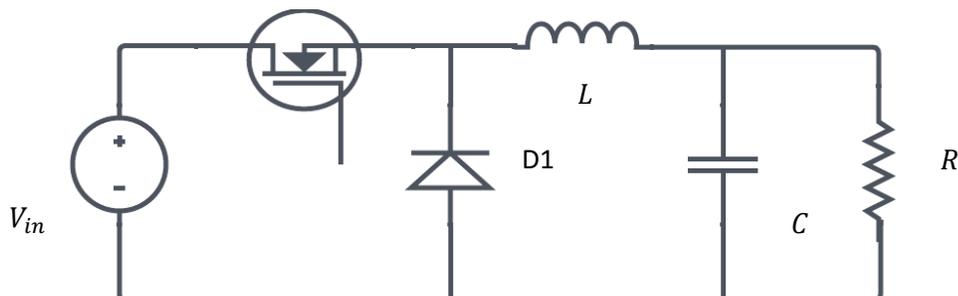


Figura 6. Topología del convertidor Buck.

$$\frac{di_L}{dt} = -\frac{V_o}{L} + \frac{d}{L}V_{in} \quad (8)$$

$$\frac{dV_o}{dt} = \frac{i_L}{C} - \frac{V_o}{RC} \quad (9)$$

Para obtener la relación de impedancias entre la impedancia de entrada (Z_{in}) y la impedancia de salida (Z_{out}) iniciamos con la relación de ganancia del convertidor que se muestra en la ecuación 10:

$$M = \frac{V_o}{V_{in}} = d \quad (10)$$

Si se considera que el sistema no tiene pérdidas por conmutación, consideramos que la potencia de entrada P_{in} debe ser igual a la potencia de salida P_o , como se presenta en la ecuación 6. Si la igualdad la expresamos en función de la impedancia se obtiene la ecuación 7. Acomodando la expresión y sustituyendo la ecuación 10 en la ecuación 7 y despejando la impedancia de entrada se obtiene una expresión que depende del ciclo de trabajo, la ecuación 11, describe lo antes dicho:

$$\frac{Z_o}{Z_{in}} = \frac{V_o^2}{V_{in}^2} = d^2 \rightarrow Z_{in} = \frac{Z_o}{d^2} \quad (11)$$

Es de suma importancia considerar el teorema de máxima transferencia de energía al diseñar un convertidor. Este teorema establece que la potencia de salida será máxima cuando la impedancia de entrada coincida con la impedancia de salida, lo que hace que el esquema de seguimiento sea una búsqueda de concordancia de impedancias mediante la modificación del ciclo de trabajo. Sin embargo, en ciertas condiciones de operación, el convertidor no podrá obtener la máxima potencia debido a las relaciones de impedancias con el ciclo de trabajo, lo que se debe tener en cuenta al diseñar el convertidor [11, 12].

2.4.3. Convertidor Buck-Boost en el seguimiento del punto de máxima potencia (MPPT) relación de impedancias

La combinación en cascada del convertidor Buck y el convertidor Boost resulta en un convertidor que puede proveer una salida elevadora o reductora del voltaje de entrada con una polaridad inversa [13]. En la Figura 7, se presenta la topología del convertidor Buck-Boost, así mismo en las ecuaciones 12, y 13 se presenta la dinámica del convertidor:

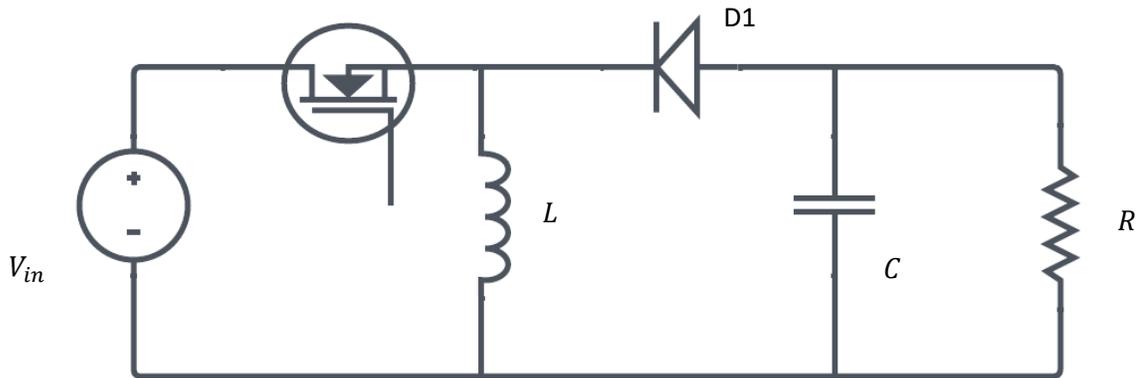


Figura 7. Topología del convertidor Buck-Boost.

$$\frac{di_L}{dt} = \frac{(1-d)V_o}{L} + \frac{d}{L}V_{in} \quad (12)$$

$$\frac{dV_o}{dt} = \frac{i_L}{C} - \frac{V_o}{RC} \quad (13)$$

Para obtener la relación de impedancias entre la impedancia de entrada (Z_{in}) y la impedancia de salida (Z_{out}) iniciamos con la relación de ganancia del convertidor que se muestra en la ecuación 14.

$$M = \frac{V_o}{V_{in}} = \frac{d}{1-d} \quad (14)$$

Tomando en cuenta la expresión de la ecuación 7 y la ganancia del convertidor (ecuación 14) tenemos que:

$$\frac{V_{in}^2}{Z_{in}} = \frac{V_o^2}{Z_o} = \frac{\left(V_{in} \left(\frac{d}{1-d}\right)\right)^2}{Z_o} \quad (15)$$

Despejando la impedancia de entrada obtenemos una expresión que esta en función del ciclo de trabajo:

$$\frac{V_{in}^2}{Z_{in}} = \frac{\left(V_{in} \left(\frac{d}{1-d}\right)\right)^2}{Z_o} \rightarrow \frac{1}{Z_{in}} = \frac{d^2}{Z_o(1-d)^2} \rightarrow Z_{in} = Z_o \left(\frac{1-d}{d}\right)^2 \quad (16)$$

2.5. Algoritmos de seguimiento del punto de máxima potencia

2.5.1. Perturbar y observar (P&O)

Esta técnica es ampliamente utilizada en dispositivos comerciales y sirve de base para la mayoría de los algoritmos más avanzados descritos en la literatura. El método P&O se emplea ampliamente debido a su bajo costo y facilidad de implementación. Consiste en alterar la tensión del panel fotovoltaico en una dirección específica mediante la modificación del ciclo de trabajo del convertidor CD-CD (Δd), y luego observar cómo se comporta la potencia de salida. Si la potencia aumenta, se continúa con la alteración en la misma dirección; de lo contrario, se realiza una alteración en sentido contrario.

Este proceso se repite periódicamente, lo que provoca que la potencia oscile alrededor del punto de máxima potencia (PMP) en estado estacionario, desperdiciando así parte de la energía disponible en el panel fotovoltaico. Para asegurar un comportamiento adecuado tanto en términos dinámicos como en estado estacionario, es crucial seleccionar cuidadosamente un valor apropiado para Δd . El principal inconveniente de este método es el desplazamiento ocasional del PMP debido a cambios rápidos en las condiciones climáticas, como la presencia de nubes en movimiento. La Figura 8 ilustra el flujo de esta técnica [14-16].

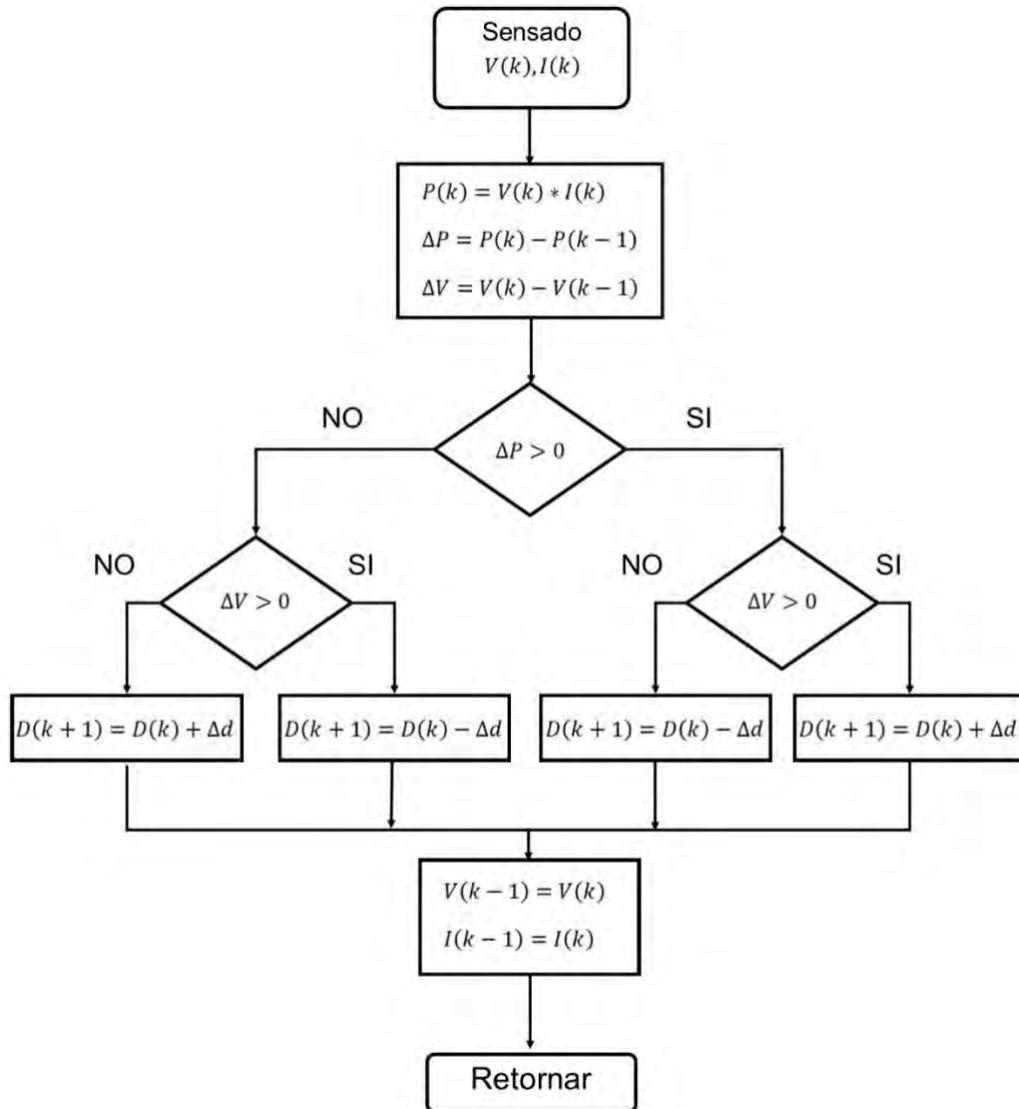


Figura 8. Diagrama de flujo del algoritmo perturbar y observar (P&O).

Las principales desventajas de este algoritmo son:

- El sistema nunca opera en el punto máximo de potencia, sino que oscilará en torno a él.
- Pierde efectividad ante perturbaciones bruscas en la irradiación solar y la temperatura.

Si bien se han realizado modelos donde estos comportamientos se ven atenuados añaden complejidad al método, y ralentizan el funcionamiento de este [17].

2.5.2. RCC (Ripple Correlation Control)

Cuando un panel fotovoltaico está conectado a un convertidor de potencia la acción de conmutación del convertidor impondrá corriente y voltaje. Esto provoca una ondulación en el sistema. El algoritmo RCC pretende utilizar esta ondulación para realizar el MPPT, como esta onda está totalmente disponible, queda perturbar esta señal para aplicar el control. La comparación del valor del voltaje y corriente la realiza con los valores del MPPT. El algoritmo RCC va a forzar la onda a su decremento hasta cero, y finalmente arrastrara el voltaje y la corriente del panel al punto máximo de potencia [18].

2.5.3. Método de la tensión en circuito abierto (V_{oc})

El método de la tensión en circuito abierto (V_{oc}) es una técnica utilizada en la caracterización y optimización de células solares y módulos fotovoltaicos. Se basa en la observación de una relación lineal entre la tensión en circuito abierto (V_{oc}) y la tensión máxima de potencia (V_{mp}) que se puede obtener de la célula o el módulo. Esta relación lineal es una característica inherente de las células solares y se utiliza para determinar la constante de proporcionalidad (k_{oc}) entre estas dos tensiones [19]. En la ecuación 17, muestra lo antes descrito:

$$V_{MP} = k_{OC}V_{OC} \quad (K_{OC} < 1) \quad (17)$$

Para obtener el valor de k_{oc} se realizan mediciones experimentales continuas de las tensiones en diferentes condiciones. Se utiliza una ecuación (Ec. 17) para calcular el punto de máxima potencia (PMP) y se selecciona la tensión correspondiente a ese punto como la tensión óptima. Luego, se compara esta tensión óptima con la tensión en circuito abierto para verificar la constante de proporcionalidad seleccionada en esa condición específica. Sin embargo, este algoritmo tiene algunas limitaciones. Para medir las tensiones en cada período de tiempo y en cada condición meteorológica, se requiere interrumpir el proceso del algoritmo, lo que puede resultar en pérdida de energía. Además, este método puede no ser muy preciso en casos de sombreado parcial, donde ciertas secciones del módulo fotovoltaico están expuestas a una menor radiación solar debido a obstáculos o condiciones ambientales específicas [19].

Ventajas del algoritmo V_{oc} :

- Simplicidad: El algoritmo V_{oc} es relativamente simple de implementar y comprender. Utiliza mediciones de tensión en circuito abierto y tensión máxima de potencia para establecer una relación lineal y determinar la constante de proporcionalidad entre ambas.
- Utilización de características inherentes: Aprovecha la relación lineal entre la tensión en circuito abierto y la tensión máxima de potencia, que es una característica inherente de las células solares y módulos fotovoltaicos. Esto permite obtener una estimación rápida de la tensión máxima de potencia sin necesidad de mediciones exhaustivas.
- Cálculo del punto de máxima potencia (MPP): El algoritmo V_{oc} utiliza la relación lineal para calcular el punto de máxima potencia (MPP), que es un parámetro importante en la caracterización y optimización de sistemas fotovoltaicos.

Desventajas del algoritmo V_{oc} :

- Interrupciones en el proceso: Para realizar mediciones de tensión en diferentes condiciones y de tiempo, es necesario interrumpir el proceso del algoritmo. Esto puede resultar en pérdida de energía y afectar la eficiencia del sistema fotovoltaico.
- Limitaciones en casos de sombreado parcial: El algoritmo V_{oc} puede no ser muy preciso cuando se enfrenta a sombreado parcial, donde ciertas partes del módulo fotovoltaico reciben menos radiación solar. En estas situaciones, la relación lineal entre la tensión en circuito abierto y la tensión máxima de potencia puede no ser válida debido a la presencia de sombras.
- Dependencia de la constante de proporcionalidad: El algoritmo V_{oc} depende de la determinación precisa de la constante de proporcionalidad (k_{oc}) entre la tensión en circuito abierto y la tensión máxima de potencia. Si esta constante no se calcula correctamente o no se tiene en cuenta la variabilidad debido a diferentes condiciones, los resultados pueden no ser precisos.

2.5.4. Conductancia incremental (IncCond)

La técnica IncCond se utiliza ampliamente por su gran precisión de seguimiento en estado estacionario y su buena adaptabilidad a los cambios rápidos de las condiciones meteorológicas. El método toma en cuenta la siguiente aseveración que la derivada de la potencia de salida del sistema con respecto a la tensión es igual a cero:

$$\frac{dP_{pv}}{dV_{pv}} = 0 \quad (17)$$

De esta forma la tensión del sistema puede ser regulada a la tensión del punto máximo de potencia midiendo la conductancia incremental $\frac{dI}{dV}$ y la conductancia $\frac{I}{V}$.

Entonces:

$$\frac{dP_{pv}}{dV_{pv}} = \frac{d(I_{pv} * V_{pv})}{dV_{pv}} = I_{pv} + \left[\frac{dI_{pv}}{dV_{pv}} \right] V_{pv} \quad (18)$$

$$\frac{d(I_{pv})}{dV_{pv}} = -\frac{I_{pv}}{V_{pv}} \quad (19)$$

A partir de la ecuación 19 deducimos que cuanto más lejos se está del punto de máxima potencia, mayor es $\frac{dP_{pv}}{dV_{pv}}$, lo cual ocasiona un cambio en el ciclo de trabajo ya que el sistema busca ajustar la tensión del módulo para que opere en $\frac{dP_{pv}}{dV_{pv}} = 0$. La Figura 9 ilustra el diagrama de flujo del algoritmo IncCond [20, 21].

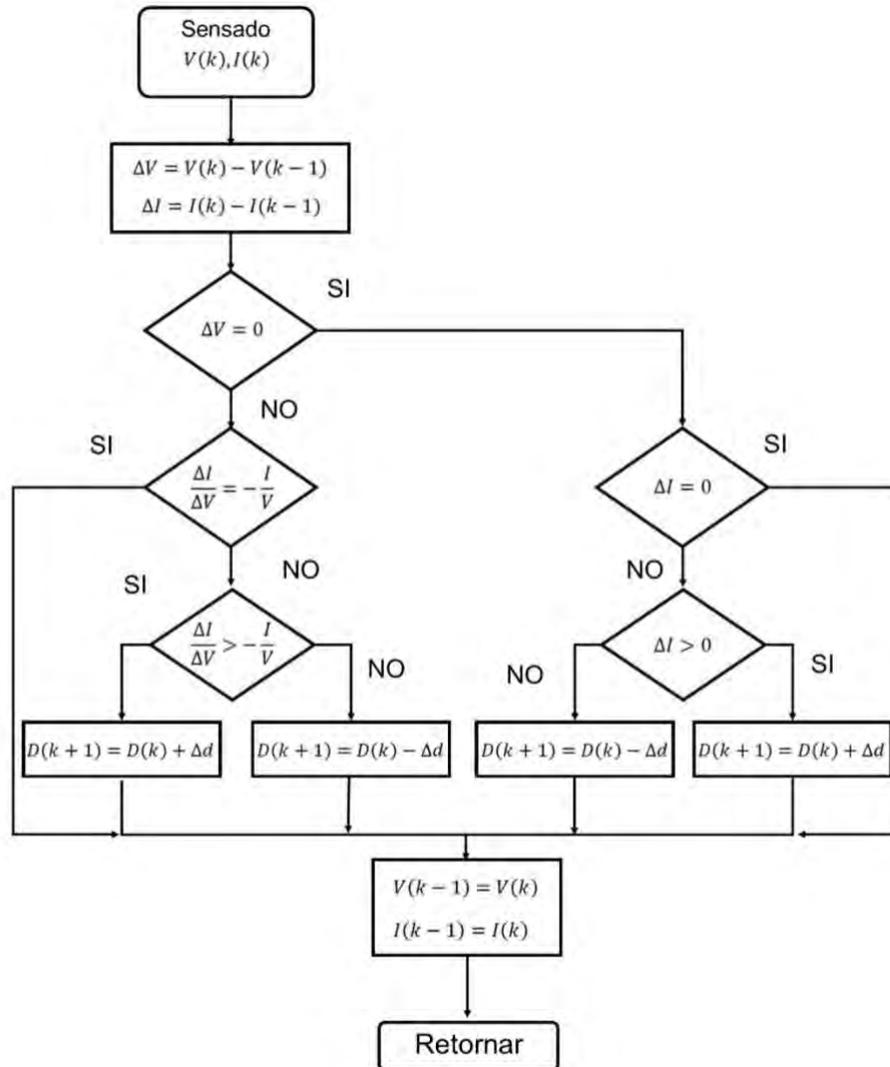


Figura 9. Diagrama de flujo del algoritmo conductancia incremental IncCond.

Ventajas:

- Reduce al mínimo la oscilación alrededor del punto máximo de potencia.
- Extrae un porcentaje mayor de potencia en comparación con el algoritmo P&O.

Desventaja:

- Complejidad al momento de diseñar el controlador.

2.5.5. Controlador Difuso (FLC)

La FLC (Fuzzy Logic Control, por sus siglas en inglés) es una estrategia de inteligencia artificial, emplea la lógica heurística para abordar problemas complejos. Gracias a su sencillez y efectividad, se ha vuelto ampliamente utilizado en el control de sistemas lineales y no lineales. Con el paso del tiempo, este enfoque ha demostrado notables cualidades en el diseño de controladores MPPT altamente eficientes, sin la necesidad de contar con un modelo matemático específico del sistema fotovoltaico. El controlador difuso es un sistema interpretativo. Los elementos se relacionan con conjuntos que no son nítidamente definidos, de esta manera se otorga un grado de pertenencia relativa y no estricta como en la lógica tradicional. Pretende emular la capacidad de razonamiento humano en función de conceptos ambiguos “variables lingüísticas” [17, 22, 23].

Consta de 3 etapas:

- I. Borrosificación: Se asignan variables de entrada para el controlador, estas variables sufren una traducción por términos interpretados por lógica difusa, después de la traducción le asociamos distintos grados de pertenencia a los conjuntos difusos, constituyendo así las funciones de membresía.
- II. Inferencia: Establecidas las funciones de membresía se relacionarán entre ellas mediante un conjunto de reglas, las cuales una vez aplicadas producirán una salida interpretable en el sistema difuso.
- III. Desborrosificación: La salida obtenida en el proceso II será traducida a valores interpretables por el equipo físico utilizado para el control. Uno de los métodos más utilizados en esta etapa es del “centroide”.

En la Figura 10, se presenta el diagrama a bloques del algoritmo FLC.

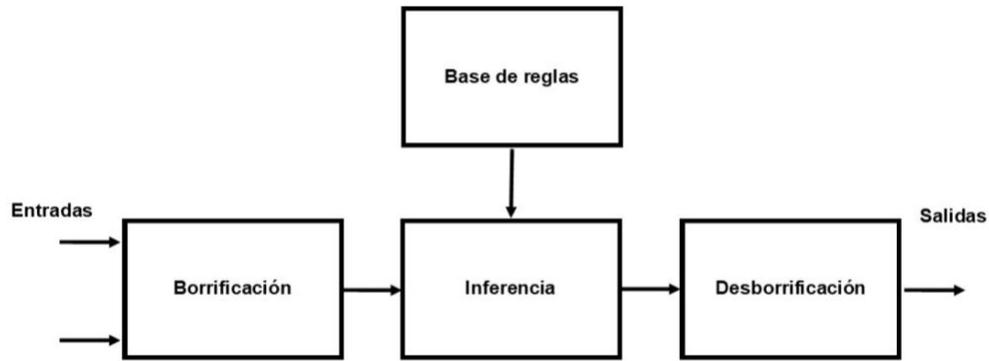


Figura 10. Diagrama de bloques del algoritmo FLC.

Ventajas que ofrece el método:

- Respuesta rápida y estabilidad ante cambios bruscos en las condiciones ambientales.
- Es de fácil comprensión. Los conceptos que involucran este método son de fácil comprensión.
- Es flexible y de fácil reestructuración.
- Es tolerante a datos imprecisos.
- Puede ser combinada con técnicas convencionales de control.

2.5.6. Redes Neuronales Artificiales (RNA)

Los RNA se definen como sistemas de mapeo no lineal que se basan en principios observados en los sistemas nerviosos de humanos y animales. Estos sistemas constan de numerosos procesadores simples interconectados mediante conexiones ponderadas. Las unidades de procesamiento, conocidas como neuronas, reciben entradas de otros nodos y generan una salida escalar simple que depende de la información local disponible, almacenada internamente o recibida a través de las conexiones ponderadas. A través de estas conexiones, se pueden realizar diversas funciones complejas [24, 25]. En numerosas redes, las unidades de procesamiento exhiben una respuesta con la siguiente forma:

$$y = f\left(\sum_k \omega_k x_k\right) \quad (20)$$

Donde:

x_k : Señales de salida de otros nodos o entradas externas.

ω_k : Pesos de las ligas de conexión.

$f(\cdot)$: Función no lineal simple / Función de activación.

La función $f(\cdot)$ puede adoptar diferentes formas, como tangente hiperbólica, sigmoideal, escalón, lineal, lineal con saturación, logística, entre otras. Cada unidad de procesamiento tiene una tarea básica: recibir entradas de otras unidades o fuentes externas y procesar la información para generar una salida que se envía a otras unidades. Aunque la estructura de una red neuronal puede ser variada las capas que contienen estas estructuras se definen en función de su posición en la topología de la red. Las entradas externas se aplican en la primera capa, mientras que las salidas se consideran la última capa. Las capas internas que no se ven como entradas o salidas se conocen como capas ocultas. En general, las entradas no se consideran una capa debido a que no realizan ningún procesamiento [24, 25].

La suma ponderada de las entradas conectadas, junto con un bias θ , representa la entrada total u de una unidad k :

$$u(t) = \sum_j \omega_j x_j + \theta \quad (21)$$

Si el valor del peso ω_j es positivo, se interpreta como una señal de excitación, mientras que, si el peso es negativo, se entiende como una señal de inhibición de la entrada. Cuando consideramos las entradas como funciones del tiempo, la expresión previa se transforma en:

$$u(t) = \sum_j \omega_j(t) x_j(t) + \theta(t) \quad (22)$$

En la Figura 11, se muestra el esquema de una red de entrada única, y en la expresión 23 el modelo matemático de la misma.

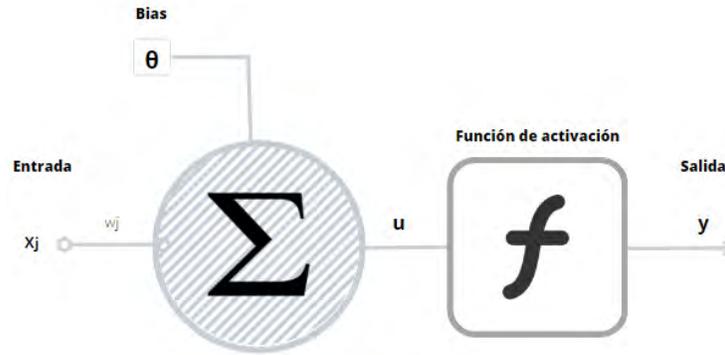


Figura 11. Esquema básico de una red neuronal artificial (RNA).

$$y = f\left(\sum_j \omega_j x_j + \theta\right) \quad (23)$$

2.5.6.1. Funciones de activación

Las neuronas cuentan con una función de transición o activación que les permite ajustar su nivel de activación en función de las señales que reciben. Estas señales pueden provenir tanto del entorno externo como de otras neuronas a las que están conectadas. El nivel de activación de una neurona se determina en base a las entradas recibidas y los valores sinápticos, sin considerar los valores anteriores de los estados de activación. La regla que logra establecer el efecto de la entrada total $u(t)$ en la activación de la unidad k esta dado por:

$$y(t + 1) = F_k(y(t), u(t)) \quad (24)$$

En numerosas situaciones, esta función presenta una relación no decreciente en relación con la entrada total de la unidad:

$$y(t + 1) = F_k \left[\sum_j \omega_j(t) x_j(t) + \theta(t) \right] \quad (25)$$

2.5.6.1.1. Función de activación escalón

La función de escalón, también llamada función umbral, limitador estricto o función de Heaviside en honor al matemático inglés, fue la primera función no lineal utilizada para modelar neuronas artificiales. Se empleó para analizar las comunicaciones telegráficas. La función de activación escalón se utiliza en neuronas binarias, en las cuales la activación es 1 cuando la suma de las entradas es igual o mayor que el umbral de la

neurona, y es 0 cuando es menor, en la Figura 12, se presenta de manera gráfica la función escalón.

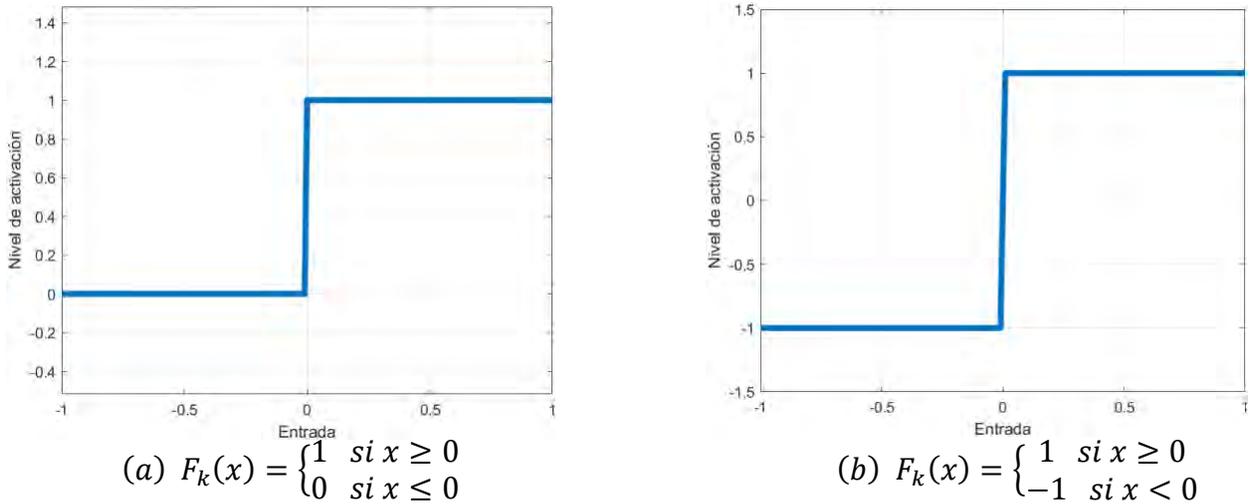
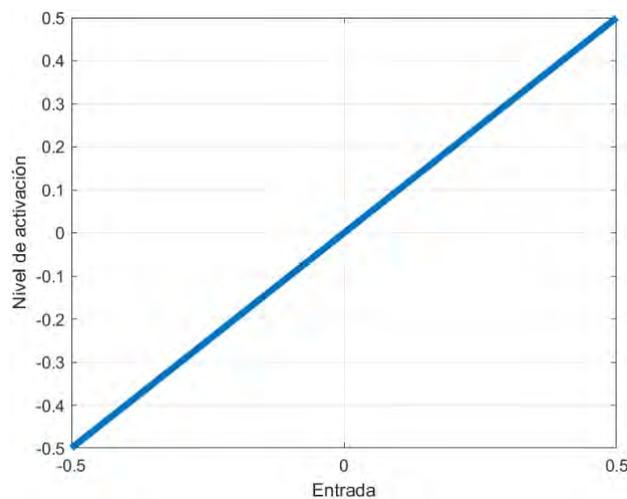


Figura 12. (a) función de activación escalón, (b) función de activación escalón simétrica o bipolar.

2.5.6.1.2. Función de activación lineal

La función lineal o identidad se representa por la expresión $F_k(u) = u$. En las neuronas con función mixta, si la suma de las señales de entrada es menor que un límite inferior, la función se define como 0. Si la suma es mayor o igual al límite superior, la activación es 1. Si la suma de entrada se encuentra entre los dos límites, la activación es una función lineal de la suma de las señales de entrada [25]. en la Figura 13, se presenta de manera gráfica la función lineal.

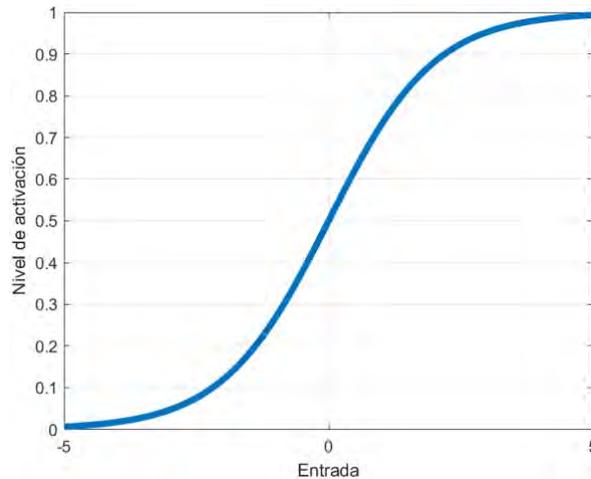


$$F_k(x) = x$$

Figura 13. Función de activación lineal.

2.5.6.1.3. Función de activación sigmoideal

La función sigmoideal produce valores cercanos a los límites asintóticos. Esto implica que, en la mayoría de los casos, la salida estará en la región alta o baja de la curva sigmoide. En situaciones en las que la pendiente es alta, la función tiende a comportarse como una función escalón. Sin embargo, la importancia de la función sigmoideal radica en que su derivada es siempre positiva y cercana a cero para valores grandes positivos o negativos, alcanzando su máximo valor cuando x se aproxima a cero. Generalmente, es deseable que la función de activación de una neurona sea no lineal, creciente, continua y derivable. Las funciones sigmoideas cumplen con todos estos requisitos, lo que las convierte en una opción particularmente útil en redes neuronales entrenadas con *backpropagation*, en la Figura 14, se muestra de manera grafica la función de activación sigmoide [25].

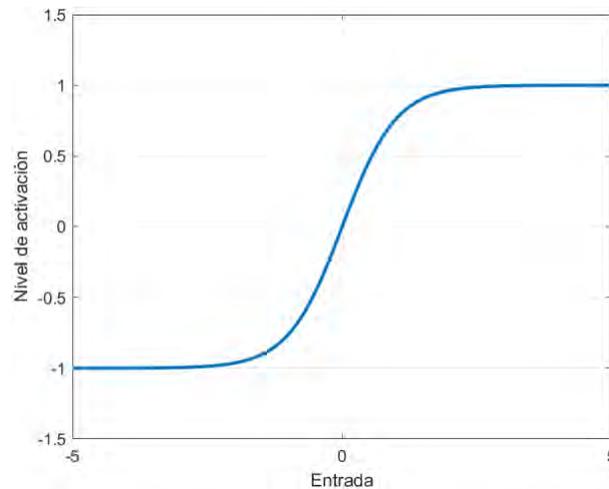


$$F_k(u) = \frac{1}{1 + e^{-u}}$$

Figura 14. Función de activación sigmoide.

2.5.6.1.4. Función de activación tangente hiperbólica

La función tangente hiperbólica se utiliza en casos con cambios suaves entre valores positivos y negativos de la señal a clasificar. Es una de las funciones más comunes en entrenamientos supervisados, como el de retropropagación del error. Es importante tener precaución al usar esta función dentro del rango entre los umbrales positivos y negativos antes de la saturación, ya que, de lo contrario, la salida siempre será saturada con valores de 1 y -1, en la Figura 15, se muestra la gráfica de la función tangente hiperbólica [26, 27]:



$$F_k(u) = \frac{e^u - e^{-u}}{e^u + e^{-u}}$$

Figura 15. Función de activación tangente hiperbólica.

2.5.6.2. Arquitectura de la red neuronal artificial (RNA)

El modelo de red neuronal de unidad básica puede combinarse con más esquemas que cumplan con la misma configuración, a continuación, se presentan algunas arquitecturas.

2.5.6.2.1. Red neuronal feed-forward

La mayoría de las herramientas comerciales que usan redes neuronales optan por sistemas de varias capas. Comúnmente, las neuronas dentro de una capa actúan de manera autónoma y simultánea, lo que simplifica su uso. Las capas están interconectadas de modo que la capa i pasa información a la capa $i + 1$. A estas se les llama redes neuronales progresivas, ya que no poseen retroalimentación. En contraste, las que sí tienen este sistema de retroalimentación se llaman redes recurrentes. En una red feed-forward podemos encontrar varias configuraciones según sea su aplicación [26, 27].

2.5.6.2.1.1. Redes neuronales de una sola capa oculta (redes simples)

Es el modelo básico de red neuronal. Las neuronas iniciales simplemente captan señales externas y las reenvían a las neuronas finales, las únicas que procesan la información. Por lo tanto, a pesar de tener aparentemente dos niveles, se ven como una red de una sola capa [26]. En la figura 16, se muestra el esquema de esta configuración.

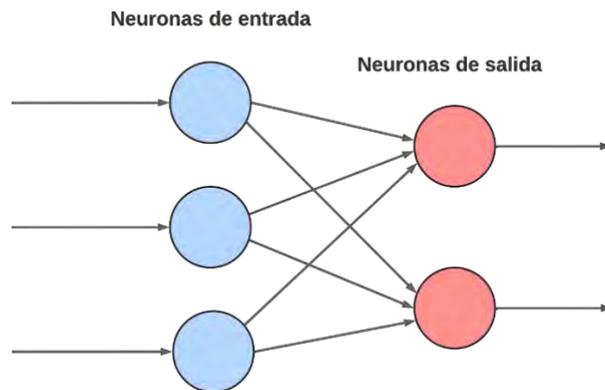


Figura 16. Esquema de una red neuronal feed-forward simple.

2.5.6.2.1.2. Redes neuronales multicapa

En una red neuronal básica, se pueden observar directamente las capas inicial y final. Sin embargo, al incorporar capas adicionales entre ellas, estas ya no se pueden ver desde fuera, necesitando métodos como backpropagation para modificar sus características internas [26]. En la Figura 17, se muestra el esquema de esta configuración.

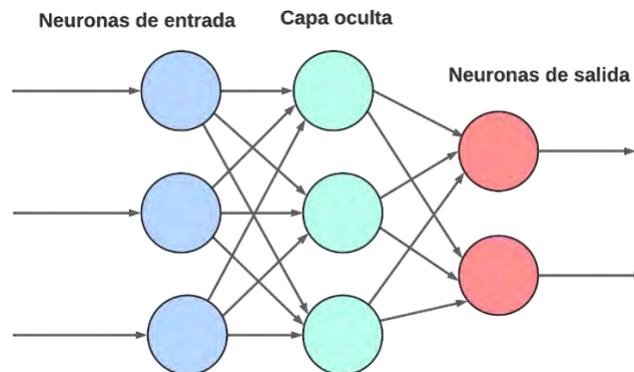


Figura 17. Esquema de una red feed-forward multicapa con una única capa oculta.

2.5.6.2.2. Redes recurrentes

Las redes recurrentes pueden tener enlaces unidireccionales o bidireccionales. Cuando son bidireccionales, estas redes pueden llenar huecos en patrones que se presentan de manera incompleta o que tienen interferencias. Un modelo popular que utiliza conexiones bidireccionales es la red de Hopfield [26]. En la Figura 18, se muestra el esquema de una red recurrente con conexiones bidireccionales.

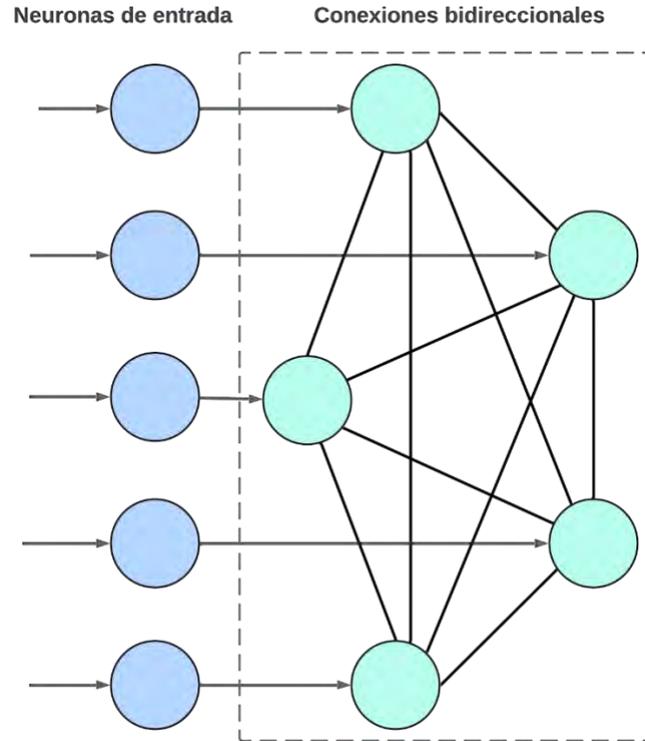


Figura 18. Red neuronal recurrente con conexiones bidireccionales. John J. Hopfield. *Neural networks and physical systems with emergent collective computational abilities. Proceedings of the National Academy of Sciences*, 79(8):2554–2558, 1982. URL <http://www.pnas.org/content/79/8/2554>

2.5.6.3. Entrenamiento de redes

Al proceso por el cual se ajustan los parámetros de la red neuronal (pesos y sesgos) se le denomina "entrenamiento". El entrenamiento permite que la red realice una tarea específica de la mejor manera posible. Estas tareas pueden ser variadas; entre ellas encontramos la clasificación de imágenes, la predicción de una secuencia de tiempo, o cualquier otro tipo de aprendizaje automático. En la mayoría de las redes, el proceso de entrenamiento sigue una secuencia determinada. En la Figura 19, se muestra un esquema lógico sobre el proceso de entrenamiento [28].

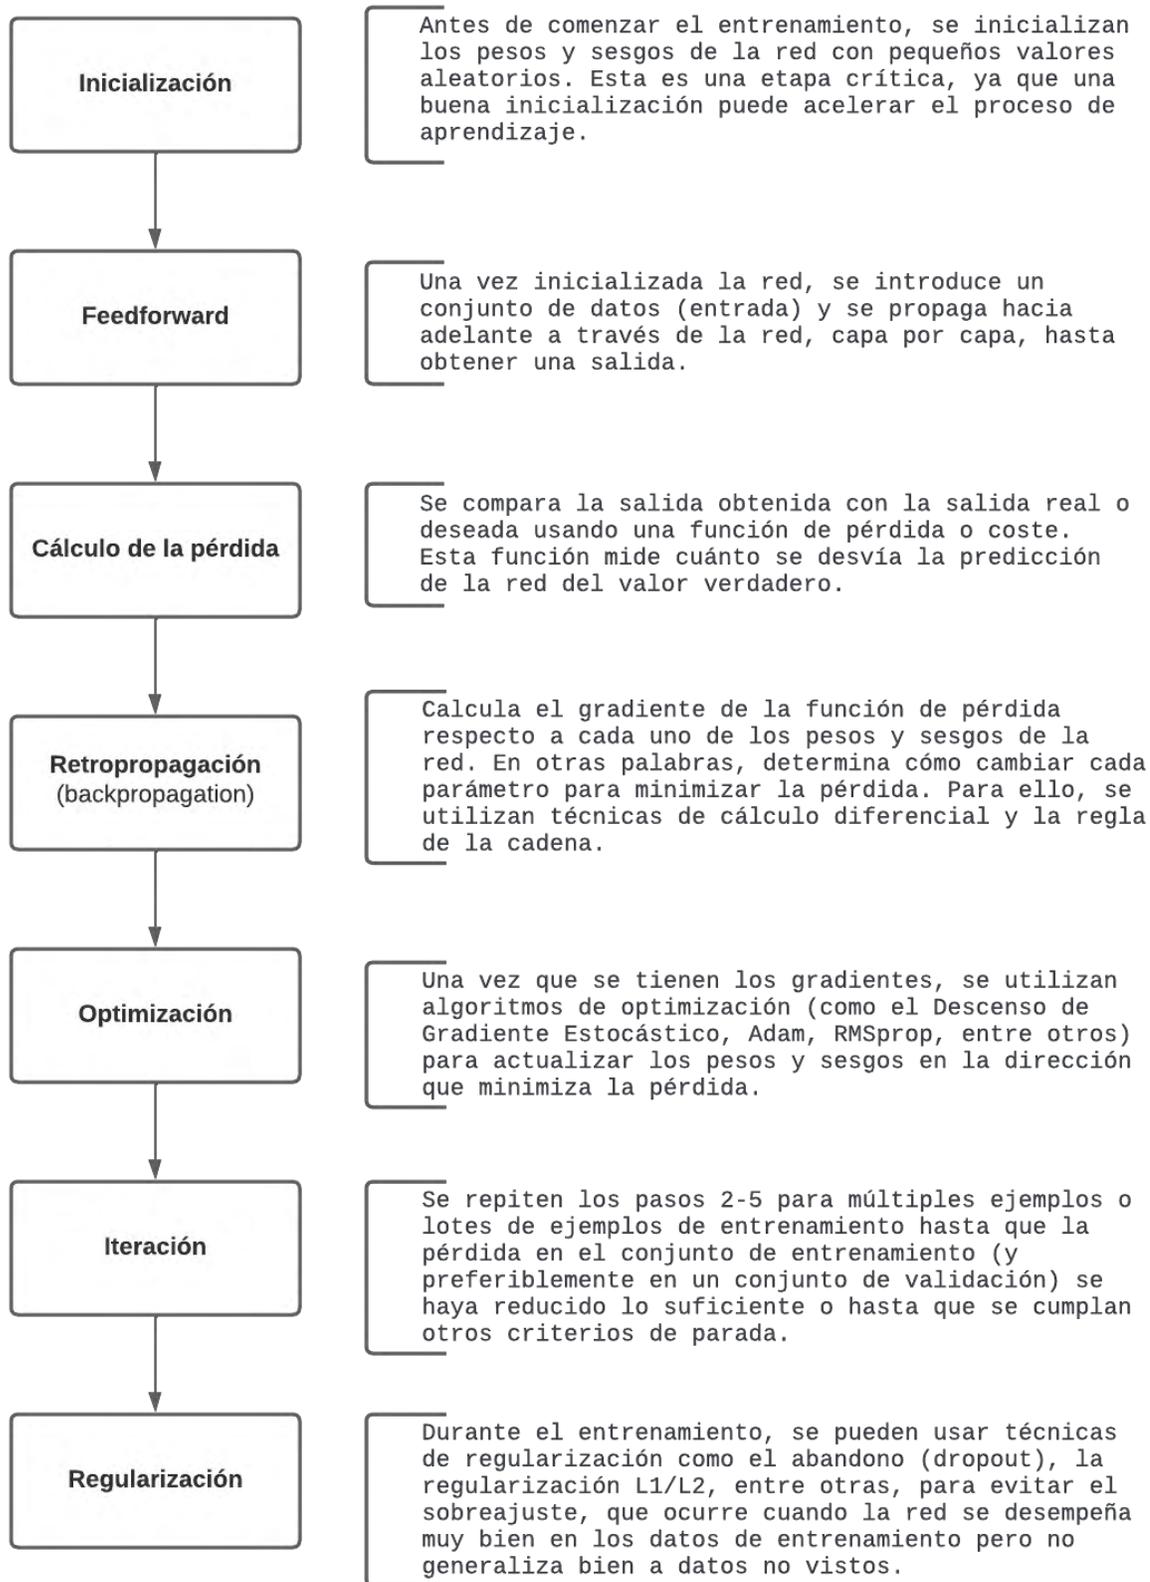


Figura 19. Proceso de entrenamiento de una red neuronal artificial [28].

2.5.6.3.1. Retro-propagación (*Backpropagation*)

El algoritmo de retropropagación fue introducido por Paul Werbos en 1974 durante su investigación doctoral y más tarde ganó reconocimiento gracias a David Rumelhart en 1986 [29]. El algoritmo funciona tomando una entrada y utilizando pesos aleatorios iniciales, se propaga a través de las capas hasta generar una salida. Esta salida se coteja con el resultado deseado, resultando en un error. Luego, este error se retropropaga a través de las capas anteriores, ajustándolas para mejorar la predicción. Este ciclo continúa iterativamente para cada conjunto de entrada-salida hasta alcanzar un nivel de error tolerable [29].

El algoritmo de retropropagación calcula el gradiente de un escalar z en un gráfico computacional. Comienza con el gradiente inmediato $\frac{dz}{dz} = 1$. Luego, calcula el gradiente para cada "padre" de z multiplicando el gradiente actual por el Jacobiano de la operación que produjo z . Cuando un nodo en el gráfico puede ser alcanzado por múltiples rutas, se suman los gradientes de estas diferentes rutas [28].

Cada nodo en el gráfico representa una variable tensorial. Cada variable tiene subrutinas asociadas que ofrecen:

- La operación que computa la variable.
- Una lista de variables que son "hijos" de la variable en el gráfico.
- Una lista de variables que son "padres" de la variable en el gráfico.

Cada operación tiene una operación de retropropagación correspondiente que calcula un producto Jacobiano-vector. Cada operación sabe cómo retropropagar a través de sus aristas en el gráfico. El algoritmo de retropropagación no necesita conocer las reglas de diferenciación por sí mismo; simplemente llama a los métodos de retropropagación de cada operación con los argumentos correctos [28].

Las implementaciones de software de la retropropagación ofrecen tanto operaciones como sus métodos de retropropagación, lo que permite a las bibliotecas de aprendizaje profundo retropropagar a través de operaciones comunes como multiplicación de matrices, exponentes y logaritmos [28].

2.5.6.3.1.1. Algoritmos para el entrenamiento

En el entrenamiento de redes neuronales usando retropropagación, existen algoritmos clave como el gradiente descendente, que busca reducir el error al moverse en sentido opuesto al gradiente. Por otro lado, el gradiente conjugado optimiza el error no solo en la dirección tradicional del gradiente, sino también en una conjugada, ofreciendo una convergencia acelerada. Además, el método Levenberg-Marquardt fusiona el enfoque del gradiente descendente con el método de Newton generalizado de segundo orden, aprovechando las derivadas de segundo nivel para afinar la minimización del error [29].

Ventajas de las RNA:

- Presentan un gran número de características semejantes a las del cerebro (Aprendizaje, generación de experiencia, generalización de casos anteriores y nuevos, separación de características esenciales, etc.).
- Tienen mayor versatilidad, no dependen del cumplimiento de los supuestos teóricos sobre los que se basan las técnicas estadísticas.
- Tienen la habilidad de extraer relaciones complejas no lineales de un conjunto de datos sin disponer previamente de conocimiento alguno del sistema o de un modelo teórico.
- Admiten como variables de entrada conjuntos mixtos de variables cuantitativas y cualitativas.

2.5.7. Algoritmos de optimización

Los algoritmos de optimización son técnicas computacionales que buscan encontrar la solución óptima a un problema de optimización. En general, un problema de optimización consiste en encontrar la mejor solución posible para un conjunto de variables, sujetas a ciertas restricciones. Estas variables pueden ser continuas, discretas o combinatorias. Pueden ser utilizados en una amplia variedad de campos, desde la optimización de procesos industriales hasta la optimización de sistemas de energía renovable [19, 30, 31].

Ventajas de los algoritmos de optimización:

- Flexibilidad: Los algoritmos de optimización son más flexibles que el seguimiento del punto de máxima potencia, ya que pueden adaptarse a diferentes condiciones ambientales y de carga.
- Eficiencia: Los algoritmos de optimización pueden lograr una eficiencia más alta que el seguimiento del punto de máxima potencia en condiciones variables, lo que significa que el sistema de energía renovable puede utilizar de manera más efectiva la energía disponible.
- Mayor precisión: Los algoritmos de optimización pueden ser más precisos en la determinación del punto de operación óptimo del sistema de energía renovable.

Desventajas de los algoritmos de optimización:

- Complejidad: Los algoritmos de optimización pueden ser más complejos que el seguimiento del punto de máxima potencia, lo que puede requerir más recursos y tiempo de procesamiento.
- Costo: Los algoritmos de optimización pueden ser más costosos que el seguimiento del punto de máxima potencia debido a la necesidad de hardware y software especializados.

CAPÍTULO 3.

ESTADO DEL ARTE

3.1. Algoritmos de seguimiento del punto de máxima potencia en línea

Los algoritmos de seguimiento de máxima potencia se clasifican en tres vertientes importantes. Los algoritmos más utilizados por su bajo costo de implementación son las técnicas en línea, en las que se destacan el algoritmo perturbar y observar (P&O), y conductancia incremental (IncCond). Ambos algoritmos reportan eficiencias que rondan el 93% al 98%, sin embargo, el algoritmo de conductancia incremental presenta mejores resultados, además de que reduce significativamente las oscilaciones en estado estacionario en comparación con el algoritmo perturbar y observar (P&O). Al presentarse cambios bruscos en la irradiancia o temperatura el algoritmo de conductancia incremental (IncCond) muestra un mejor rendimiento dinámico debido al tiempo de convergencia casi instantáneo y una reducción notable en las oscilaciones, en la Tabla 1, se muestra una comparación en términos de eficiencia y comportamiento dinámico de los algoritmos en línea [11, 20, 32-41].

Tabla 1. Comparación dinámica de los algoritmos en línea.

Artículo	Convertidor	Algoritmo	Variables de entrada	Variable de salida	Arreglo	Potencia (W)	Eficiencia (%)	Tiempo de estabilización (s)
[11]	Bidireccional (Buck +Boost)	P&O	Voltaje, corriente	d	SFA Serie	1000	97.19	1.1
[20]	Boost	IncCond	Voltaje, corriente	d	Modular	245	96.60	0.15
		P&O	Voltaje, corriente	d			96.10	0.2
[32]	Cuk	IncCond	Voltaje, corriente	d	Modular	87	-	0.2
[33]	Boost	IncCond	Voltaje, corriente	d	Modular	20	-	-
[34]	Buck-Boost	P&O	Voltaje, corriente	d	Modular	87	93.23	0.081
		IncCond					93.37	0.081
	SEPIC	P&O					93.64	0.108
		IncCond					94.30	0.288
	Cuk	P&O					94.36	0.084
		IncCond					94.52	0.089
	Zeta	P&O					94.16	0.08
		IncCond					94.36	0.08

[35]	Boost	P&O Modificado	Voltaje, corriente	d	Modular	60	98.30	0.0125
[36]	Boost	P&O Modificado	Voltaje, corriente	d	SFA Serie	-	97.20	0.12
[37]	Boost	P&O IncCond	Voltaje, corriente	d	Modular	220	97.37 97.28	-
[38]	Buck	P&O	Voltaje, corriente	d	Modular	600	95	-
[39]	Boost	P&O IncCond	Voltaje, corriente	d	Modular	60	-	0.3
							-	0.2
[40]	Cuk	Voltaje fraccional (fvoc)	Voltaje, corriente	d	SFA Serie	100	79	0.65
[41]	Boost	P&O	Voltaje, corriente	d	Modular	50	95	0.5

3.2. Algoritmos de seguimiento de máxima potencia fuera de línea

Como segunda vertiente se tienen los algoritmos fuera de línea en los cuales destacan los algoritmos de optimización, redes neuronales artificiales, y lógica difusa, estos algoritmos reducen de forma significativa las oscilaciones en estado estacionario, y reportan eficiencias que rondan el 97.5% y el 99.69% siendo los algoritmos de optimización los que reportan los mayores porcentajes de eficiencia. Entre los algoritmos de optimización que más figuran para el seguimiento del punto de máxima potencia tenemos: algoritmo de optimización de la rémora (ROA) con una eficiencia del 99.68%; el método de optimización de forrajeo de la mantarraya (MRFO) con una eficiencia del 99.54%; y la optimización de enjambre de partículas (PSO) con una eficiencia 98.83% [42-47]. En el caso del algoritmo de lógica difusa, reporta eficiencias que rondan entre 97% y el 99% Para los algoritmos basados en redes neuronales las eficiencias rondan entre el 97% al 99.66%, la red neuronal bayesiana presenta una eficiencia del 99.51%. La red neuronal DS-ANN puede usarse para cualquier célula policristalina sin necesidad de reentrenar a la red, reporta una eficiencia del 99.66%, sin embargo, hay otras configuraciones que tienen mejores eficiencias, con mayores capas ocultas con una eficiencia reportada del 99.90%, en la Tabla 2, se muestra una comparación dinámica de los algoritmos fuera de línea [27, 29, 48-53].

Tabla 2. Comparación dinámica de los algoritmos fuera de línea.

Artículo	Convertidor	Algoritmo	Variables de entrada	Variable de salida	Arreglo	Potencia (W)	Eficiencia (%)	Tiempo de estabilización (s)
[13]	Boost	DS-ANN	Hoja de datos del panel	Voltaje	Modular	150	99.66	-
[27]	Boost	RNA Q-Network	Voltaje, corriente	d	Arreglo 3X2	15	-	-
[29]	-	RNA	Temperatura, irradiancia	Voltaje, corriente	Modular	5	98.50	-
[37]	Boost	FLC	Voltaje, corriente	d	Modular	213.15	77.60	0.15
		RNA	Temperatura, irradiancia	Voltaje			97.79	0.1
		SMC	Voltaje, corriente	d			97.52	0.1
[42]	Boost	ROA	Voltaje, corriente	d	Arreglo 3x2	90	99.68	0.88
		MRFO					99.54	1.85
		PSO					98.83	2.96
[44]	Boost	RNA	Voltaje	d	Modular	250	97.51	0.2
		PSO					97.93	0.25
[45]	Boost	PSO	Voltaje, corriente	d	Serie	1K	-	0.048
[46]	Cuk	PSO	Voltaje, corriente	d	Serie	150	-	-
[47]	Split-pi	PSO	Voltaje, corriente	d	Modular	25	-	0.15
[48]	Boost	Rprop-NN	Irradiancia, temperatura	d	Modular	115.5	-	0.1
[49]	Boost	RNA	Voltaje, corriente	d	Serie	305	94.74	-
			Voltaje, corriente, temperatura				94.96	-
			Voltaje, irradiancia				100	-
			Voltaje, corriente, irradiancia, temperatura				98.43	-
[50]	-	RNA	Irradiancia, temperatura	d	Serie	648.6	91.03	0.108
		Bayesiana - RNA					99.51	0.087
		PSO					98.78	0.213

[51]	-	RNA	Temperatura, irradiancia	Voltaje	Arreglo 3x3	266.6	98.14	-
[52]	Boost	RNA	Temperatura, irradiancia	d	Modular	3.75K	-	-
[53]	Boost	RNA	Corriente, temperatura	Voltaje	Serie	120	95.00	-

3.3. Algoritmos de seguimiento de máxima potencia híbridos

En la tercer vertiente se encuentran los algoritmos híbridos, que son la combinación entre los algoritmos en línea y fuera de línea, sin embargo, esto también puede presentarse entre la combinación de una sola vertiente, por ejemplo, el algoritmo de optimización de enjambre de partículas (PSO) fusionado con el algoritmo de optimización de salpas (SSO) que en su conjunto llamamos SSO-PSO la cual reporta una eficiencia del 99.91 %, este algoritmo presenta características que supera a las técnicas convencionales, ya que elimina las oscilaciones en estado estacionario, y tiene un corto tiempo de asentamiento con un menor sobre impulso, además maximiza la potencia en estado transitorio. El algoritmo PSO-SS utiliza las ventajas de PSO y espacio de búsqueda para converger bajo el efecto estocástico de la radiación solar y la temperatura. Se ha observado una notable disminución de la velocidad de procesamiento con un mayor rendimiento tanto en simulación como en hardware. La eficiencia reportada del PSO-SS es del 99.23%. El algoritmo HHO-P&O es la combinación de las técnicas clásicas de computación llamadas Harris Hawk Optimization (HHO) y el algoritmo perturbar y observar (P&O), este algoritmo fusiona las cualidades de consistencia y rapidez que destacan de ambos algoritmos, el algoritmo presenta una eficiencia del 99.50%, no obstante, presenta un mejor comportamiento ante sombreado parcial complejo en comparación con técnicas convencionales de seguimiento, esto lo hace versátil en presencia de condiciones meteorológicas cambiantes. El algoritmo ANN- ACO que es una red neuronal artificial optimizada meta heurísticamente es entrenada por medio del algoritmo de optimización de colonias de hormigas (ACO), este algoritmo presenta una velocidad de asentamiento mayor y una oscilación mínima en estado estacionario en comparación a los algoritmos convencionales de seguimiento, este algoritmo muestra una eficiencia del 99.20% [54-59]. En la Tabla 3, se muestra una comparación dinámica de los algoritmos híbridos.

Tabla 3. Comparación dinámica de los algoritmos híbridos.

Artículo	Convertidor	Algoritmo	Variables de entrada	Variable de salida	Arreglo	Potencia (W)	Eficiencia (%)	Tiempo de estabilización (s)
[54]	-	PSO-SS	Voltaje, corriente	d	Arreglo 2X3	300	99.23	0.05
		Fuzzy-P&O					96.07	0.08
		P&O-PSO					92.34	0.067
		P&O-PSO-SS					94.67	0.057
[55]	Cuk	HHO-P&O	Voltaje, corriente	d	Serie	1259	99.50	0.25
[56]	-	P&O - RNA	Voltaje, corriente	d	Modular	180	-	-
[57]	Boost	PSO-ANN	Voltaje, corriente	d	Modular	305	95.70	0.26
		ACO-ANN					99.20	0.18
[58]	Boost	GA-FLC	Irradiancia, temperatura	d	Serie	1000.7	-	0.0193
		PSO-FLC					-	0.0193
		GA-ANN					-	0.0169
		GA-FLC-ANN					-	0.0168
[59]	Boost	ANN-P&O	Irradiancia, temperatura, corriente	Voltaje	Arreglo 2X4	550	97.75	0.305
		ANN-IC					97.85	0.302
		ANN-HC					98	0.3
		RBFC-Fuzzy					98	0.252

El desarrollo de algoritmos para el seguimiento del punto de máxima potencia es clave para optimizar los procesos de generación de energía fotovoltaica, si bien tenemos excelentes rendimientos en los algoritmos fuera de línea, los algoritmos híbridos contemplan escenarios más complejos, y por eso que ahora se están enfocando en desarrollar algoritmos que fusionen sus características y resuelvan necesidades que los algoritmos convencionales no resuelven. En la figura 20, se presenta la eficiencia promedio de los diferentes algoritmos de seguimiento.

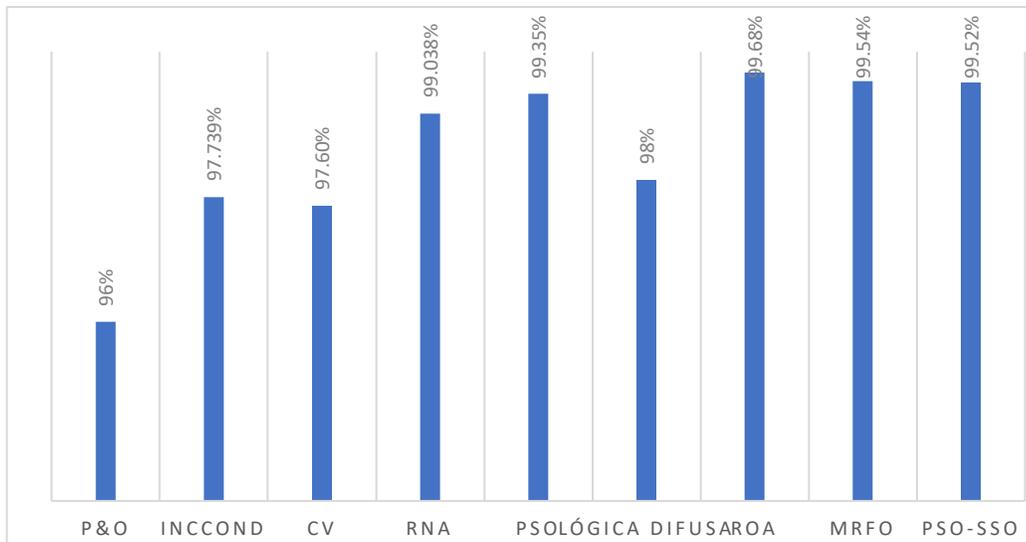


Figura 20. Desempeño de los diferentes algoritmos para el seguimiento del punto de máxima potencia.

En conclusión, los algoritmos convencionales siguen siendo útiles por su sencillez y bajo coste, los algoritmos fuera de línea y, en particular, los híbridos, están allanando el camino hacia un aprovechamiento más eficiente y adaptable de la energía solar, abordando las complejidades y dinámicas de las condiciones ambientales. Los desarrollos futuros se centran en la fusión de las características de estos algoritmos para resolver problemas que los enfoques tradicionales no pueden, optimizando aún más los sistemas de energía fotovoltaica.

CAPÍTULO 4.

METODOLOGÍA

4.1. Simulación del módulo fotovoltaico EPCOM – EPL32024 en SIMULINK

Las características eléctricas del panel EPL32024 se presentan en la Tabla 4, estos datos se extrajeron de la hoja de datos que el fabricante entrega al momento de adquirir el panel. Dentro de la máscara del PV-Array en SIMULINK, que es un modelo utilizado para simular el comportamiento de arreglos fotovoltaicos, se introdujeron los datos que se presentan en la Tabla 4.

Tabla 4. Características eléctricas del panel EPL32024.

Módulo EPL32024	
Potencia máxima - P_{mp}	320 W
Voltaje de máxima potencia - V_{mp}	37.42 V
Corriente de máxima potencia - I_{mp}	8.55 A
Voltaje de circuito abierto - V_{oc}	46.35 V
Corriente de corto circuito - I_{sc}	9.07 A
Coefficiente de temperatura Pmax	-0.41%/°C
Coefficiente de temperatura Voc	-0.31%/°C
Coefficiente de temperatura Isc	0.06%/°C

En la Figura 21, se observan las curvas características de voltaje-potencia y voltaje-corriente del panel EPL32024 que mostró PV-Array de SIMULINK. Las curvas características generadas en SIMULINK para el panel EPL32024 muestran una alta concordancia con las curvas proporcionadas en la hoja de datos del fabricante. Esta similitud confirma la precisión del modelo en SIMULINK, indicando que las simulaciones reflejan de manera fiable el comportamiento real del panel bajo diversas condiciones operativas. En el anexo A, se presenta la hoja de datos del panel EPL32024.

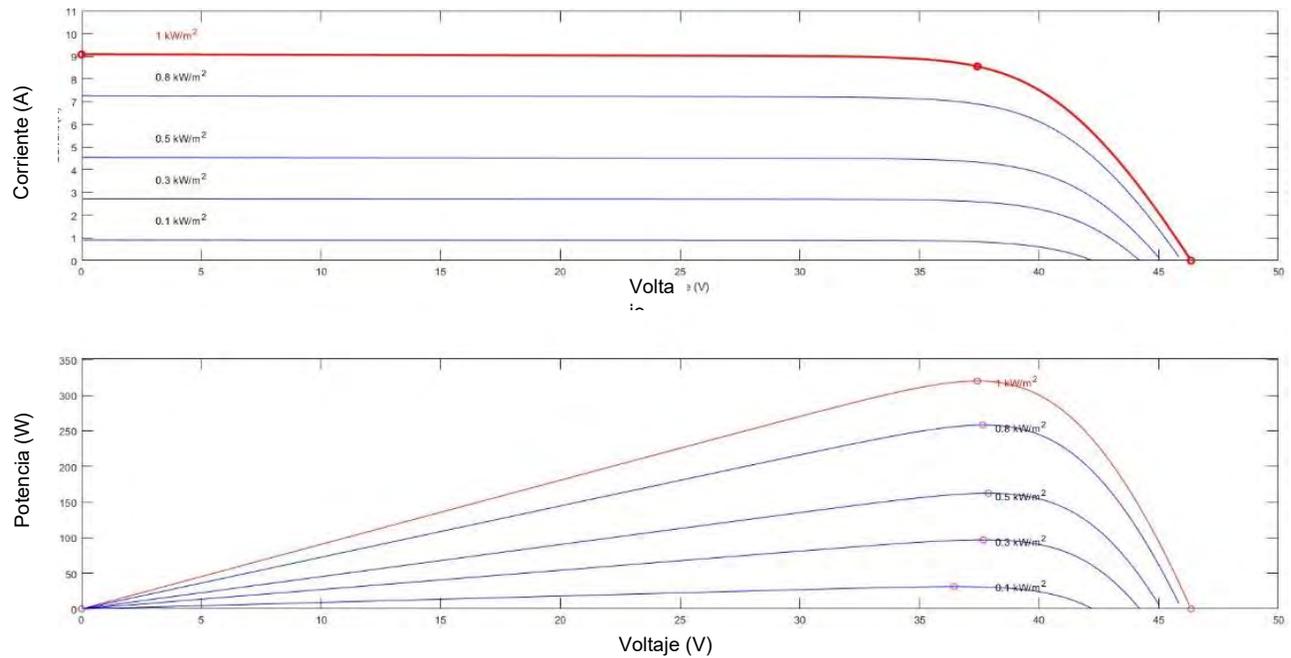


Figura 21. Curvas características V-I del módulo fotovoltaico EPL32024.

4.2. Diseño del convertidor CD-CD elevador (boost)

Con base a las características eléctricas del panel EPL32024 se realizó un análisis del convertidor boost en modo de conducción continua (MCC), de esta manera se calcularon los parámetros del convertidor que se presentan en la Tabla 5.

Tabla 5. Parámetros del convertidor boost.

Potencia de salida - P_o	320 W
Voltaje de entrada - V_{in}	37.42 V
Corriente de entrada - I_{in}	8.55 A
Voltaje de salida - V_o	100 V
Frecuencia - f	100 kHz
ΔV_c	5%
Δi_L	5%
Inductor - L	0.0027 H
Capacitor - C	$2.0026 \times 10^{-05} F$
Resistencia - R	31.25 Ω

Después de calcular los parámetros del convertidor, debemos tomar en cuenta la relación de impedancias que se presenta en este tipo de configuraciones (panel - convertidor – carga). Esta relación está dada por la Ecuación 8, la cual relaciona la impedancia de entrada Z_{in} con el ciclo de trabajo (d) y la impedancia de salida (Z_{out}) en el convertidor boost.

Con esta relación se realizó un barrido del ciclo de trabajo (d) y la impedancia de entrada Z_{in} . La gráfica resultante se presenta en la Figura 22, en ella se puede observar la impedancia de salida Z_o en distintas irradiancias, con esto podemos visualizar teóricamente que la carga a la salida del convertidor de 31.25Ω tendrá un rango de operación aceptable para las pruebas que se realizarán al sistema.

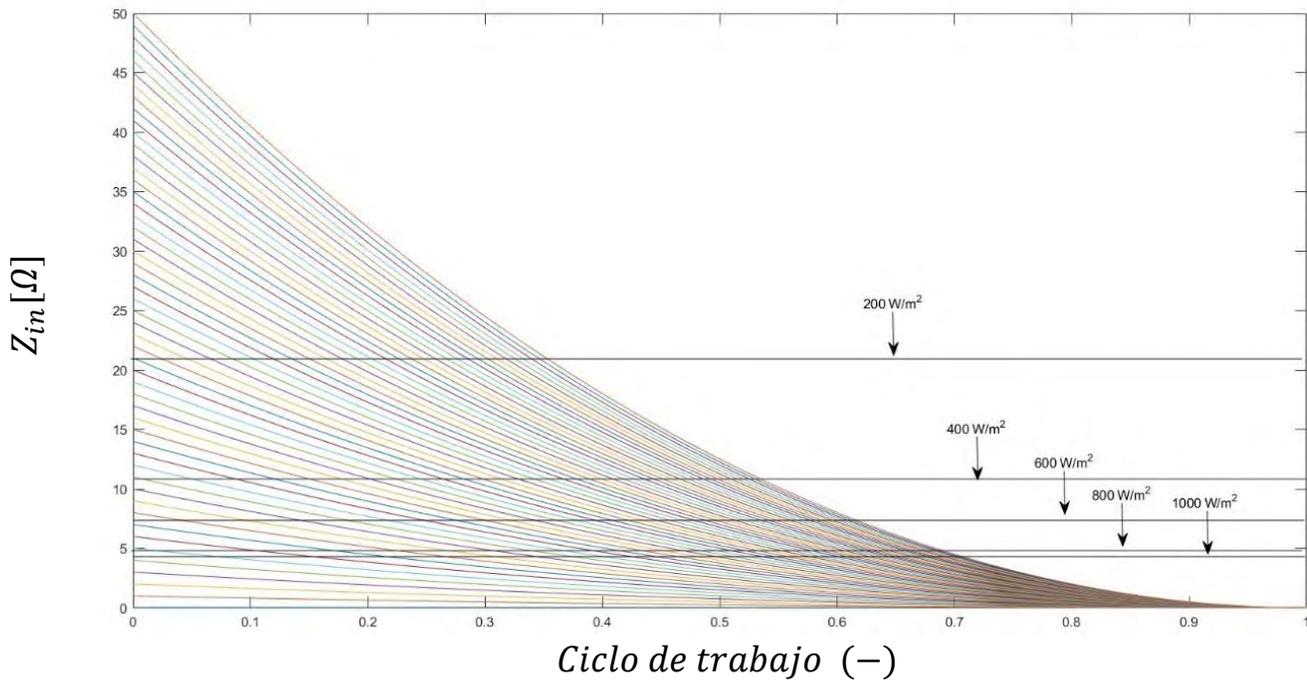


Figura 22. Relación de impedancia bajo diferentes irradiancias.

En la Tabla 6, se puede observar la relación que existe entre los voltajes y corrientes de máxima potencia, la irradiancia y el ciclo de trabajo. Para ello se despeja el ciclo de trabajo D en Ecuación 8, de esta manera se obtiene la ecuación 26.

$$d = 1 - \sqrt{\frac{Z_{in}}{Z_o}} \quad (26)$$

Tabla 6. Relación teórica entre los parámetros de máxima potencia y el ciclo de trabajo del convertidor boost.

Irradiancia G $\left(\frac{W}{m^2}\right)$	V_{mp} (V)	I_{mp} (A)	P_{mp} (W)	d (-)
1000	37.42	8.55	320	0.63
900	37.37	7.74	289.18	0.6112
800	37.64	6.86	258.14	0.5896
700	37.82	5.99	226.59	0.5590
600	37.80	5.15	194.67	0.5236

4.3. Obtención del algoritmo ICANNi

El algoritmo basado en redes neuronales artificiales inversas (ANNi) y la ley de control integral (IC) representa una innovación significativa en el campo del control de procesos, especialmente en sistemas no lineales complejos. ICANNi se basa en el uso de redes neuronales para modelar el comportamiento inverso de un sistema, permitiendo un control preciso y adaptativo. Este enfoque es particularmente útil cuando los modelos matemáticos exactos del sistema son difíciles de obtener debido a la naturaleza no lineal y dinámica del proceso.

El algoritmo ICANNi se obtiene entrenando una red neuronal para que aprenda la relación inversa entre las entradas y salidas del sistema. Este proceso de entrenamiento implica proporcionar a la red datos de entrada y salida del sistema real, ajustando los pesos de la red para minimizar el error entre las salidas previstas por la red y las salidas reales del sistema. Una vez entrenada, la red puede utilizarse para calcular las entradas necesarias para lograr las salidas deseadas, lo que permite un control eficaz del sistema.

Se aplicó un esquema de control basado en ICANNi para la producción de hidrógeno en un motor de combustión interna. Se utilizaron controladores de modelo predictivo (MPC) y de tipo PID junto con una red neuronal de perceptrón multicapa. Este enfoque permitió una producción eficiente en la demanda de hidrógeno, lo que mejoró la eficiencia térmica y de combustión del motor, además de reducir el uso de combustibles fósiles. La

combinación de estos controladores con redes neuronales permitió una respuesta rápida y precisa a las demandas variables de hidrógeno del motor [60].

En este trabajo, el algoritmo ICANNi se utilizará para el seguimiento de máxima potencia en un sistema fotovoltaico. El objetivo es optimizar la producción de energía del sistema fotovoltaico ajustando continuamente las condiciones de operación para mantener la máxima eficiencia. Al aplicar ICANNi, se espera mejorar significativamente la eficiencia y el rendimiento del sistema fotovoltaico, asegurando que se aproveche al máximo la energía solar disponible en todo momento. Esta aplicación resalta la versatilidad y eficacia de ICANNi en diferentes contextos industriales y de energía renovable, demostrando su importancia en la ingeniería de control moderna.

4.3.1. Obtención de la red neuronal artificial representativa del sistema fotovoltaico

Se propone una red neuronal artificial (ANN) que sea característica del sistema donde alguna de sus entradas sea la variable que se requiera estimar, y su salida sea una variable que se pueda medir. En este caso se propone una red *feed-forward* de una neurona en su capa oculta, una salida que es la irradiancia (G) y tres neuronas de entrada, el voltaje del panel (V_{pv}), la corriente del panel (I_{pv}) y el ciclo de trabajo (d). La función de activación en la capa oculta es una función tangente hiperbólica y en su neurona de salida es una función lineal. En la Figura 23 y en la ecuación 27, podemos observar el esquema descrito y la ecuación de la red respectivamente.

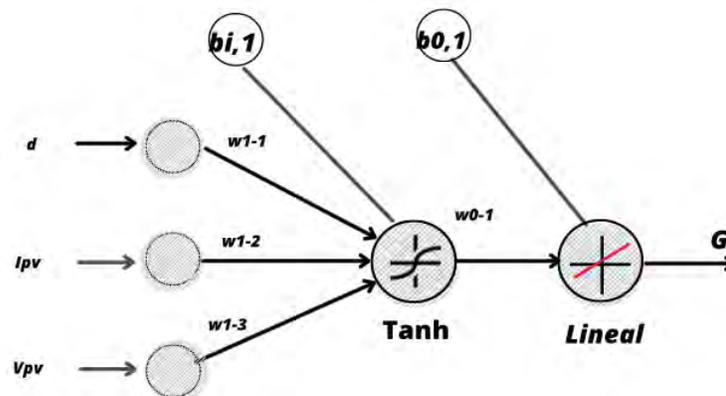


Figura 23. ANN característica del sistema fotovoltaico.

El polinomio característico de la red se presenta en la siguiente expresión.

$$y_{ann} = LINEAR[w_o(\tanh(W_i x_j + b_{i(s)})) + b_o] \quad (27)$$

Donde

y_{ann} = Irradiancia G

x_j = Datos de entrada ($x_1 = d, x_2 = I_{pv}, x_3 = V_{pv}$)

W_i = Pesos

$b_{i(s)}$ = Sesgos (bias)

La red neuronal fue diseñada en Matlab Script, y para ello se tomaron los datos de la Tabla 6, donde se relaciona el ciclo de trabajo con el punto de máxima potencia. Estos datos se extrapolaron y generaron vectores de datos de entrada, como lo son, la corriente y el voltaje del panel, así como el ciclo de trabajo. La normalización de los datos se realizó con la ecuación 28, esta normalización va desde 0.1 para el dato de menor valor 0.9 para el dato de mayor valor.

$$x = 0.8 \left(\frac{x_j - x_{jmin}}{x_{jMAX} - x_{jmin}} \right) + 0.1 \quad (28)$$

Donde:

x_{jmin} = Dato de entrada mínimo

x_{jMAX} = Dato de entrada máximo

En las Figuras 24, 25, y 26 se presentan los vectores de ciclo de trabajo (d), corriente del panel (I_{pv}) y voltaje del panel (V_{pv}) respectivamente, correspondientes a las entradas con las cuales fue entrenada la red y en la Figura 27 se presenta la salida de la red la cual corresponde a la irradiancia (G).

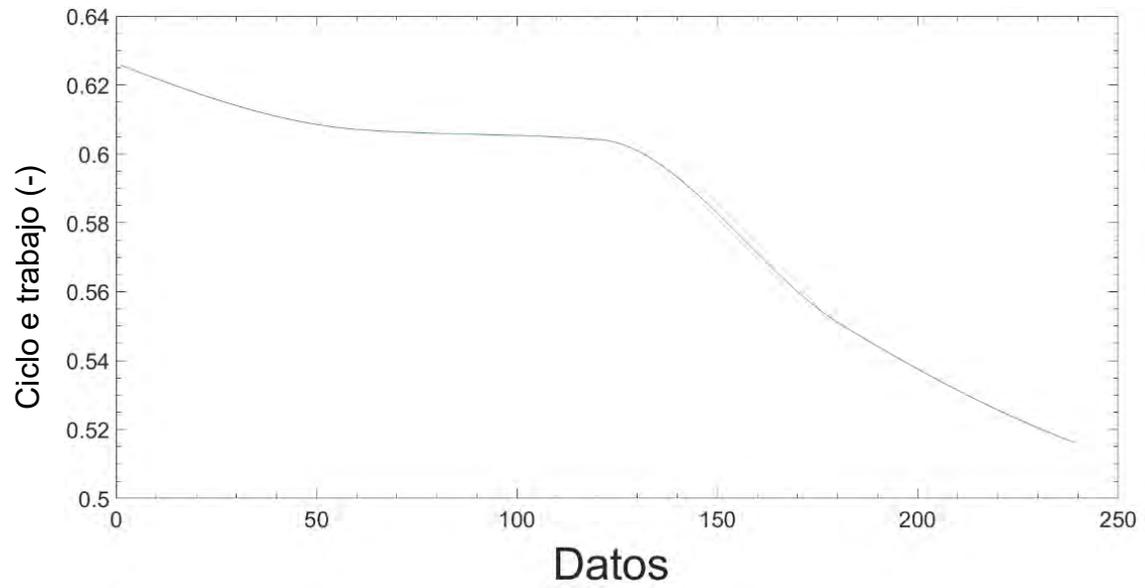


Figura 24. Ciclo de trabajo utilizado como variable de entrada para el entrenamiento de la red.

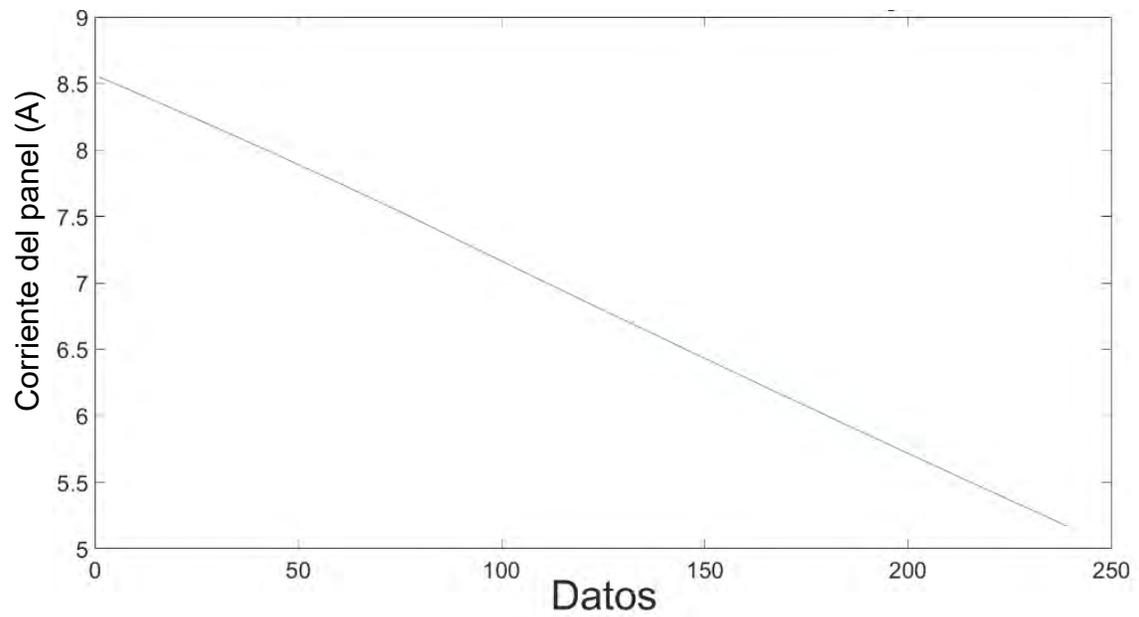


Figura 25. Corriente de máxima potencia utilizada como variable de entrada para el entrenamiento de la red.

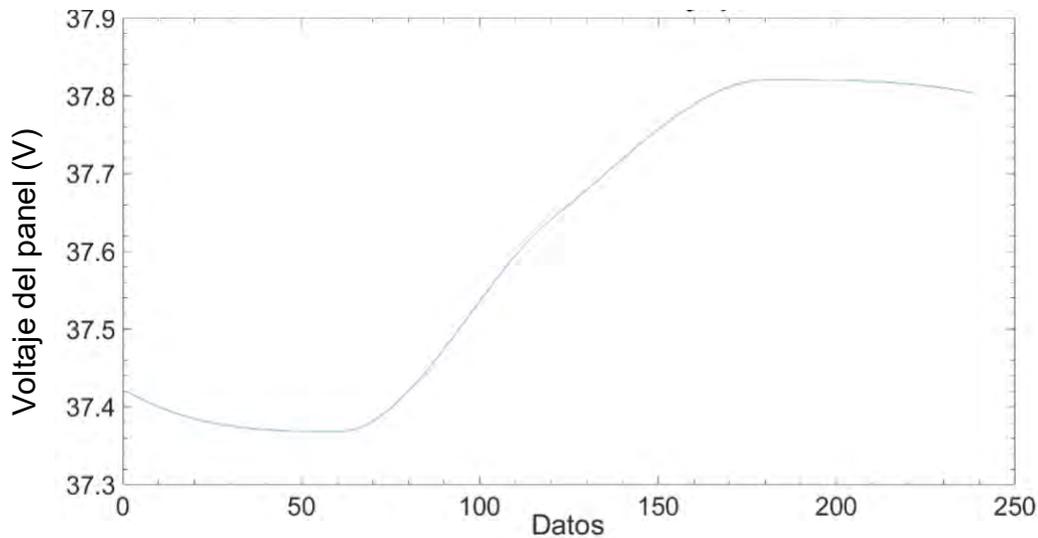


Figura 26. Voltaje de máxima potencia utilizado como variable de entrada para el entrenamiento de la red.

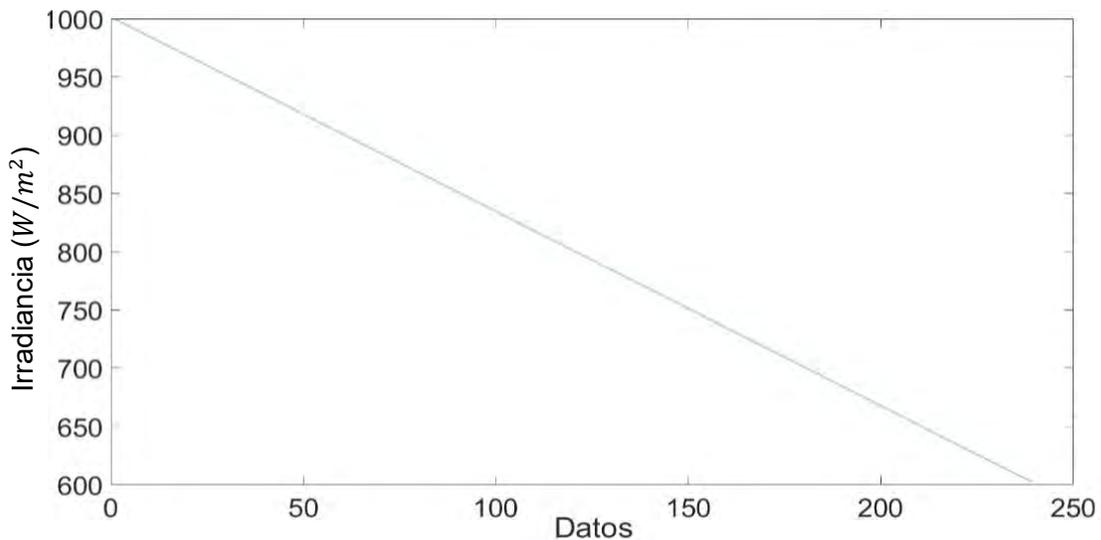


Figura 27. Irradiancia del panel utilizada como variable de salida para el entrenamiento de la red.

La red fue entrenada, probada y validada con base a los datos calculados del sistema fotovoltaico. Si bien los datos de corriente y voltaje se obtuvieron por medio del modelo del panel, los datos del ciclo de trabajo fueron calculados y afinados de manera manual. La red neuronal artificial fue entrenada con una neurona en la capa oculta, tres neuronas de entrada y una de salida. Los datos se dividieron en un subconjunto de entrenamiento (60%) para actualizar los valores de los pesos sinápticos un subconjunto de validación (20%) y un subconjunto de prueba (20%). El entrenamiento se detendrá si el error relacionado con la validación y la prueba comienza a aumentar.

Los pesos se obtuvieron mediante el algoritmo de retro-propagación de errores los cuales se presentan en la Tabla 7.

Tabla 7. Valores de los pesos (w) y sesgos (b) de la red neuronal artificial característica del sistema fotovoltaico.

Pesos y sesgos calculados para la ANN			
W_i	-0.0153	-0.182	-0.0041
W_o	-2.8818×10^3		
b_i	0.4479		
b_o	1.7582×10^3		

El modelo matemático de la red neuronal está dado por la siguiente expresión, donde G es la irradiancia :

$$G = W_{o_{1,1}} \left[\frac{2}{1 + e^{-2(\sum_{j=1}^3 (w_{i_1,j} x_j) + b_{i_1})}} - 1 \right] + b_{o_{1,1}} \quad (29)$$

4.3.2. Obtención de la red neuronal artificial inversa (ANNi)

Mediante la ecuación 29 es posible determinar la salida del sistema siempre y cuando se conozcan los parámetros de entrada. Para esta aplicación, la variable que se desea determinar por la red neuronal artificial inversa (ANNi) es el ciclo de trabajo (d). A continuación, se presenta la expresión despejada para el ciclo de trabajo, que a su vez es la red neuronal artificial inversa ANNi.

$$d = \left[\frac{-\frac{1}{2} \left[\ln \left(\frac{W_{o_{1,1}} - G + b_{o_{1,1}}}{W_{o_{1,1}} + G - b_{o_{1,1}}} \right) \right] - W_{i_{1,2}} I - W_{i_{1,3}} V - b_{i_1}}{W_{i_{1,1}}} \right] \quad (30)$$

Sustituyendo los parámetros de la red (pesos y sesgos)

$$d = \left[\frac{-\frac{1}{2} \left[\ln \left(\frac{(-2.8818 \times 10^3) - G + 1.7582 \times 10^3}{(-2.8818 \times 10^3) + G - 1.7582 \times 10^3} \right) \right] - (-0.182)I - (-0.0041)V - 0.4479}{-0.0153} \right] \quad (31)$$

Resolviendo las multiplicaciones de signos, obtenemos:

$$d = \left[\frac{-\frac{1}{2} \left[\operatorname{Ln} \left(\frac{(-2.8818 \times 10^3) - G + 1.7582 \times 10^3}{(-2.8818 \times 10^3) + G - 1.7582 \times 10^3} \right) \right] + 0.182I + 0.0041V - 0.4479}{-0.0153} \right] \quad (32)$$

En la Figura 28, se observa un esquema de la ANNi, donde la salida que en este caso era la irradiancia se vuelve nuestra entrada, y el ciclo de trabajo que en principio era una entrada ahora es nuestra salida.

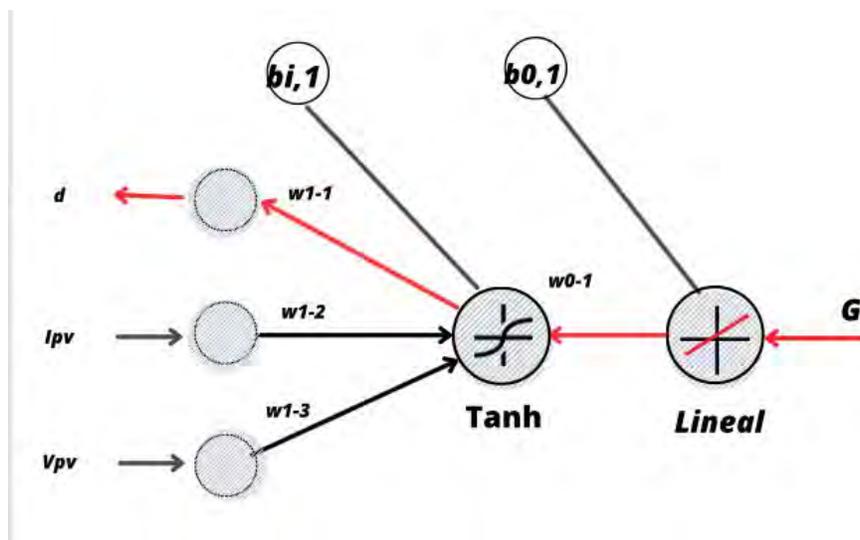


Figura 28. Esquema de la red neuronal inversa.

4.3.3. Modelo de referencia

El modelo de referencia se realizó por medio de una red neuronal artificial (ANN) que consta de tres capas, una capa de entrada con una neurona, una capa oculta con cuatro neuronas y una capa de salida con una sola neurona. La entrada del modelo de referencia es la irradiancia (G) y la salida es el ciclo de trabajo (d). Los datos experimentales se dividieron en un subconjunto de entrenamiento (60%) para actualizar los valores de los pesos sinápticos un subconjunto de validación (20%) y un subconjunto de prueba (20%), de la misma manera que la red que se utilizó para la red inversa. En la Figura 29, se presenta la gráfica interceptor, que muestra la exactitud que tiene nuestra salida deseada frente a los valores predichos por la red.

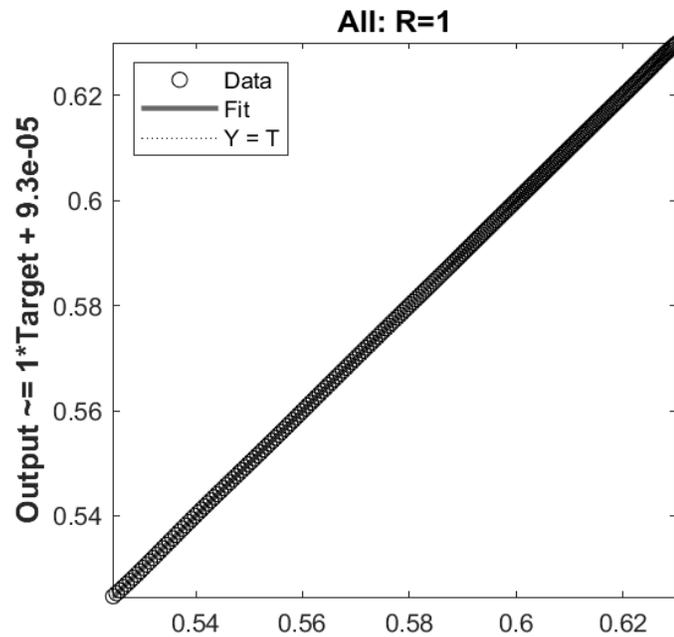


Figura 29. Salida deseada del ciclo de trabajo frente a los valores predichos por la red.

La imagen muestra un gráfico de ajuste de datos. En este gráfico, el eje horizontal (x) representa el “*Target*” (objetivo) y el eje vertical (y) representa el “*Output*” (resultado). Los puntos en el gráfico, marcados con círculos y etiquetados como “*Data*” (datos), representan las observaciones reales.

La línea continua en el gráfico, etiquetada como “*Fit*” (ajuste), representa el modelo matemático que mejor se ajusta a los datos observados. Además, hay una línea punteada llamada “ $Y = T$ ” que sirve como referencia, mostrando dónde el resultado sería igual al objetivo. La ecuación del ajuste que aparece en el gráfico es “ $Output = \sim 1 * Target + 9.3e-05$ ”. Esto significa que el resultado es casi igual al objetivo, con una diferencia muy pequeña (un intercepto de $9.3e-05$, que es casi cero).

Finalmente, el valor de $R=1$ indica que hay una correlación perfecta entre los datos observados y el modelo ajustado. Esto significa que el modelo explica completamente la variabilidad en los datos, es decir, el modelo predice los datos observados con una precisión extremadamente alta.

4.3.4. Ley de control integral (IC)

Esta estrategia de control busca eliminar el error en estado estable que se genera entre el ciclo de trabajo de la red ANNi y el modelo de referencia. Para estimar el error, el ciclo de trabajo calculado por la red ANNi, se compara con el ciclo de trabajo del modelo de referencia, este error se integra y luego esta se multiplica por una ganancia y se añade al ciclo de trabajo calculado por la ANNi. La integración del controlador integral (IC) y la red neuronal artificial inversa (ANNi) la llaman ICANNi [60].

En la figura 30, se presenta un diagrama a bloques de SIMULINK, del algoritmo ICANNi. El cual consta de su panel caracterizado (EPL32024), un convertidor boost, la red artificial inversa (ANNi), el modelo de referencia y la ley de control integral.

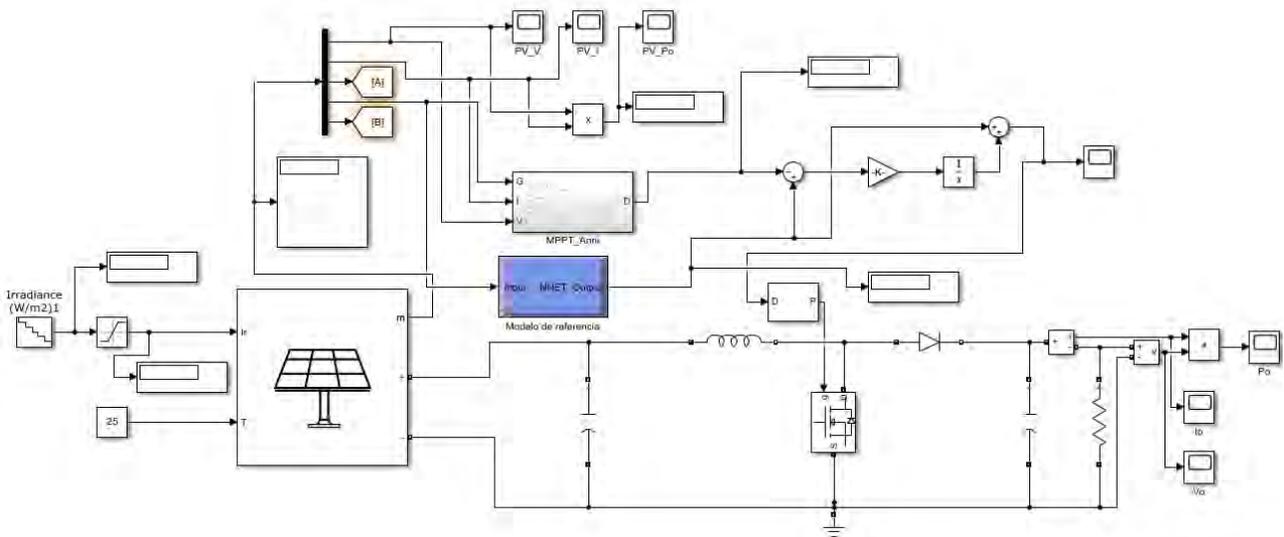


Figura 30. Diagrama esquemático de las interconexiones del sistema fotovoltaico con el algoritmo ICANNi.

CAPÍTULO 5.

PRUEBAS Y

RESULTADOS

5.1. Variación de irradiancia y temperatura constante de 25°C para el algoritmo perturbar y observar (P&O)

El algoritmo P&O inicia el sistema con un ciclo de trabajo inicial “Dinicial” de 0.5, y está delimitado con un ciclo de trabajo máximo “Dmax” de 0.95 y un ciclo de trabajo mínimo “Dmin” de 0.05. La variación del ciclo de trabajo para cada perturbación “deltaD” es de 0.00003. En la Figura 31, se presenta el diagrama a bloques del sistema fotovoltaico.

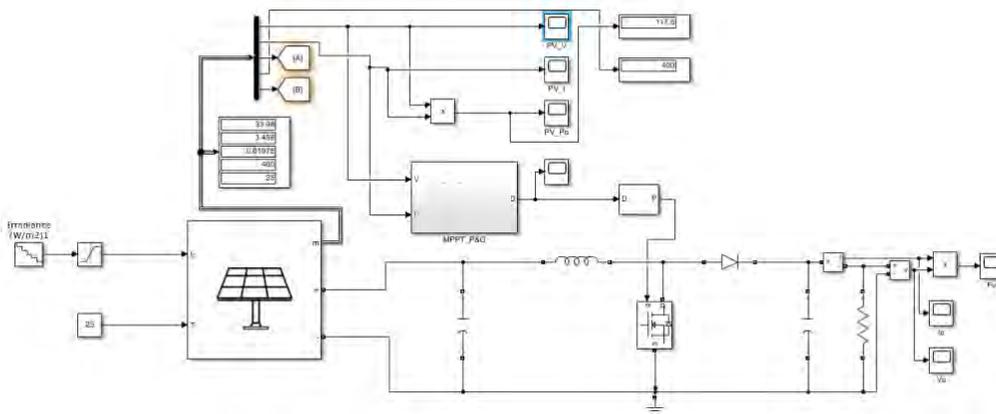


Figura 31. Diagrama esquemático de las interconexiones del sistema fotovoltaico con el algoritmo P&O.

El sistema se somete a cambios drásticos de irradiancia que van desde 1000 W/m^2 hasta 600 W/m^2 estos cambios se realizan con una caída de 100 W/m^2 cada 0.2 segundos. En la Figura 32, se observa el comportamiento de la potencia de salida que tiene el panel, donde el eje “y” corresponde a la potencia y el eje “x” al tiempo de simulación.

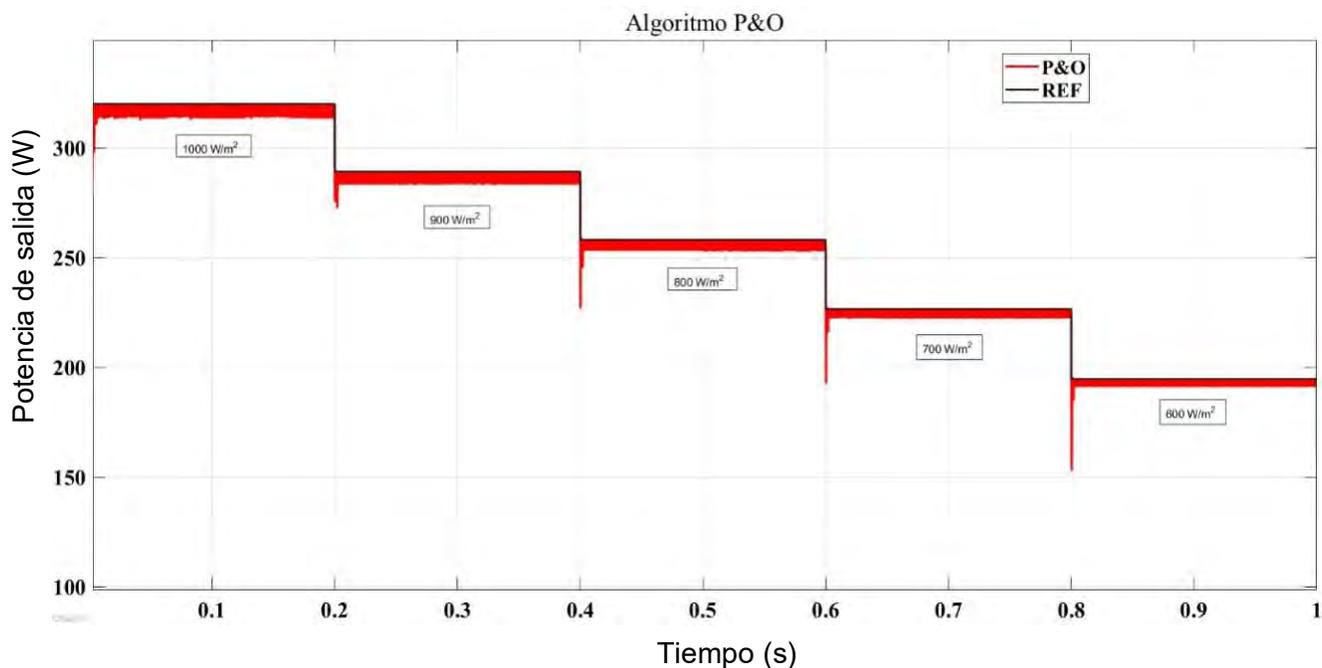


Figura 32. Seguimiento del punto de máxima potencia con el algoritmo P&O.

4.5.1. Error de seguimiento del punto de máxima potencia del algoritmo P&O

En la Figura 33, se presenta una gráfica que muestra el error de seguimiento del algoritmo, la gráfica representa la diferencia entre la potencia de salida obtenido por el algoritmo P&O y la potencia de referencia de acuerdo a la irradiancia.

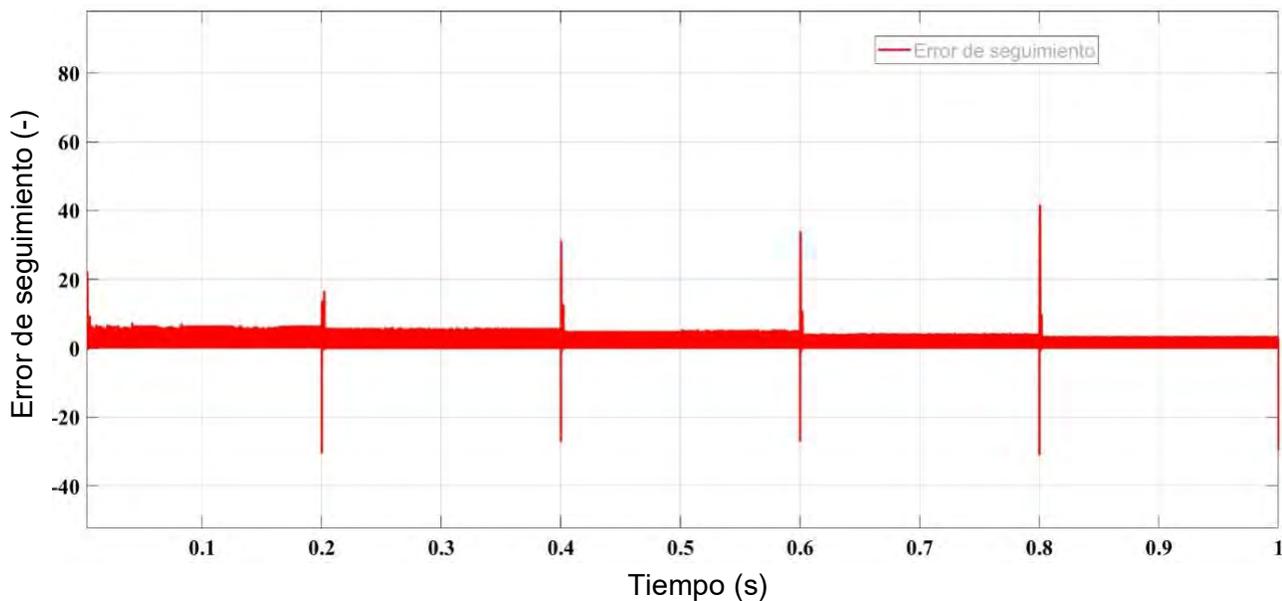


Figura 33. Error del seguimiento del algoritmo P&O.

4.5.2. Respuesta del algoritmo P&O ante irradiancia real.

El sistema se somete a valores de irradiancia solar real extraídos de la base de datos del Instituto Nacional de Ecología y Cambio Climático (Sinaica). Los valores corresponden a la irradiancia incidente en el municipio de Cuernavaca en el estado de Morelos, en el mes de diciembre del año 2019, se tomaron los primeros días del mes (1-3) en un horario de 9:00 am a 14:00 pm, donde la irradiancia es mayor a 600 W/m^2 . En la Figura 34, se muestra de manera gráfica el comportamiento de la irradiancia en los tres días simulados.

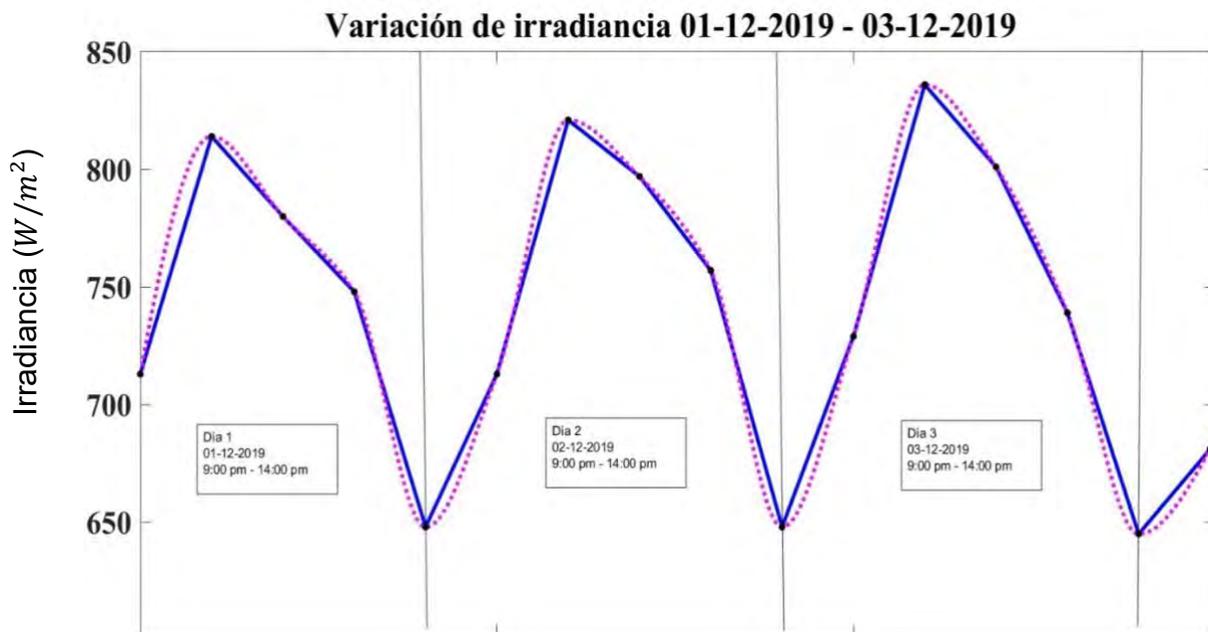


Figura 34. Irradiancia incidente en Cuernavaca en las fechas 01-12-2019 – 01-12-2019.

Tomando como base la irradiancia que se muestra en la Figura 34, se procedió a realizar la simulación del sistema. Para esta simulación, se utilizó el algoritmo perturbar y observar para el seguimiento del punto de máxima potencia. Como se puede observar en la Figura 35, el sistema logra seguir el punto de máxima potencia; sin embargo, presenta oscilaciones alrededor del punto de interés. Las oscilaciones se deben principalmente a la estructura del controlador utilizado.



Figura 35. Seguimiento del punto de máxima potencia con el algoritmo P&O con irradiancia real.

4.5.3. Índice de desempeño y eficiencia del algoritmo P&O

En la tabla 8, se presenta el error cuadrático medio (MSE), que nos muestra qué tan lejos estamos de los valores reales. También se muestra el error porcentual absoluto medio (MAPE), que nos indica el porcentaje de error entre la variable deseada y la variable controlada; un porcentaje por debajo del 5% se considera aceptable. Por último, se incluye el tiempo promedio de estabilización que refleja la rapidez con la que el sistema alcanza el estado estacionario deseado.

Tabla 8. Índice de desempeño del algoritmo P&O.

Algoritmo	Error cuadrático medio	Desviación estándar	MAPE %	Tiempo de estabilización (s)
P&O	2.84920632	1.553613518	0.523592979	0.0156

Tabla 9. Eficiencia promedio del sistema con el algoritmo P&O

Eficiencia de conversión energética	Eficiencia teórica del convertidor	Eficiencia total del sistema
$n_{ce} = \frac{P_{pmp}}{P_{pv}}$	$n_t = \frac{V_o(1-D)}{V_{in}}$	$n_t = n_{ce} * n_t$
98%	95.5 %	93.59%

4.6. Variación de irradiancia y temperatura constante de 25°C para el algoritmo ICANNi

El sistema se somete a cambios drásticos de irradiancia que van desde 1000 W/m^2 hasta 600 W/m^2 estos cambios se realizan con una caída de 100 W/m^2 cada 0.2 segundos. En la Figura 36, se observa el comportamiento de la potencia de salida que tiene el panel, donde el eje “y” corresponde a la potencia y el eje “x” al tiempo de simulación.

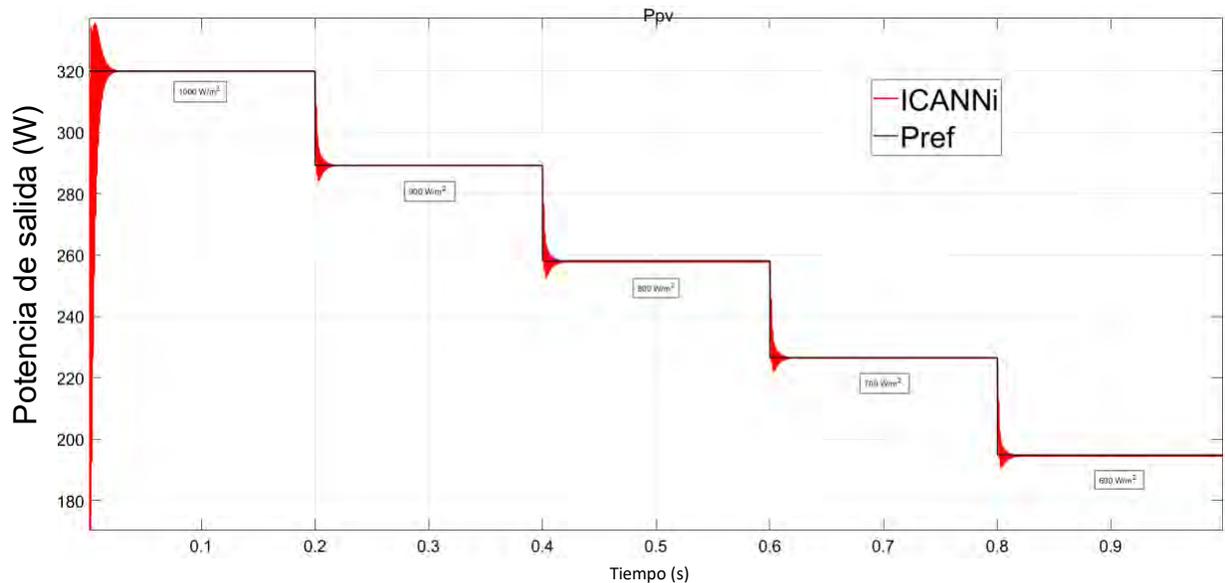


Figura 36. Seguimiento del punto de máxima potencia con el algoritmo ICANNi.

Como se puede observar en la Figura 36, al utilizar la metodología propuesta se logra extraer la máxima potencia del panel en cada cambio de irradiancia. De la misma forma, se puede apreciar que las oscilaciones alrededor del punto de máxima potencia se eliminaron en estado estable. La eliminación de las oscilaciones tiene un impacto positivo en la eficiencia del sistema, por lo que el algoritmo propuesto muestra mejoras en la extracción de energía.

4.6.1. Error de seguimiento del algoritmo ICANNi

En la Figura 37, se presenta una gráfica que muestra el error de seguimiento del algoritmo, la gráfica representa la diferencia entre el valor obtenido por el algoritmo ICANNi y el valor de referencia.

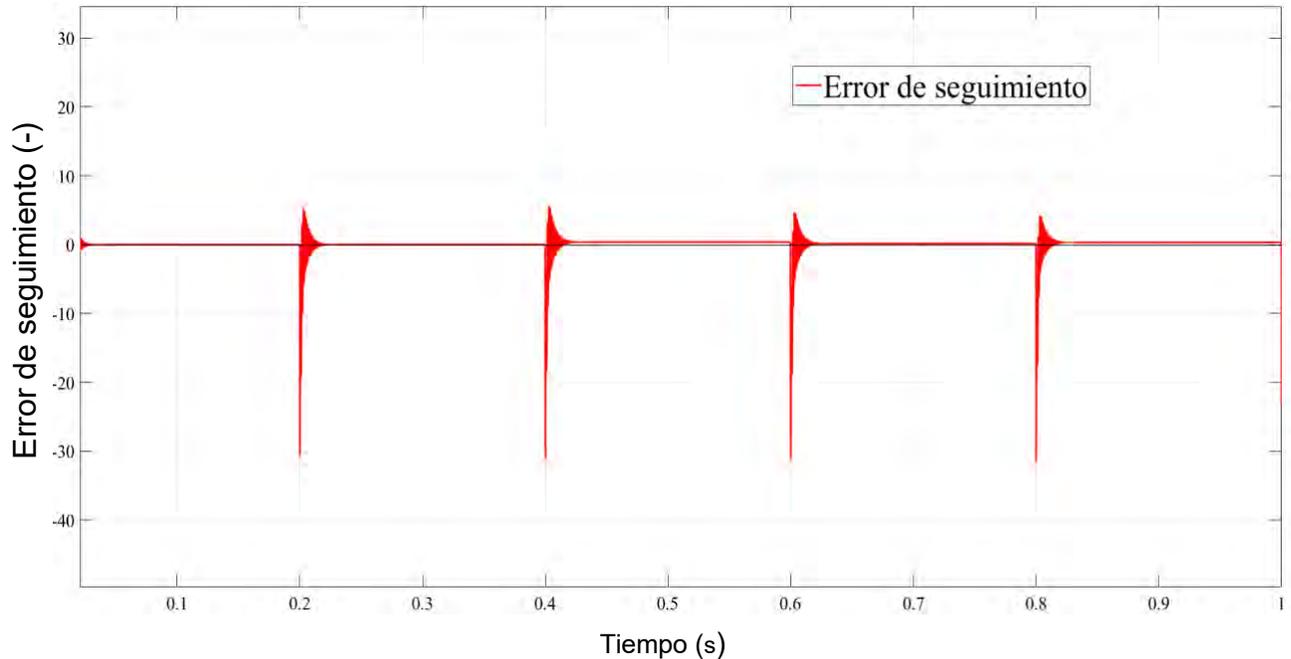


Figura 37. Error del seguimiento del algoritmo ICANNi.

De acuerdo con lo que se muestra en la Figura 37, los momentos en los que se presenta mayor error son durante los cambios de irradiancia; esto se debe a los ajustes que la red neuronal inversa realiza al ciclo de trabajo. Sin embargo, el error de seguimiento obtenido es aceptable y presenta un mejor comportamiento que el error de seguimiento del algoritmo P&O.

4.6.2. Respuesta del algoritmo ICANNi ante irradiancia real

El sistema se somete a valores de irradiancia solar real extraídos del Instituto Nacional de Ecología y Cambio Climático (Sinaica). Los valores corresponden a la irradiancia incidente en el municipio de Cuernavaca en el estado de Morelos, en el mes de diciembre del año 2019, se tomaron los primeros días del mes (1-3) en un horario de 9:00 am a 14:00 pm, donde la irradiancia es mayor a 600 W/m^2 . En la Figura 38, se presenta la dinámica que se obtiene al aplicar el algoritmo ICANNi.

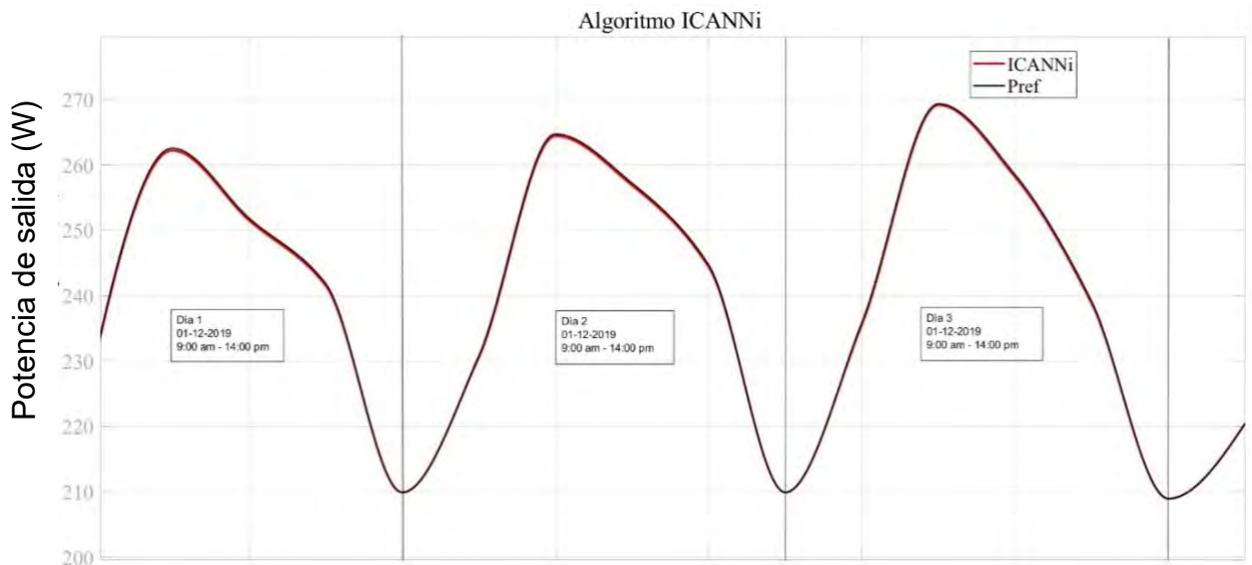


Figura 38. Seguimiento del punto de máxima potencia con el algoritmo ICANNi e irradiancia real.

El comportamiento dinámico del sistema fotovoltaico utilizando el algoritmo ICANNi destaca por su estabilidad y precisión, siguiendo de cerca la potencia de referencia durante los días y las condiciones de irradiancia analizadas, como se observa en la Figura 38. La potencia generada con ICANNi refleja fielmente los picos y valles de potencia, con desviaciones mínimas que indican una optimización eficiente. En contraste, el algoritmo P&O (Perturbar y Observar) presenta oscilaciones significativas ante variaciones en la irradiancia real (Ver Figura 35), lo que se traduce en fluctuaciones notables en la potencia de salida. Estas oscilaciones del P&O pueden disminuir la eficiencia del sistema fotovoltaico y provocar pérdidas de energía, especialmente en situaciones de irradiancia variable. En cambio, el algoritmo ICANNi mantiene una salida más suave y estable, mejorando la consistencia y el rendimiento energético del sistema fotovoltaico.

4.6.3. Índice de desempeño y eficiencia del algoritmo ICANNi

En la tabla 10, se presentan los resultados para el error cuadrático medio (MSE), la desviación estándar, error porcentual absoluto medio (MAPE), y el tiempo promedio de estabilización. Así mismo en la tabla 11, se presenta la eficiencia del sistema con el algoritmo ICANNi.

Tabla 10. Índice de desempeño del algoritmo ICANNi.

Algoritmo	Error cuadrático medio	Desviación estándar	MAPE %	Tiempo de estabilización (s)
ICANNi	0.03913594	0.019964719	0.065298535	0.023

Los valores de desempeño del algoritmo ICANNi muestran una alta precisión y eficiencia en la predicción y estabilización de la potencia de salida del sistema fotovoltaico. El error cuadrático medio (MSE) de 0.03913594 indica que las diferencias entre los valores predichos y los valores reales son mínimas, reflejando un rendimiento óptimo del algoritmo en términos de precisión. Además, la desviación estándar de 0.019964719 sugiere que las variaciones en los valores de potencia son pequeñas y consistentes, lo que refuerza la confiabilidad del ICANNi en diversas condiciones operativas.

Por otro lado, el error absoluto porcentual medio (MAPE) de 0.065298535 % evidencia que el porcentaje de error es extremadamente bajo, lo cual es crucial para aplicaciones donde la precisión es esencial. El tiempo de estabilización de 0.023 segundos demuestra la capacidad del algoritmo para adaptarse rápidamente a cambios en las condiciones de irradiancia, permitiendo una respuesta ágil y eficiente. Estos valores combinados subrayan la eficacia del ICANNi en mantener la estabilidad y optimización de la potencia de salida en sistemas fotovoltaicos, asegurando un rendimiento constante y confiable.

Tabla 11. Eficiencia promedio del sistema con el algoritmo ICANNi

Eficiencia de conversión energética	Eficiencia teórica del convertidor	Eficiencia total del sistema
$n_{ce} = \frac{P_{pmp}}{P_{pv}}$	$n_c = \frac{V_o(1-D)}{V_{in}}$	$n_t = n_{ce} * n_c$
99.96%	98.2%	98.16072%

Los valores de eficiencia del sistema fotovoltaico con el algoritmo ICANNi destacan por su alta capacidad de conversión y rendimiento general. La eficiencia de conversión energética (n_{ce}) es del 99.96%, lo que indica que casi toda la energía solar captada se

convierte en energía eléctrica útil. Este alto porcentaje demuestra la eficacia del sistema en la maximización del uso de la energía disponible.

Además, la eficiencia teórica del convertidor (n_c), calculada como 98.2%, refleja la capacidad del convertidor de transformar la energía de entrada en energía de salida con mínimas pérdidas. Finalmente, la eficiencia total del sistema (n_t), que es el producto de la eficiencia de conversión energética y la eficiencia del convertidor, es del 98.16072%. Este valor subraya la integración eficiente de todos los componentes del sistema, asegurando un rendimiento óptimo y fiable en la generación de energía eléctrica a partir de la energía solar.

En la Tabla 12, se presenta la comparación del algoritmo P&O y el algoritmo ICANNi, tomando en cuenta los índices de desempeño, y en la Tabla 13 la eficiencia de conversión y la eficiencia del convertidor con cada algoritmo.

Tabla 12. Comparación del algoritmo P&O y el algoritmo ICANNi en terminos de eficiencia.

Algoritmo	Eficiencia de conversión energética	Eficiencia teórica del convertidor	Eficiencia total del sistema
	$n_{ce} = \frac{P_{pmp}}{P_{pv}}$	$n_c = \frac{V_o(1-D)}{V_{in}}$	$n_t = n_{ce} * n_c$
P&O	98%	95.5%	93.59%
ICANNi	99.96%	98.2%	98.16072%

Los valores presentados en la tabla revelan una clara ventaja del ICANNi en términos de eficiencia de conversión energética y desempeño global del sistema fotovoltaico. En cuanto a la eficiencia de conversión energética (n_{ce}), el ICANNi alcanza un impresionante 99.96%, muy por encima del 98% obtenido con P&O. Esta diferencia refleja la capacidad superior del ICANNi para convertir la energía solar disponible en energía eléctrica, minimizando las pérdidas durante el proceso. Además, la eficiencia teórica del convertidor (n_c) bajo el control de ICANNi es del 98.2%, comparado con el 95.5% del P&O, lo que indica un manejo más eficiente de la energía dentro del convertidor, reduciendo aún más las pérdidas internas.

La eficiencia total del sistema es otra métrica en la que el ICANNi demuestra su superioridad, con un 98.16072% en comparación con el 93.59% del P&O. Este resultado subraya que el ICANNi no solo mejora la eficiencia en la conversión de energía, sino que optimiza el rendimiento integral del sistema fotovoltaico. La combinación de una alta eficiencia de conversión energética y un convertidor más eficiente permite que el ICANNi maximice el aprovechamiento de la energía, convirtiéndose en una opción más eficaz para aplicaciones en sistemas fotovoltaicos que buscan minimizar pérdidas y maximizar la producción energética.

Tabla 13. Comparación del algoritmo P&O y el algoritmo ICANNi en términos de los índices de desempeño.

Algoritmo	Error cuadrático medio	Desviación estándar	MAPE %	Tiempo de estabilización (s)
P&O	2.84920632	1.553613518	0.523592979	0.0156
ICANNi	0.03913594	0.019964719	0.065298535	0.023

La comparación entre los algoritmos P&O e ICANNi, según los valores de desempeño presentados, muestran una ventaja significativa del ICANNi en términos de precisión y estabilidad. El error cuadrático medio (MSE) del P&O es considerablemente mayor, con un valor de 2.84920632, en comparación con el MSE del ICANNi, que es de solo 0.03913594. Esto sugiere que el ICANNi tiene una capacidad mucho mayor para predecir con precisión la potencia de salida, reduciendo significativamente los errores. Además, la desviación estándar, que mide la variabilidad de la potencia de salida respecto a la referencia, es mucho menor en ICANNi (0.019964719) en comparación con P&O (1.553613518), indicando que ICANNi ofrece un rendimiento mucho más consistente y estable.

En cuanto al error absoluto porcentual medio (MAPE), el ICANNi también muestra un desempeño superior, con un MAPE de 0.065298535%, lo que refleja un error porcentual mínimo en comparación con el 0.523592979% de P&O. Aunque el tiempo de estabilización del P&O es ligeramente menor (0.0156 segundos frente a 0.023 segundos del ICANNi), la diferencia es mínima y no compensa las ventajas claras que ICANNi

ofrece en términos de precisión y estabilidad. En conjunto, estos valores destacan la capacidad del ICANNi para proporcionar un control más preciso y estable en sistemas fotovoltaicos, minimizando errores y garantizando un rendimiento más fiable en comparación con el algoritmo P&O.

CAPÍTULO 6.
CONCLUSIONES Y
TRABAJOS
FUTUROS

6.1. Conclusión

El análisis y desarrollo de algoritmos para el seguimiento del punto de máxima potencia (MPPT) en sistemas fotovoltaicos es fundamental para optimizar la generación de energía solar. A lo largo de esta tesis, se logró cumplir con el objetivo general de diseñar y evaluar el desempeño de un convertidor CD-CD que permite extraer la máxima potencia de un sistema de cosecha de energía, utilizando como herramienta principal redes neuronales artificiales inversas. Este logro se refleja en la comparación de dos algoritmos, donde se evaluó su eficiencia y desempeño bajo diferentes condiciones de operación. Se cumplió con el objetivo específico de proponer un convertidor CD-CD que cumple con las características del sistema de cosecha de energía (sistema fotovoltaico). Además, se obtuvo una red neuronal artificial adecuada y representativa del sistema fotovoltaico, así como una red neuronal artificial inversa que permite extraer el punto de máxima potencia.

El algoritmo desarrollado ICANNi demostró una superioridad notable frente al algoritmo Perturbar y Observar (P&O), eliminando por completo las oscilaciones en estado estacionario y reduciendo significativamente el error de seguimiento. Los resultados gráficos y los índices de desempeño presentados corroboran la eficacia del algoritmo desarrollado. Aunque el tiempo de estabilización del algoritmo ICANNi es ligeramente más lento que el P&O, siendo aproximadamente 8 milisegundos mayor, esta pequeña desventaja es compensada por la mejora en la eficiencia de conversión de energía y la operación del convertidor, logrando reducir las oscilaciones y el estrés en los dispositivos de conmutación, cumpliendo así con las metas propuestas.

Los resultados en simulación del algoritmo ICANNi bajo condiciones de irradiancia real han demostrado su capacidad para adaptarse a variaciones rápidas y complejas en el ambiente, lo que lo hace especialmente adecuado para aplicaciones prácticas en entornos donde la irradiancia solar puede ser inestable. Esto confirma el cumplimiento del objetivo específico de obtener el desempeño del sistema fotovoltaico aplicando la metodología de redes neuronales artificiales para el seguimiento del punto de máxima potencia.

Esta adaptabilidad y precisión refuerzan la viabilidad del algoritmo para su uso en sistemas fotovoltaicos. En comparación con los algoritmos convencionales como el P&O, que siguen siendo útiles debido a su simplicidad y bajo costo, los algoritmos híbridos y avanzados como el ICANNi están allanando el camino hacia un aprovechamiento más eficiente y adaptable de la energía solar. Este avance contribuye no solo a la eficiencia energética sino también al desarrollo sostenible y la reducción de la huella de carbono, cumpliendo así con las metas de optimización de los sistemas de energía fotovoltaica.

El incremento de la eficiencia en la conversión de energía solar mediante el uso de algoritmos tiene implicaciones significativas para el futuro de la energía renovable. La reducción de las oscilaciones y el aumento de la precisión en el seguimiento del punto de máxima potencia permiten un uso más efectivo de los recursos disponibles. Esto no solo mejora la rentabilidad de los sistemas fotovoltaicos, sino que también promueve una mayor adopción de esta tecnología en diversas aplicaciones. El potencial de integración de redes neuronales artificiales en el seguimiento de máxima potencia, demostrado en este trabajo, abre nuevas oportunidades para el desarrollo de sistemas de control más sofisticados. La capacidad de estos algoritmos para aprender y adaptarse a diferentes condiciones ambientales es una ventaja considerable que puede llevar a mejoras continuas en el rendimiento del sistema. A medida que se desarrollen más aplicaciones y se realicen más investigaciones en este campo, es probable que veamos un aumento en la eficiencia y la fiabilidad de los sistemas fotovoltaicos.

El futuro del seguimiento de la máxima potencia en sistemas fotovoltaicos probablemente verá una mayor integración de técnicas avanzadas de inteligencia artificial, lo que llevará a una mayor optimización de la generación de energía solar y contribuirá al objetivo global de sostenibilidad energética. Este desarrollo, alcanzado mediante el cumplimiento de los objetivos y metas propuestos en esta tesis, no solo es beneficioso para la industria de la energía solar, sino también para el medio ambiente, ya que contribuye a la reducción de la dependencia de combustibles fósiles y a la disminución de las emisiones de gases de efecto invernadero.

6.2. Trabajos futuros

- I. **Implementación del Algoritmo ICANNi en un Sistema Real:** Un paso importante para futuros trabajos es la implementación del algoritmo ICANNi en un sistema fotovoltaico real. Esto permitirá validar los resultados obtenidos en simulaciones y evaluar el desempeño del algoritmo bajo condiciones de operación reales.
- II. **Comparación del Algoritmo ICANNi con Otros Algoritmos Híbridos:** Otro enfoque interesante para futuras investigaciones es la comparación del algoritmo ICANNi con otros algoritmos híbridos de seguimiento de máxima potencia (MPPT). Esto incluiría algoritmos que combinan técnicas de inteligencia artificial con métodos tradicionales de MPPT.
- III. **Desarrollo de un Análisis del Convertidor para Evaluar su Comportamiento Dinámico con el Algoritmo ICANNi:** Un aspecto crucial para mejorar la eficiencia del sistema fotovoltaico es entender el comportamiento dinámico del convertidor CD-CD cuando se utiliza el algoritmo ICANNi. Futuras investigaciones deberían centrarse en un análisis detallado del convertidor, observando cómo responde a diferentes condiciones de carga y variaciones de irradiancia

REFERENCIAS

- [1] F. J. R. d. I. A. C. d. C. E. Mondragón, Físicas y Naturales, "Ciclos del dióxido de carbono en la formación y utilización de combustibles fósiles y su efecto en el cambio climático," vol. 45, no. 176, pp. 833-849, 2021.
- [2] I. E. AGENCY, "Renewables 2022 - Analysis and forecast to 2027," IEA, 2022.
- [3] J. Rodríguez *et al.*, "La industria solar fotovoltaica y fototérmica en México," ed: Ciudad de México. ProMéxico. 172pp. Disponible en: [https://www.gob.mx/cms ...](https://www.gob.mx/cms...), 2017.
- [4] M. González García, V. Cárdenas Galindo, and R. J. U. P. Álvarez Salas, "Inversores inteligentes en sistemas de energía solar fotovoltaica," vol. 16, no. 238, pp. 24-29, 2019.
- [5] L. A. Becerra-Pérez, R. R. González-Díaz, and A. C. J. R. Villegas-Gutiérrez, "La energía solar fotovoltaica, análisis costo beneficio de los proyectos en México," vol. 5, no. 2, 2021.
- [6] J. M. Enrique Gómez, *Diseño, modelado y optimización de sistemas de seguimiento del punto de máxima potencia de generadores fotovoltaicos mediante convertidores CC/CC*. 2011.
- [7] Y. A. Zúniga-Ventura, "Control del punto de máxima potencia en paneles solares bajo variaciones de radiación y temperatura," 2014.
- [8] O. Perpiñán Lamigueiro, *Energía Solar Fotovoltaica*. 2011.
- [9] E. E. Henao-Bravo, D. A. Márquez-Viloria, J. P. Villegas-Ceballos, S. I. Serna-Garcés, C. A. Ramos-Paja, and D. J. T. González-Montoya, "Modelo matemático de sistemas fotovoltaicos para búsqueda distribuida del punto de máxima potencia," vol. 19, no. 37, pp. 107-124, 2016.
- [10] E. L. Delgadillo, L. E. A. Miranda, F. d. J. R. Díaz, A. V. Rivera, V. U. M. Sánchez, and D. S. J. P. E. Jiménez, "IMPLEMENTACIÓN DE MODELOS DE PANELES SOLARES MEDIANTE VERILOGA (IMPLEMENTATION OF SOLAR PANEL MODELS THROUGH VERILOGA)," vol. 41, no. 134, 2019.
- [11] A. Gil Velazco, "Operación y Control de un Sistema Fotovoltaico Autónomo con Extracción de Máxima Energía y Mínimo Capacitor de Enlace," 2021.
- [12] J. A. Luna Arteaga, "Implementación de la técnica Perturbar y Observar para el seguimiento del punto de máxima potencia ante sombreado parcial," 2019.
- [13] B. Cortés, R. Tapia, and J. J. J. E. Flores, "System-Independent Irradiance Sensorless ANN-Based MPPT for Photovoltaic Systems in Electric Vehicles," vol. 14, no. 16, p. 4820, 2021.
- [14] S. Cuestas and L. J. A. e. E. R. y. M. A.-A. Lebus, "Diseño de un seguidor de punto máximo de potencia," pp. 37-42, 2011.
- [15] M. G. Molina, P. E. Mercado, and P. E. J. A. e. e. r. y. m. a. Wiernes, "Análisis y simulación de algoritmos de control para el seguimiento del punto de máxima potencia de sistemas solares fotovoltaicos conectados a la red eléctrica," vol. 11, 2007.
- [16] L. Ruiz, J. Beristáin, I. Sosa, and J. J. R. d. i. e. Hernández, electrónica y computación, "Estudio del algoritmo de seguimiento de punto de máxima potencia perturbar y observar," vol. 8, no. 1, pp. 17-23, 2010.
- [17] D. González Quintana, "Control inteligente del seguimiento del punto de máxima potencia (MPPT) de instalaciones fotovoltaicas conectadas a la red," Universidad Central" Marta Abreu" de Las Villas, Facultad de Ingeniería ..., 2019.

- [18] B. Subudhi and R. J. I. t. o. S. E. Pradhan, "A comparative study on maximum power point tracking techniques for photovoltaic power systems," vol. 4, no. 1, pp. 89-98, 2012.
- [19] M. Sarvi and A. J. E. S. Azadian, "A comprehensive review and classified comparison of MPPT algorithms in PV systems," vol. 13, no. 2, pp. 281-320, 2022.
- [20] H. Acevedo Meza, J. L. Mendoza García, and S. J. R. c. d. t. d. a. Sepúlveda Mora, "Estrategias de control mppt aplicadas en un convertidor dc/dc tipo boost para sistemas fotovoltaicos," vol. 2, no. 30 (2017), pp. 102-108, 2017.
- [21] J. R. Chantres Borges, "Comparación de algoritmos MPPT aplicados a sistemas fotovoltaicos," Universidad Central" Marta Abreu" de Las Villas, Facultad de Ingeniería ..., 2018.
- [22] C. Robles and G. J. T. Villa, "Control del punto de máxima potencia de un panel solar fotovoltaico, utilizando lógica difusa," vol. 10, no. 2, pp. 54-72, 2011.
- [23] L. Torres, G. L. Magaldi, G. R. Catuogno, and G. O. Garcia, "Implementación de Control Difuso para Optimización de Energía en Sistema Fotovoltaico," in *XVII Reun. Trab. en Proceso. la Inf. y Control*, 2017.
- [24] F. Berzal, "REDES NEURONALES & DEEP LEARNING," *Copyright © 2018 Fernando Berzal*, vol. Volumen 2 GRANADA 2018.
- [25] D. P. P. Cruz, "INTELIGENCIA ARTIFICIAL CON APLICACIONES A LA INGENIERÍA," *Alfaomega Grupo Editor, S.A. de C.V.*, vol. Primera edición, 2010.
- [26] E. Varela-Arregoces and E. J. I. y. D. e. T. Campbells, "Redes Neuronales Artificiales: una revisión del estado del arte, aplicaciones y tendencias futuras," vol. 2, no. 1, pp. 18-27, 2011.
- [27] K.-Y. Chou, C.-S. Yang, and Y.-P. Chen, "Deep Q-Network Based Global Maximum Power Point Tracking for Partially Shaded PV System," in *2020 IEEE International Conference on Consumer Electronics-Taiwan (ICCE-Taiwan)*, 2020, pp. 1-2: IEEE.
- [28] Y. B. Ian Goodfellow, Aaron Courville, "Deep Learning," *MIT Press*, vol. 1, pp. 203-205, 2016.
- [29] W. R. Cabana Hanco, "Algoritmo de redes neuronales artificiales para el seguimiento del punto de máxima potencia de un panel fotovoltaico," 2019.
- [30] S. Motahhir, A. El Hammoumi, and A. J. J. o. c. p. El Ghzizal, "The most used MPPT algorithms: Review and the suitable low-cost embedded board for each algorithm," vol. 246, p. 118983, 2020.
- [31] R. B. Koad, A. F. Zobia, and A. J. I. T. o. S. E. El-Shahat, "A novel MPPT algorithm based on particle swarm optimization for photovoltaic systems," vol. 8, no. 2, pp. 468-476, 2016.
- [32] A. Safari and S. J. I. t. o. i. e. Mekhilef, "Simulation and hardware implementation of incremental conductance MPPT with direct control method using cuk converter," vol. 58, no. 4, pp. 1154-1161, 2010.
- [33] J. E. Vera, J. F. Bayona, and R. S. J. V. e. Cayanza, "Seguimiento del punto de máxima potencia (SPMP) en paneles solares," vol. 8, no. 2, pp. 49-53, 2014.
- [34] J. López Seguel, S. Seleme Jr, and L. M. J. I.-R. C. d. I. Morais, "Comparison of the performance of MPPT methods applied in converters Buck and Buck-Boost for autonomous photovoltaic systems," vol. 29, no. 2, 2021.

- [35] M. Abdel-Salam, M.-T. El-Mohandes, and M. J. S. E. Goda, "An improved perturb-and-observe based MPPT method for PV systems under varying irradiation levels," vol. 171, pp. 547-561, 2018.
- [36] A. Gil-Velasco and C. J. E. Aguilar-Castillo, "A modification of the perturb and observe method to improve the energy harvesting of PV systems under partial shading conditions," vol. 14, no. 9, p. 2521, 2021.
- [37] R. X. Cuzco Sisa and D. G. Arcos Avilés, "Análisis comparativo del desempeño de algoritmos seguidores del punto de máxima potencia en sistemas fotovoltaicos."
- [38] L. Luque, V. Toranzos, and L. J. A. e. E. R. y. M. A.-A. Vera, "Uso eficiente de la energía en sistemas fotovoltaicos autónomos: desarrollo de un convertidor CC-CC con seguimiento de punto de máxima potencia," vol. 16, pp. 63-70, 2021.
- [39] J. D. Velez Sanchez, "Simulacion y evaluacion del control lineal y no lineal de un convertidor DC-DC para un sistema PV," 2015.
- [40] D. M. Cruz-Monsalve, L. D. Pabón-Fernández, E. A. Caicedo-Peñaranda, A. Pardo-García, and J. L. J. A. r. d. i. Díaz-Rodríguez, administración e ingeniería, "Prototipo de seguimiento de máximo punto de potencia (MPPT) de bajo costo," vol. 8, no. 2, pp. 98-106, 2020.
- [41] M. D. R. RIVERA ESPINOSA, "Diseño e implementación de un algoritmo para obtener el máximo punto de potencia en paneles solares," 2018.
- [42] I. Dagal, B. Akin, and E. J. S. R. Akboy, "MPPT mechanism based on novel hybrid particle swarm optimization and salp swarm optimization algorithm for battery charging through simulink," vol. 12, no. 1, p. 2664, 2022.
- [43] S. Mo, Q. Ye, K. Jiang, X. Mo, and G. J. E. R. Shen, "An improved MPPT method for photovoltaic systems based on mayfly optimization algorithm," vol. 8, pp. 141-150, 2022.
- [44] S. Srivastava, C. Lata, P. Lohan, and R. W. J. I. Mosobi, "Comparative Analysis of Particle Swarm Optimization and Artificial Neural Network Based MPPT with Variable Irradiance and Load," vol. 10, no. 3, pp. 460-465, 2022.
- [45] E. Neri-Rodríguez, M. Oliver-Salazar, and S. J. C. Ortiz-López, Morelos, México: CENIDET, "Comparación entre los algoritmos optimización por enjambre de partículas y perturbar y observar en un sistema fotovoltaico bajo condiciones de sombreado parcial," 2015.
- [46] S. Javed and K. Ishaque, "A comprehensive analyses with new findings of different PSO variants for MPPT problem under partial shading," *Ain Shams Engineering Journal*, vol. 13, no. 5, p. 101680, 2022/09/01/ 2022.
- [47] S. Rosas Romero, "Control Inteligente para el Seguimiento del Punto de Máxima Potencia (MPPT) en sistemas fotovoltaicos," 2022.
- [48] Y. Cui, Z. Yi, J. Duan, D. Shi, and Z. Wang, "A Rprop-neural-network-based PV maximum power point tracking algorithm with short-circuit current limitation," in *2019 IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT)*, 2019, pp. 1-5: IEEE.
- [49] G. Illana Gisbert, "Redes neuronales artificiales para el seguimiento del punto de máxima potencia de paneles solares integrados en vehículo eléctrico," 2021.
- [50] X. Meng, F. Gao, and T. Xu, "Optimized Design of Artificial Neural Network based Global MPPT for PV System under Partial Shading Conditions," in *2020 IEEE 9th*

- International Power Electronics and Motion Control Conference (IPEMC2020-ECCE Asia)*, 2020, pp. 1729-1733: IEEE.
- [51] R. Subha and S. Himavathi, "Neural network based maximum power point tracking scheme for PV systems operating under partially shaded conditions," in *2014 International Conference on Advances in Green Energy (ICAGE)*, 2014, pp. 39-43: IEEE.
- [52] B. J. E.-J. o. U. S. Dwinanto, "MPPT PV Modeling with ANN Using Matlab Simulink," vol. 2, no. 8, pp. 1.609-1.619, 2022.
- [53] J. Esperanza, G. Catuogno, F. Serra, and J. Bossio, "Estrategia de Seguimiento del Punto de Máxima Potencia en Condiciones de Sombreado Parcial con RNA."
- [54] A. Ballaji, R. Dash, V. Subburaj, J. R. Kalvakurthi, D. Swain, and S. C. J. I. A. Swain, "Design & development of MPPT using PSO with predefined search space based on fuzzy fokker planck solution," vol. 10, pp. 80764-80783, 2022.
- [55] M. A. Hafeez, A. Naeem, M. Akram, M. Y. Javed, A. B. Asghar, and Y. J. E. Wang, "A novel hybrid MPPT technique based on Harris hawk optimization (HHO) and perturb and observer (P&O) under partial and complex partial shading conditions," vol. 15, no. 15, p. 5550, 2022.
- [56] M. A. Sahnoun, H. M. R. Ugalde, J.-C. Carmona, and J. Gomand, "Maximum Power point Tracking Using P&O Control Optimized by a Neural Network Approach: A Good Compromise between Accuracy and Complexity," *Energy Procedia*, vol. 42, pp. 650-659, 2013/01/01/ 2013.
- [57] B. Babes, A. Boutaghane, N. J. N. C. Hamouda, and Applications, "A novel nature-inspired maximum power point tracking (MPPT) controller based on ACO-ANN algorithm for photovoltaic (PV) system fed arc welding machines," vol. 34, no. 1, pp. 299-317, 2022.
- [58] M. N. Ali, K. Mahmoud, M. Lehtonen, and M. M. J. S. Darwish, "Promising MPPT methods combining metaheuristic, fuzzy-logic and ANN techniques for grid-connected photovoltaic," vol. 21, no. 4, p. 1244, 2021.
- [59] S. R. Kiran, C. H. Basha, V. P. Singh, C. Dhanamjayulu, B. R. Prusty, and B. J. I. A. Khan, "Reduced simulative performance analysis of variable step size ANN based MPPT techniques for partially shaded solar PV systems," vol. 10, pp. 48875-48889, 2022.
- [60] M. Cervantes-Bobadilla, J. García-Morales, R. F. Escobar-Jiménez, J. A. Hernández-Pérez, J. F. Gómez-Aguilar, and V. H. Olivares-Peregrino, "Experimental implementation of a new control approach using an inverse neural network to on-demand hydrogen production," *Control Engineering Practice*, vol. 105, p. 104631, 2020/12/01/ 2020.

Anexo A. Hoja de datos del panel EPL32024



MÓDULO FOTOVOLTAICO
EPL33024

MÓDULO POLICRISTALINO
320-350 W / 72 Celdas / 5 Bus bars



Los módulos fotovoltaicos de EPCOM son fabricados solo con celdas grado A, con una alta eficiencia y garantía de 25 años de potencia.

CARACTERISTICAS

-  Celdas de 5 bus bars con una eficiencia hasta 19 %
-  Caja de control IP65 o IP67 con resistencia al agua para una larga durabilidad
-  Marco de aluminio de alta calidad, puede resistir carga hasta 5400 Pa y presión del viento hasta 2400 Pa
-  Vidrio templado de bajo hierro brindando alta transmisividad
-  Alto rendimiento en ambientes de poca luz
-  Doble prueba EL antes y después de laminación

25
AÑOS
GARANTÍA DE POTENCIA LINEAL

10
AÑOS
GARANTÍA DEL PRODUCTO

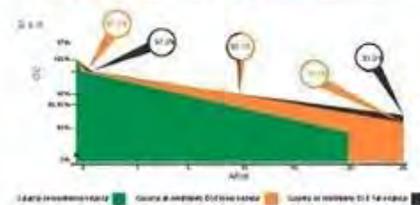
CERTIFICADOS

IEC 61215 / IEC 61730 / CE
ISO 9001:2015



GARANTÍA DE RENDIMIENTO LINEAL

10 años de garantía del producto - 25 años de garantía de potencia lineal



INFORMACIÓN ELÉCTRICA EN STC*

Potencia máxima (Pmax)	320 W	325 W	330 W	335 W	340 W	345 W	350 W
Tolerancia de potencia	0 +5 W						
Eficiencia del módulo	16,49 %	16,75 %	17,01 %	17,27 %	17,52 %	17,78 %	18,04 %
Máxima capacidad de voltaje (Vmp)	37,42 V	37,69 V	37,87 V	38,15 V	38,37 V	38,55 V	38,80 V
Máxima capacidad de corriente (Imp)	8,55 A	8,62 A	8,71 A	8,78 A	8,86 A	8,95 A	9,02 A
Voltaje de circuito abierto (Voc)	46,35 V	46,64 V	46,79 V	46,32 V	46,55 V	46,70 V	46,92 V
Corriente de cortocircuito (Isc)	9,07 A	9,12 A	9,16 A	9,16 A	9,24 A	9,31 A	9,40 A

*Condiciones Estándar de Medida: Radiación: 1000 W/m² · Temperatura de las celdas: 25°C · AM: 1,5

INFORMACIÓN ELÉCTRICA EN NOCT*

Potencia máxima de salida (Pmax)	236,73 W	240,43 W	244,13 W	248,00 W	251,53 W	255,23 W	258,92 W
Capacidad máxima de voltaje (Vmp)	34,56 V	34,81 V	34,98 V	35,52 V	35,44 V	35,60 V	35,84 V
Capacidad máxima de corriente (Imp)	6,84 A	6,90 A	6,97 A	6,78 A	7,00 A	7,16 A	7,22 A
Voltaje de Circuito Abierto (Voc)	43,03 V	43,29 V	46,79 V	42,78 V	43,21 V	43,35 V	43,55 V
Corriente de cortocircuito (Isc)	7,36 A	7,40 A	7,45 A	7,44 A	7,50 A	7,56 A	7,63 A

*Temperatura Nominal de Operación de la Celda: Irradiación: 800W/m² · Temperatura ambiente: 20°C · AM: 1,5 · Velocidad del viento: 1 m/s

CARACTERÍSTICAS DE TEMPERATURA

NOCT	45 °C ±2 °C
Coefficiente de temperatura de Pmax	-0,41%/°C
Coefficiente de temperatura de Voc	-0,31%/°C
Coefficiente de temperatura de Isc	+0,06%/°C

RANGO MÁXIMO

Rango de temperatura de operación	-45 °C ~ +85 °C
Máximo voltaje del sistema	1500 V
Rango máximo de capacidad del fusible	15 A
Máxima carga frontal (ejem. nieve)	5 400 Pa
Máxima carga posterior (ejem. viento)	2 400 Pa

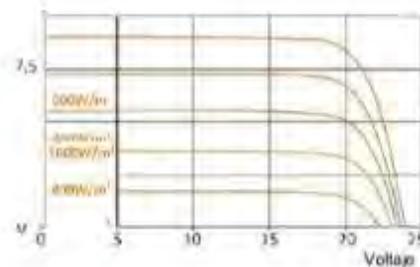
CARACTERÍSTICAS MECÁNICAS

Tipo de celdas	Polisilicio (156x156 mm)
Número de celdas	72
Dimensiones	1956x992x40 mm
Peso	22,8 kg
Vidrio	3,2 mm vidrio templado
Marco	Aleación de aluminio anodizado
Caja de control	IP65 o IP67
Cable	0,9 m
Conector	MC4 o MC4 compatible

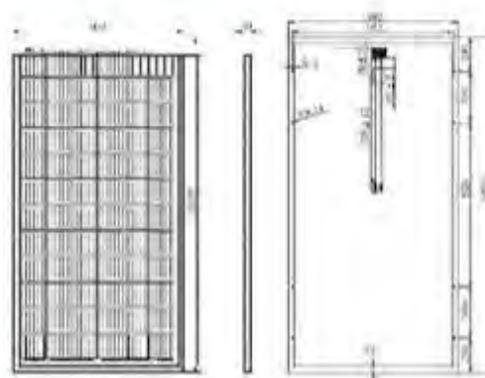
EMBALAJE

Tipo	Pzas	Peso
Paketa	26 pzas	620 kg
Contenedor 20GP	300 pzas	7,6 t
Contenedor 40GP	640 pzas	15,4 t
Contenedor 40HQ	696 pzas	16,2 t

CURVA I-V



DISEÑO DE INGENIERÍA



NOTA: Para uso de sistemas de interconexión con la red eléctrica y sistemas aislados.