



UNIVERSIDAD DE GUANAJUATO

CAMPUS IRAPUATO-SALAMANCA
DIVISIÓN DE INGENIERÍAS

*Sistema de Identificación de Parámetros
Operativos en Celdas Fotovoltaicas Mediante
Métodos de Optimización Metaheurísticos*

TESIS

QUE PARA OBTENER EL GRADO DE:

Maestro en Ingeniería Eléctrica

PRESENTA:

Ing. Alan Ortega González

DIRECTOR:

Dr. Juan Gabriel Aviña Cervantes

CODIRECTOR:

M.I. José Maurilio Raya Armenta

Salamanca, Gto.

Mayo, 2021

Resumen

En la actualidad, uno de los principales problemas que aquejan al ser humano son prioritariamente los sistemas relacionados con la salud, la agricultura, la conservación del medio ambiente y el uso eficiente de la energía. Las energías renovables tienen un papel fundamental y probablemente será la energía principal del futuro. La tecnología fotovoltaica puede cosechar energía de la luz solar y aparentemente parece ser una fuente inagotable de energía. En este sentido los modelos fotovoltaicos son de gran importancia en el diseño de sistemas eléctricos de potencia cuyos procesos de estudio requieren de adecuados métodos de optimización. El presente proyecto de tesis trata sobre el análisis y determinación de los parámetros de un modelo fotovoltaico, comparando modernos y potentes algoritmos metaheurísticos de optimización (en nuestro caso: Teaching Learning Based optimization, Particle Swarm Optimization y Differential Evolution). Las curvas de corriente contra voltaje I-V utilizadas en este estudio corresponden al módulo fotovoltaico M-60 Monocrystalline. Dicho módulo se analiza mediante el cálculo de los 5 parámetros utilizando el modelo del diodo único para diferentes condiciones de irradiación y temperatura del panel solar.

Las principales características analizadas para cada algoritmo mediante el error cuadrático medio son: el mejor, el promedio, el peor valor y la desviación estándar para un número determinado de repeticiones. Además, se comparan los modelos de optimización en tiempo de convergencia, exactitud y número de iteraciones. Complementariamente, se calculan los puntos de máxima potencia (MPP) para cada curva, y se realiza una interpolación a la base de datos experimental para determinar los parámetros a diferentes niveles de irradiación y temperatura.

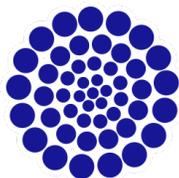
Agradecimientos institucionales

A la Universidad de Guanajuato por la formación académica a lo largo de mi trayectoria estudiantil que inició con el bachillerato y está presente en mis estudios de posgrado. En especial a la División de Ingenierías del Campus Irapuato-Salamanca (DICIS) de la cual soy parte de la comunidad estudiantil.



UNIVERSIDAD DE
GUANAJUATO

Un especial agradecimiento al Consejo Nacional de Ciencia y Tecnología (CONACyT) y al gobierno federal por el apoyo económico mediante la asignación de la beca con registro 957701.



CONACYT

Consejo Nacional de Ciencia y Tecnología

Agradecimientos personales

Especial agradecimiento a mi familia, por su apoyo constante en esta etapa académica en la cual estuvieron siempre presentes.

Al Dr. Mario Ibarra Manzano por el apoyo recibido durante mi participación en congresos nacionales.

A mis asesores académicos, Dr. Juan Gabriel Aviña Cervantes y M.I. José Maurilio Raya Armenta por brindar su apoyo y conocimientos que contribuyeron a la realización de mi trabajo de tesis de grado para maestría.

De igual manera, me gustaría agradecer a mis compañeros de posgrado Uriel Robles Cervantes y Reyna Pernía Perez, a quienes tuve el placer de conocer, deseándoles el mejor de los éxitos en su vida profesional.

Al mismo tiempo, a todos mis amigos que estuvieron presentes durante mi trayectoria académica, y en memoria especial a Eduardo Anguiano Cuéllar, estudiante de DICIS el cual perdió la vida en marzo del 2019, por su apoyo incondicional a quien tuve la fortuna de conocer.

Dedicatoria

Dedico esta tesis especialmente a mis queridos padres: **Sra. Leticia González Morales y Sr. Julián Ortega Pichardo** por su apoyo incondicional durante mi formación académica que aun esta en proceso de crecimiento, y donde espero me sigan apoyando para seguir brindándoles satisfacciones.

Índice general

1. Introducción	1
1.1. Objetivo General	1
1.2. Objetivos Específicos	1
1.3. Justificación	2
1.4. Estado del arte	3
1.5. Estructura de la tesis	6
2. Métodos de optimización	7
2.1. Introducción	7
2.2. Optimización por enjambre de partículas (PSO)	9
2.2.1. Global Best PSO	12
2.2.2. Local Best PSO	13
2.3. Optimización Basada en Enseñanza-Aprendizaje (TLBO)	16
2.3.1. Fase de profesor	16
2.3.2. Fase de aprendizaje	18
2.4. Evolución diferencial (DE)	19

2.4.1. Mutación	19
2.4.2. Recombinación	22
2.4.3. Selección	23
3. Metodología	26
3.1. Funciones de referencia	26
3.2. Modelo del panel fotovoltaico	27
3.2.1. Modelo de diodo único	29
3.2.2. Modelo del panel fotovoltaico (PV-Array)	32
3.2.3. Curvas características	33
3.2.4. Punto de Máxima Potencia MPP	34
3.3. Formulación del problema de optimización	36
3.3.1. Función de Aptitud (Fitness)	36
3.3.2. Interpolación	37
4. Resultados numéricos	43
4.1. Validación	43
4.2. Cálculo de parámetros y RMSE	49
4.2.1. Análisis RMSE a diferente valor de irradiancia	50
4.2.2. Evaluación de algoritmos a distintos valores de irradiancia.	56
4.2.3. Estimación de parámetros a diferente valor de irradiancia.	58
4.2.4. Análisis RMSE a diferente valor de temperatura	58
4.2.5. Evaluación de algoritmos a distintos valores de temperatura.	65

4.2.6. Estimación de parámetros a diferente valor de temperatura.	65
4.2.7. Curvas de corriente y potencia contra voltaje.	68
4.2.8. Valores del Punto de Máxima Potencia	71
4.2.9. Interpolación	73
4.3. Discusión	75
5. Conclusión	77
Referencias Bibliográficas.	82

Índice de figuras

1.1. Radiación solar media diaria en México [Smartbitt, 2021].	4
2.1. Máximo global en la función esfera invertida.	8
2.2. Cardumen de peces en su estructura como enjambre de partículas [Posidoniaecosports, 2021].	10
2.3. Movimiento de partículas en el proceso de optimización visto vectorialmente [Ishaque et al., 2012]	11
2.4. Diagrama a bloques del algoritmo PSO	12
2.5. Diagrama de flujo del algoritmo TLBO.	20
2.6. Diagrama de bloques del algoritmo de Evolución Diferencial.	22
3.1. Funciones de prueba para validación de algoritmos de optimización.	29
3.2. Circuito equivalente de una celda fotovoltaica.	30
3.3. Circuito equivalente PV-array.	32
3.4. Curvas típicas de corriente, potencia y voltaje de una celda fotovoltaica convencional [Ruiz C et al., 2010].	33
3.5. Diagrama de flujo del algoritmo Perturbar y Observar.	35
3.6. Diagrama a bloques de la metodología	36

3.7. Curvas características <i>IV</i> Modulo M-60 Monocrystalline [Tongwei Solar (Hefei) Co., Ltd, 2021].	41
4.1. Módulo M-60 Monocrystalline [Tongwei Solar (Hefei) Co., Ltd, 2021].	49
4.2. Gráficas RMSE, tiempo y error absoluto $G = 1000 W/m^2$, $T = 25^\circ C$, $AM = 1.5$	51
4.3. Gráficas RMSE, tiempo y error absoluto $G = 800 W/m^2$, $T = 25^\circ C$, $AM = 1.5$	53
4.4. Gráficas RMSE, tiempo y error absoluto $G = 600 W/m^2$, $T = 25^\circ C$, $AM = 1.5$	54
4.5. Gráficas RMSE, tiempo y error absoluto $G = 400 W/m^2$, $T = 25^\circ C$, $AM = 1.5$	55
4.6. Gráficas RMSE, tiempo y error absoluto $G = 200 W/m^2$, $T = 25^\circ C$, $AM = 1.5$	56
4.7. Gráficas RMSE, tiempo y error absoluto $T = 0^\circ C$, $G = 1000 W/m^2$, $AM = 1.5$	60
4.8. Gráficas RMSE, tiempo y error absoluto $T = 20^\circ C$, $G = 1000 W/m^2$, $AM = 1.5$	61
4.9. Gráficas RMSE, tiempo y error absoluto $T = 40^\circ C$, $G = 1000 W/m^2$, $AM = 1.5$	62
4.10. Gráficas RMSE, tiempo y error absoluto $T = 60^\circ C$, $G = 1000 W/m^2$, $AM = 1.5$	63
4.11. Gráficas RMSE, tiempo y error absoluto $T = 80^\circ C$, $G = 1000 W/m^2$, $AM = 1.5$	64
4.12. Curvas <i>IV</i> Modulo M-60 Monocrystalline [Tongwei Solar (Hefei) Co., Ltd, 2021].	68
4.13. Curvas características obtenidas con el algoritmo GPSO.	69

4.14. Curvas características obtenidas con el algoritmo TLBO.	70
4.15. Curvas características obtenidas con el algoritmo LPSO.	71
4.16. Curvas características obtenidas con el algoritmo DE.	72
4.17. Interpolación obtenidas con el algoritmo DE.	74

Índice de tablas

3.1. Funciones de referencia para evaluación de algoritmos de optimización	28
3.2. Condiciones de interpolación $G = 500W/m^2, T = 50^\circ C$	39
4.1. Factores de ajuste para los algoritmos de optimización	44
4.2. Resultados obtenidos por el método de optimización GPSO para las funciones de referencia seleccionadas.	45
4.3. Resultados obtenidos por el método de optimización TLBO para las funciones de referencia.	46
4.4. Resultados obtenidos por el método de optimización LPSO para las funciones de referencia.	47
4.5. Resultados obtenidos por el método de optimización DE para las funciones de referencia.	48
4.6. Rango valores aceptables para cada parámetro de los algoritmos.	50
4.7. RMSE y desviación estándar para diferente nivel de irradiancia	57
4.8. Estimación de parámetros a diferente irradiación	59
4.9. RMSE y desviación estándar para diferente nivel de temperatura	66
4.10. Estimación de parámetros a diferente temperatura	67

4.11. Voltaje MPP a diferentes valores de irradiancia	73
4.12. Voltaje MPP a diferentes niveles de temperatura	73
4.13. Estimación de parámetros a diferente temperatura con irradiancia $G=700$ W/m^2	74

Capítulo 1

Introducción

1.1. Objetivo General

Determinación de los cinco parámetros de un modelo fotovoltaico del modelo de diodo único mediante métodos metaheurísticos de optimización y evaluar una comparación de desempeño entre los métodos propuestos. Además, obtener las curvas de corriente contra voltaje $I-V$ para el panel solar M-60 Monocrystalline a diferentes niveles de irradiancia y temperatura. En este proceso, se propone una técnica de interpolación con el fin de obtener una base de datos en cualquier condición de irradiancia y temperatura del panel para calcular la evolución de los parámetros dentro del rango de operación del panel fotovoltaico.

1.2. Objetivos Específicos

- Implementar los métodos de optimización modernos: Teaching learning based optimization, Particle swarm optimization y Differential evolution.
- Determinar los cinco parámetros en un panel fotovoltaico usando un modelo de diodo único para diferentes niveles de irradiancia y temperatura para los métodos de optimización seleccionados.

1.3 Justificación

- Hacer una comparación de tiempo de ejecución, exactitud y precisión entre los modelos de optimización propuestos y seleccionar el más adecuado para el problema eléctrico.
- Determinar los puntos de máxima transferencia de potencia (MPP) en cada modelo y curva obtenida.
- Proponer un modelo de interpolación para calcular los parámetros de la celda fotovoltaica a diferentes niveles de irradiancia y temperatura.

1.3. Justificación

El cambio climático, la contaminación ambiental y el agotamiento de combustibles fósiles son desafíos cruciales que resaltan la importancia del uso de fuentes de energía renovables. Las energías renovables, y en particular la energía solar, son la única solución clara a la contaminación ambiental que se produce a partir del uso de combustibles fósiles. La energía solar es ampliamente disponible y es sin duda la mejor opción para proporcionar electricidad a los países y áreas remotas, porque a nivel de la evolución humana el sol brillará en la Tierra por bastante tiempo.

En este sentido, el suministro de energía renovable mediante redes de sistemas fotovoltaicos deben ser debidamente modelados, con el objetivo de que su integración en la red eléctrica se pueda realizar correctamente. Esto se puede realizar mediante la determinación óptima de los parámetros de los modelos matemáticos que rigen los módulos de transformación de energía solar a eléctrica. Mismo si en estos momentos, los sistemas fotovoltaicos son poco eficientes y de fabricación compleja; su instalación, modelado y control es menos demandante que otros sistemas generadores de energía. Esto permite enfocar los esfuerzos en la determinación de los parámetros dinámicos del panel fotovoltaico y de la configuración utilizada.

La exactitud en la caracterización de los modelos fotovoltaicos depende principalmente la determinación precisa de los parámetros de su modelo que generalmente no están disponibles y que pueden variar debido al envejecimiento y las fallas. Además, los parámetros del modelo también cambian con las condiciones de funcionamiento en campo (afectado

1.4 Estado del arte

principalmente por la irradiancia y temperatura) del dispositivo fotovoltaico. La mayoría de las hojas de datos de los fabricantes no brindan suficiente información sobre los parámetros dependientes de las condiciones climáticas, en este sentido la determinación precisa de los parámetros del panel permitirá diseñar una transferencia óptima de energía entre los sistemas de generación y distribución.

En la literatura existen diversos mecanismos de análisis, sin embargo, en esta tesis se propone utilizar técnicas de optimización metaheurísticas en la determinación automática de los parámetros de un sistema fotovoltaico con el objetivo de obtener en cualquier momento, la máxima transferencia de potencia y en cualquier condición de irradiancia y temperatura del panel.

1.4. Estado del arte

La radiación solar es la energía emitida por la superficie del sol. La onda de radiación térmica incidente sobre la superficie terrestre tiene tres características generales:

1. la escasa intensidad, dado que presenta un promedio de 1.0 KW/m^2 en el espectro AM1.5;
2. la intermitencia debido a la alternancia entre el día y la noche; y
3. la poca uniformidad ya que se concentra con mayor intensidad entre las latitudes de $\pm 30^\circ$ [Bernardelli, 2010].

La cantidad de radiación solar que llega a la superficie terrestre cada año corresponde a 160 veces la energía de las reservas mundiales de combustibles fósiles, y equivale a 15,000 veces el consumo anual de energía de fuente fósil [Bernardelli, 2010]. Las zonas con niveles de insolación anual superior a los 2500 kWh/m^2 que es aproximado 6.84 kWh/m^2 diarios, son muy eficientes para producir energía mediante paneles solares. Como se observa en la Figura 1.1, una de estas zonas comprende el desierto de Sonora en el norte de México. Alrededor de esta zona, se encuentran áreas con un nivel menor de radiación solar anual en el orden de 2000 kWh/m^2 resultando ser igual de eficientes [Bernardelli, 2010].

1.4 Estado del arte

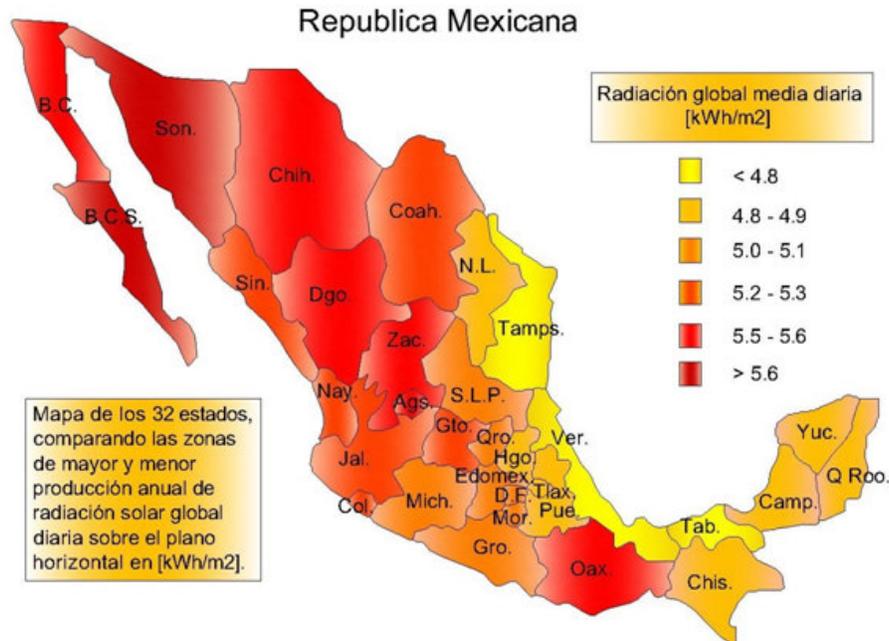


Figura 1.1: Radiación solar media diaria en México [Smartbitt, 2021].

En este tenor, la producción de energía fotovoltaica es tendencia mundial ya que muchos países desarrollados están tratando de aumentar la producción de energía mediante fuentes renovables como la luz solar con el fin de reducir la producción de gases de efecto invernadero [Pearce, 2002]. La tecnología de sistemas fotovoltaicos (PV) permite generar electricidad a partir de la energía de los rayos solares, además, desde la década de 1950 se han utilizado con éxito para obtener energía eléctrica [Metatla et al., 2013]. La baja contaminación al medio ambiente producida por el uso de esta tecnología incrementa el interés de producción de sistemas fotovoltaicos [Elnagi Mahmoud et al., 2018].

La potencia que entrega un panel fotovoltaico depende de varios factores como la intensidad de luz, temperatura de la celda, orientación del panel y condiciones atmosféricas. La radiación que recibe el panel solar afecta principalmente la cantidad de corriente producida por el panel, mientras que la temperatura de la celda afecta de manera más directa el voltaje producido por la celda. Los paneles fotovoltaicos son evaluados bajo condiciones de prueba estándar (STC¹). Sin embargo, en condiciones reales con variaciones de irradian-

¹ [kW/m²], 25[°C] a AM1.5.

1.4 Estado del arte

ción y temperatura de la celda, los paneles solares se comportan de manera diferente a la ideal. Por lo cual, el determinar los parámetros de un panel solar en condiciones reales de funcionamiento es necesario un diseño preciso y confiable. Los modelos de diodo único y de diodo doble se utilizan ampliamente, incluso se han implementado modelos con hasta tres diodos [Pandey and Sandhu, 2015]. De esta manera existen trabajos relacionados en determinar los 5 parámetros basándose únicamente en la información de la hoja de datos [Coelho and Castro, 2012]. Sin embargo, una representación precisa depende en gran medida en los parámetros del modelo que generalmente no están dados por el fabricante y cambian con el transcurso del tiempo, envejecimiento del panel, fallas, condiciones ambientales diferentes, entre otras [Yu et al., 2017].

Dentro de la literatura, existen contribuciones para la simulación, modelado y determinación de módulos fotovoltaicos en condiciones reales implementado en el entorno MATLAB [Bellia et al., 2014] donde los parámetros son calculados numéricamente basándose en la hoja de datos del fabricante. Además de trabajos relacionados a la predicción del comportamiento de los paneles fotovoltaicos mediante Redes Neuronales [Karamirad et al., 2013] donde la red neuronal se compara con modelos analíticos de cuatro y cinco parámetros del módulo fotovoltaico. En contraparte, para lograr una estimación precisa de los 5 parámetros PV del modelo de diodo único se ha planteado la utilización de técnicas con modelos metaheurísticos, con versiones mejoradas del algoritmo Teaching Learning Based Optimization (TLBO) [Yu et al., 2017], el algoritmo de evolución diferencial (DE) [Li et al., 2019] y el Particle Swarm Optimization (PSO) en versiones local y global [Engelbrecht, 2007]. La razón radica en que estos robustos algoritmos pueden converger a la solución incluso aunque la función de costo o el modelo no sea convexa ni continua. Sin embargo, estos estudios sobre los paneles solares están realizados bajo condiciones estándar (STC). En condiciones reales, como se muestra en [Aly et al., 2019], la realidad es otra. Los parámetros de las células fotovoltaicas dependen de la temperatura e irradiación. En este sentido el trabajo se centra en el análisis del desempeño de cuatro diferentes algoritmos metaheurísticos en diferentes condiciones de irradiación y temperatura de la celda.

1.5. Estructura de la tesis

Este trabajo está dividido en cinco capítulos, los cuales se describen brevemente a continuación.

El Capítulo 1 presenta los objetivos generales y específicos, la justificación de investigación propuesta y la revisión sintética del estado del arte.

El Capítulo 2 describe los algoritmos heurísticos utilizados y explica su implementación.

El Capítulo 3 formula la metodología de trabajo y detalla matemáticamente el problema de optimización.

El Capítulo 4 presenta los resultados obtenidos de las pruebas y su interpretación, además, se discute algún punto clave de convergencia y estabilidad de los métodos propuestos.

Finalmente, el Capítulo 5 ofrece las conclusiones generales de este trabajo.

Capítulo 2

Métodos de optimización

2.1. Introducción

La optimización matemática o también llamado programación matemática se considera como la selección de un mejor elemento, siguiendo las reglas de un criterio, a partir de las alternativas disponibles. En este sentido, un problema de optimización consiste en maximizar o minimizar una función real con el fin de conseguir un óptimo global, en otras palabras, encontrar los mejores valores disponibles de alguna función objetivo dado un dominio definido como se muestra en la Figura 2.1, la cual tiene como objetivo encontrar el máximo global, y puede ser representado de forma matemática de la siguiente manera [Baquela and Redchuk, 2013] ;

Definición 2.1.1 *Dada una función $f : \Omega \rightarrow \mathbb{R}$ de un conjunto Ω , se busca un elemento $\mathbf{x}_0 \in \Omega$, tal que $f(\mathbf{x}_0) \leq f(\mathbf{x})$ para todo $\mathbf{x} \in \Omega$ (“proceso de minimización”) o tal que $f(\mathbf{x}_0) \geq f(\mathbf{x})$ para todo $\mathbf{x} \in \Omega$ (“proceso maximización”).*

Existen algunas técnicas clásicas para resolver problemas de optimización con ciertas características específicas. Los primeros problemas de optimización fueron los de programación lineal, pero en ellos se requiere que todas las funciones sean combinaciones lineales de las variables de decisión del problema, en nuestro caso el problema involucra una función no lineal lo que implica que estos métodos no son una buena opción. Actualmente no se

2.1 Introducción

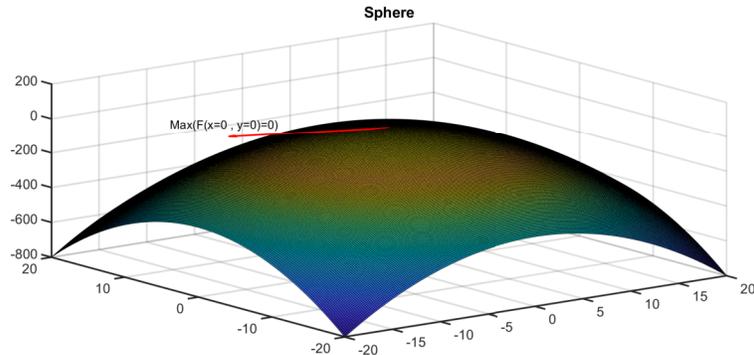


Figura 2.1: Máximo global en la función esfera invertida.

conoce un método que asegure encontrar el óptimo global de problemas no lineales de alta complejidad, dado que son basados en los cálculos del gradiente y la matriz Hessiana. El cálculo de estas derivadas es complejo e inestable en funciones discontinuas, no lineales, saturables o con gran cantidad de restricciones, por lo que los métodos metaheurísticos han sido usados para ayudar a resolver este tipo de problemas.

En particular, un método metaheurístico es usado comúnmente para resolver un tipo de problema de optimización general cuando los métodos tradicionales basados en gradientes y hessianas son inestables, discontinuos o cuyo modelo es altamente no lineal. Estos algoritmos son procesos iterativos que guían una heurística subordinada combinando de forma inteligente distintos conceptos de procesos estocásticos, en este sentido, exploran y explotan adecuadamente el espacio de búsqueda de soluciones. Normalmente, el nombre metaheurístico nace de la combinación con el prefijo griego “meta” (mas allá, en este sentido nivel superior) y palabra “heurístico” (encontrar) soluciones a problemas basados en el estudio y emulación de procesos naturales.

En nuestros días, hay un número enorme de variantes de métodos híbridos basados en algoritmos metaheurísticos, que han sido probadas en problemas específicos. Este es sin

2.2 Optimización por enjambre de partículas (PSO)

duda, un campo en investigación con un gran número de publicaciones en revista. En este sentido, es necesario realizar una introducción teórica de los métodos seleccionados para este trabajo de investigación, los cuales son explicados a continuación.

2.2. Optimización por enjambre de partículas (PSO)

La optimización por enjambre de partículas (Particle Swarm Optimization) es un método de optimización propuesto por Kennedy y Eberhart en 1995 [Kennedy and Eberhart, 1995]. Este método goza actualmente de alta popularidad por su versatilidad en la solución de problemas en ingeniería.

La inteligencia artificial asociada al de enjambre se basa en el comportamiento colectivo de sistemas descentralizados, auto organizado, natural o artificial. El algoritmo PSO sigue reglas muy simples donde no existe una estructura de control centralizada que dicte estrictamente como deben comportarse cada partícula, sino un comportamiento basado en una ley probabilística de desplazamiento. El comportamiento de cada partícula es local y, hasta cierto punto aleatorio, sin embargo, esto genera un comportamiento grupal inteligente que es desconocido para las partículas. Algunos ejemplos naturales bien conocidos que siguen un patrón de un sistema inteligente de enjambre de partículas incluyen las colonias de hormigas, parvadas de aves, rebaños de animales, crecimiento bacteriano y cardúmenes de peces [Yudong Zhang and Ji, 2015].

La Figura 2.2 muestra un cardumen de peces, donde se refleja un claro ejemplo de la inteligencia del enjambre de partículas. En este ejemplo se pone de manifiesto el comportamiento de un grupo de peces de similar tamaño y siguiendo una misma orientación y siguiendo a un líder general o en ocasiones líderes locales que retoman esa opción de liderazgo en determinados instantes de tiempo. Como un enjambre se puede decir que es un conjunto de peces, nadando en una alta sincronización y de manera polarizada.

Algorítmicamente, el PSO realiza búsquedas a través de enjambre de partículas que actualizan su posición relativa con respecto al líder de una generación a otra buscando una solución óptima (derivada de la posición actual del líder). Las partículas siguen un com-

2.2 Optimización por enjambre de partículas (PSO)

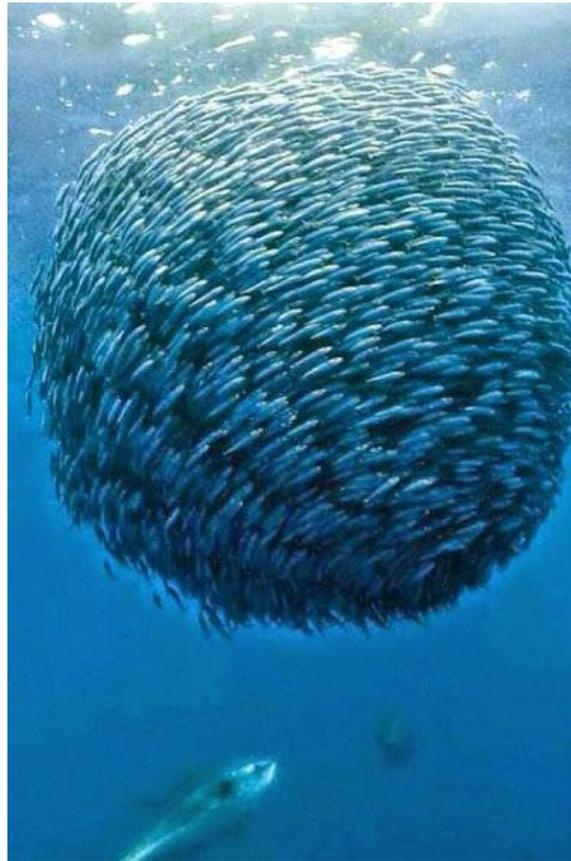


Figura 2.2: Cardumen de peces en su estructura como enjambre de partículas [Posidoniaecosports, 2021].

portamiento simple: emular el éxito de las partículas vecinas y los éxitos personales. La posición de cada partícula está relacionada directamente por la mejor partícula del vecindario (líder local) o mejor solución personal como también por la mejor solución encontrada por todas las partículas en todo el enjambre (líder general) [Ishaque et al., 2012]. Cuando una solución es encontrado el enjambre de partículas se hace más compacto y su movimiento tiende al reposo. Una representación vectorial del comportamiento de las partículas se observa en la Figura 2.3, donde se muestra que las partículas son guiadas por los líderes del enjambre, en este caso la mejor solución local y global las cuales pueden cambiar en el transcurso del tiempo. En analogía, un enjambre es similar a una población mientras que una partícula es similar a un individuo. El comportamiento iterativo del enjambre de partículas sigue estas reglas:

2.2 Optimización por enjambre de partículas (PSO)

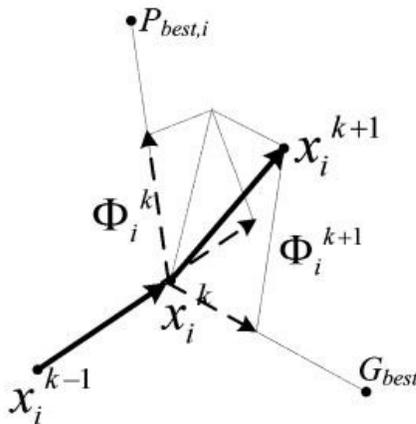


Figura 2.3: Movimiento de partículas en el proceso de optimización visto vectorialmente [Ishaque et al., 2012]

1. Sea $x_i(k)$ la posición de la partícula i en el espacio de búsqueda Ω durante en el instante de tiempo discreto k .
2. La posición de la partícula cambia por medio de una velocidad $v_i(k) = \Phi(k)$. La nueva posición viene entonces estimada por

$$\mathbf{x}_i(k+1) = \mathbf{x}_i(k) + \mathbf{v}_i(k+1) \quad (2.1)$$

3. El vector de velocidad $v_i(k)$ impulsa el proceso de optimización y refleja tanto el conocimiento, experiencia de la partícula e información socialmente intercambiada del vecindario.

El método PSO tiene varias versiones con diferencias mínimas en el algoritmo.

Los métodos implementados en este proyecto son el *Global Best PSO* y *Local Best PSO* [Engelbrecht, 2007], ambos describen el mismo proceso, mostrado en la Figura 2.4. El mecanismo básicamente consiste en crear el enjambre de partículas, determinar la aptitud de cada partícula, calcular la velocidad de las partículas, actualizar su posición, delimitar su posición manteniéndola en su rango de búsqueda y verificar la condición de paro, donde el algoritmo encontrará la solución satisfactoria. Las diferencias entre las dos versiones usadas radican en el cálculo del mejor local, que en ocasiones es también llamado mejor

2.2 Optimización por enjambre de partículas (PSO)

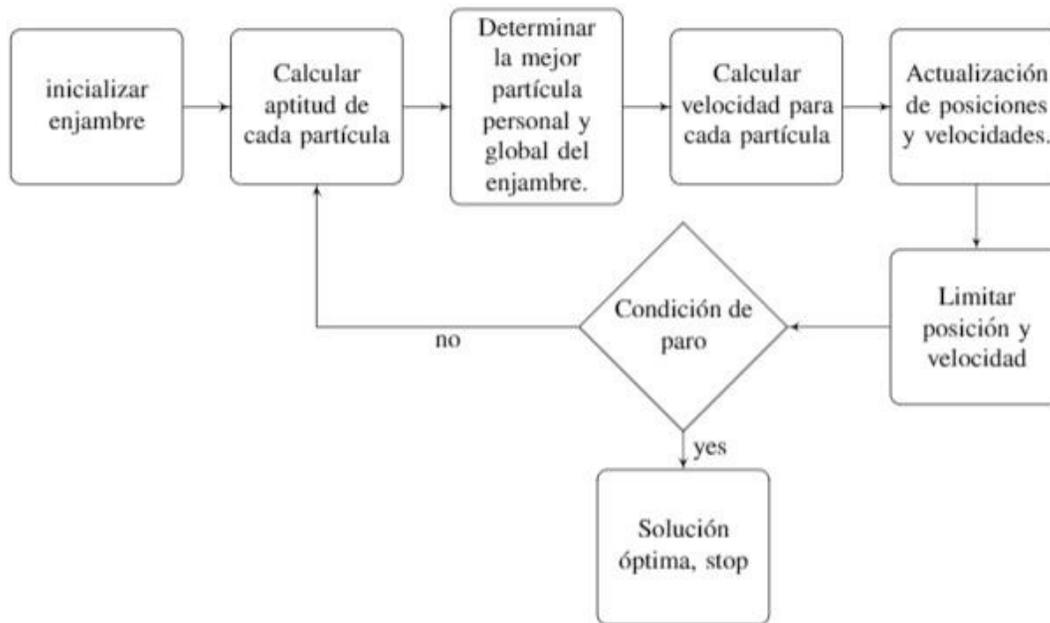


Figura 2.4: Diagrama a bloques del algoritmo PSO

personal por estar interactuando con los vecinos cercanos como se explica a continuación con más detalle.

2.2.1. Global Best PSO

La actualización de la velocidad de las partículas refleja la información obtenida de todas las partículas inter-actuantes en el enjambre. En este caso, la información social es la mejor solución encontrada por el enjambre, expresado como $\hat{y}(k)$.

Para el algoritmo *Gbest PSO*, la velocidad de la partícula i se calcula de la siguiente manera:

$$v_{ij}(k+1) = v_{ij}(k) + c_1 r_{1j}(k) [y_{ij}(k) - x_{ij}(k)] + c_2 r_{2j}(k) [\hat{y}_j(k) - x_{ij}(k)] \quad (2.2)$$

Donde, $v_{ij}(k)$ es la velocidad de la partícula i en la dimensión $j = 1, \dots, n_x$, en el transcurso del tiempo k , $x_{ij}(k)$ se refiere a la posición de la partícula i en la dimensión j ; así mismo, c_1 y c_2 son constantes de aceleración positivas utilizadas para escalar la contribución de los aspectos cognitivos y componentes sociales, respectivamente. Comúnmente, se establecen

2.2 Optimización por enjambre de partículas (PSO)

elementos que delimitan la relación entre estas dos constantes mediante:

$$c_1 + c_2 = 4. \quad (2.3)$$

La mejor posición personal y_i , asociada con la partícula i , es la mejor posición que la partícula ha tenido desde el inicio del proceso hasta este punto. Lo que modifica la mejor posición personal en la siguiente iteración $k + 1$,

$$\mathbf{y}_i(k+1) = \begin{cases} \mathbf{y}_i(k) & \text{si } f(\mathbf{x}_i(k+1)) \geq f(\mathbf{y}_i(k)) \\ \mathbf{x}_i(k+1) & \text{si } f(\mathbf{x}_i(k+1)) < f(\mathbf{y}_i(k)), \end{cases} \quad (2.4)$$

donde $f : \mathbb{R}^{n_x} \rightarrow \mathbb{R}$ es la función de aptitud (fitness), también llamada función de costo que hace el mapeo de un individuo de alta dimensionalidad a un escalar. La mejor posición global es la mejor solución que existe dentro de todo el enjambre $\hat{\mathbf{y}}(t)$, en el paso de tiempo k , como se muestra en la Ec. (2.5),

$$\hat{\mathbf{y}}(t) \in \{\mathbf{y}_0(k), \dots, \mathbf{y}_{n_s}(k)\} \mid f(\hat{\mathbf{y}}(k)) = \min \{f(\mathbf{y}_0(k)), \dots, f(\mathbf{y}_{n_s}(k))\}, \quad (2.5)$$

donde n_s es el número de partículas del enjambre. El método GLOBAL-BEST PSO (GPSO) se resume en el Algoritmo 1. Es importante tener en cuenta que para el Global Best PSO, las partículas dentro de un vecindario no tienen una relación directa ya que la partícula con mejor aptitud dentro del enjambre y la mejor solución personal de la partícula, determinarán el movimiento de esta.

2.2.2. Local Best PSO

Al igual en que en *Global Best PSO*, el algoritmo *Local Best PSO* actualiza su enjambre con la Ec. (2.1). En este caso, para el mejor *local PSO*, o *lbest PSO*, se definen vecindarios más pequeños para cada partícula. El componente social refleja el intercambio de información dentro de un vecindario, reflejando el conocimiento local del medio ambiente. Con referencia a la ecuación de velocidad presentada anteriormente, la contribución social a la velocidad de la partícula es proporcional a la distancia entre una partícula y su vecino líder, tamaño de vecindario y la mejor

2.2 Optimización por enjambre de partículas (PSO)

Algorithm 1 GLOBAL-BEST PSO

```

1: procedure INITIALIZATION( $N, D$ )
2:   for  $j = 1$  to  $D$  do
3:      $\mathbf{x}_{ij} \leftarrow \text{rand}([\mathbf{x}_{ij}^{I_j}, \mathbf{x}_{ij}^{S_j}]) \in \mathbb{R}^D$  ▷ Límites Superior e Inferior
4:   end for
5:    $\mathbf{X} \leftarrow [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_i] \in \mathbb{R}^{N \times D}$  ▷ Inicialización del enjambre
6: end procedure
7: for  $k = 1$  to  $G$  do ▷ Bucle de generaciones
8:   for para cada partícula  $i = 1, \dots, n_s$  do
9:     If  $f(\mathbf{x}_i) < f(\mathbf{y}_i)$  then  $\mathbf{y}_i = \mathbf{x}_i$  end if ▷ Mejor posición personal
10:    If  $f(\mathbf{y}_i) < f(\hat{\mathbf{y}})$  then  $\hat{\mathbf{y}} = \mathbf{y}_i$  end if ▷ Mejor posición Global
11:  end for
12:  for para cada partícula  $t = 1, \dots, n_s$  do
13:     $v_i = v_i + c_1 r_{1i} [y_i - x_i] + c_2 r_{2i} [\hat{y} - x_i]$  ▷ Actualizar velocidad
14:     $\mathbf{x}_i = \mathbf{x}_i + \mathbf{v}_i$  ▷ Actualizar posición
15:  end for
16:  if (Criterio de paro) then BreakFor() end if ▷ Convergencia anticipada
17: end for

```

posición encontrada por el enjambre. La velocidad para el *Local Best PSO (LPSO)* se actualiza de la siguiente manera:

$$v_{ij}(k+1) = v_{ij}(k) + c_1 r_{1j}(k) [y_{ij}(k) - x_{ij}(k)] + c_2 r_{2j}(k) [\hat{y}_{ij}(k) - x_{ij}(k)], \quad (2.6)$$

donde \hat{y}_{ij} es la mejor posición encontrada por la vecindad de la partícula i en la dimensión j , es decir, la mejor posición encontrada en el vecindario \mathcal{N}_i . Esta vecindad es matemáticamente definida por

$$\hat{\mathbf{y}}_i(k+1) \in \{\mathcal{N}_i \mid f(\hat{\mathbf{y}}_i(k+1)) = \min\{f(\mathbf{x})\}, \quad \forall \mathbf{x} \in \mathcal{N}_i\} \quad (2.7)$$

Donde el vecindario es representado como:

$$\mathcal{N}_i = \{\mathbf{y}_{i-n_{\mathcal{N}_i}}(k), \mathbf{y}_{i-n_{\mathcal{N}_i}+1}(k), \dots, \mathbf{y}_{i-1}(k), \mathbf{y}_i(k), \mathbf{y}_{i+1}(k), \dots, \mathbf{y}_{i+n_{\mathcal{N}_i}}(k)\} \quad (2.8)$$

La mejor posición del enjambre y_{ij} se define igual que en *Global Best PSO (GPSO)* mostrada en la Ec. (2.5).

2.2 Optimización por enjambre de partículas (PSO)

El Local-BEST PSO (LPSO) es resumido en el Algoritmo 2. Las dos versiones de

Algorithm 2 Local-BEST PSO

```

1: procedure INITIALIZATION( $N, D$ )
2:   for  $j = 1$  to  $D$  do
3:      $\mathbf{x}_{ij} \leftarrow \text{rand}([\mathbf{x}_{ij}^{I_j}, \mathbf{x}_{ij}^{S_j}]) \in \mathbb{R}^D$  ▷ Límites Superior e Inferior
4:   end for
5:    $\mathbf{X} \leftarrow [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_i] \in \mathbb{R}^{N \times D}$  ▷ Inicialización del enjambre
6: end procedure
7: for  $k = 1$  to  $G$  do ▷ Bucle de generaciones
8:   for para cada partícula  $i = 1, \dots, n_s$  do
9:      $\mathcal{N}_i = \{\mathbf{y}_{i-n_{\mathcal{N}_i}}, \mathbf{y}_{i-n_{\mathcal{N}_i}+1}, \dots, \mathbf{y}_{i-1}, \mathbf{y}_i, \mathbf{y}_{i+1}, \dots, \mathbf{y}_{i+n_{\mathcal{N}_i}}\}$  ▷ Vecindario
10:     $\hat{\mathbf{y}}_i \in \{\mathcal{N}_i \mid f(\hat{\mathbf{y}}_i) = \min\{f(\mathbf{x})\}, \forall \mathbf{x} \in \mathcal{N}_i\}$  ▷ Mejor posición Local
11:    If  $f(\hat{\mathbf{y}}_i) < f(yBest)$  then
12:       $yBest = \hat{\mathbf{y}}_i$  ▷ Mejor posición Global
13:    end if
14:  end for
15:  for para cada partícula  $t = 1, \dots, n_s$  do
16:     $v_i = v_i + c_1 r_{1i} [yBest - x_i] + c_2 r_{2i} [\hat{\mathbf{y}}_j - x_i]$  ▷ Actualizar velocidad
17:     $\mathbf{x}_i = \mathbf{x}_i + \mathbf{v}_i$  ▷ Actualizar posición
18:  end for
19:  if (Criterio de paro) then BreakFor() end if ▷ Convergencia anticipada
20: end for

```

métodos basados en enjambre de partículas son ampliamente usados y comparados entre sí. Sin embargo, estos algoritmos como la mayoría tienen factores de ajuste, estos factores afectan el desempeño del algoritmo cuando no se realiza adecuadamente. Un método metaheurístico sin factores de ajuste es deseable ya que hace más práctico la experimentación; existen pocos bajo ese esquema, uno de ellos es presentado a continuación.

2.3. Optimización Basada en Enseñanza-Aprendizaje (TLBO)

El algoritmo de optimización basado en enseñanza aprendizaje (TLBO, Teaching Learning Based Optimization) es un algoritmo desarrollado por Rao [Rao et al., 2012b]. El método de optimización imita el proceso de aprendizaje que se da entre un el profesor y un alumno dentro de un aula de clase. En este método, un grupo de estudiantes (aprendices) es considerado una población y las variables de diseño son las asignaturas ofrecidas a los estudiantes. La población X se inicializa aleatoriamente mediante un espacio de búsqueda delimitado, el valor N representa el número de alumnos en una clase, es decir, grupo o tamaño de la población. El valor D representa el número de clases o cursos ofrecidos. El procedimiento de naturaleza estocástico es iterativo y está configurado para ejecutarse para el número máximo de iteraciones G (también llamado como generaciones).

El método de optimización TLBO se divide en dos partes, la primera parte consta de la Fase del profesor y la segunda parte consta de la Fase del aprendizaje. Durante la Fase o etapa del profesor, se tiene que aprender bajo la instrucción de un profesor y la Fase de aprendizaje significa aprender a través de la interacción entre los alumnos [Rao et al., 2012a].

2.3.1. Fase de profesor

La fase profesor es la primera parte del algoritmo. Los alumnos son guiados por el profesor, cuyo objetivo es incrementar el resultado medio de la clase en la asignatura que imparte. Generalmente, se considera al profesor como la persona más instruida de la sociedad, para el algoritmo la mejor solución evaluada dentro del grupo de estudiantes es considerado profesor. El propósito de un profesor es incrementar el nivel de conocimiento dentro de su grupo de clase, en la práctica. Sin embargo, no es posible incrementar el conocimiento entre sus estudiantes por igual ya que cada estudiante posee diferentes niveles de conocimiento y esto causa que cada estudiante aprenda a

2.3 Optimización Basada en Enseñanza-Aprendizaje (TLBO)

un ritmo diferente. Para saber el nivel de conocimiento del grupo es necesario hacer una medición del aprendizaje, la encuesta comúnmente son los exámenes donde se puede medir el conocimiento medio del grupo. Un profesor, después de enseñar mejorará este nivel medio de los estudiantes a un mejor valor promedio del conocimiento. En este sentido, cada estudiante del grupo X es representado matemáticamente como $X_{j,k,i}$, donde j es una variable de diseño representada físicamente por las materias cursadas (temas) $j = 1, 2, \dots, m$. Por otro lado, k representa el k -ésimo miembro de la población (es decir, cada alumno), $k = 1, 2, \dots, n$. Finalmente, i representa la i -ésima iteración, $i = 1, 2, \dots, G_{max}$, donde G_{max} es el número máximo de generaciones (iteraciones).

La fase del profesor comienza identificando al mejor alumno de la clase (es decir, la mejor solución), donde, $X_{k,i}$ es la mejor solución en cualquier iteración hasta ese momento i , donde el valor de $f(X_{k,i})$ es valor mínimo entre el grupo, generalmente representado como $X_{kbest,i}$. El siguiente paso es calcular el valor medio de aprendizaje de las asignaturas $M_{j,i}$, como se mencionó anteriormente, el profesor tiene como objetivo incrementar el resultado medio de la clase en la materia que imparte y el incremento será en función de la capacidad del grupo.

El aumento del resultado medio existente de cada asignatura por parte del profesor se considera definido matemáticamente por

$$DMean_{j,k,i} = r_{j,i}(X_{j,kbest,i} - T_F M_{j,i}) \quad (2.9)$$

Donde $X_{j,kbest,i}$ es el resultado del mejor alumno que se convertirá en el profesor, $r_{j,i}$ es un número aleatorio uniformemente distribuido en el rango de $[0, 1]$. Además, T_F es el factor de enseñanza que decide el valor de la media a cambiar y puede ser fijado en práctica a 1 ó 2, el valor de T_F se decide al azar con la siguiente probabilidad:

$$T_F = \text{round}[1 + (2 - 1) \cdot \text{rand}(0, 1)] \quad (2.10)$$

La solución existente se actualiza en la fase del profesor de acuerdo a la siguiente

2.3 Optimización Basada en Enseñanza-Aprendizaje (TLBO)

regla,

$$X'_{j,k,i} = X_{j,k,i} + \text{DMean}_{j,k,i}, \quad (2.11)$$

Donde $X'_{j,k,i}$ es el valor actualizado de $X_{j,k,i}$. $X'_{j,k,i}$ es aceptado si el error es menor que $X_{j,k,i}$ como se observa en la Ec. (2.12),

$$\mathbf{X}'_{j,k,i} = \begin{cases} X_{j,k,i} & \text{si } f(X_{j,k,i}) < f(X'_{j,k,i}) \\ X'_{j,k,i} & \text{si } f(X'_{j,k,i}) < f(X_{j,k,i}). \end{cases} \quad (2.12)$$

Todos los valores de función aceptados, se convierten en la entrada a la fase de aprendizaje.

2.3.2. Fase de aprendizaje

La fase de aprendizaje consiste en que los aprendices incrementen su conocimiento interactuando entre ellos, el objetivo es que un aprendiz interactúe al azar con otro para mejorar e incrementar su conocimiento. Considerando lo anterior, la forma en que el estudiante interactúe con otros en un grupo de tamaño n , y en cualquier iteración i , es que cada estudiante se compare con los demás al azar.

En el proceso de comparación, se selecciona aleatoriamente dos estudiantes P y Q de modo que $X'_{P,i} \neq X'_{Q,i}$ (donde $X'_{P,i}$ y $X'_{Q,i}$ son los valores actualizados al final de la fase del profesor). El proceso de aceptación es medido mediante un factor de aprendizaje dado por

$$\mathbf{X}''_{j,P,i} = \begin{cases} X'_{j,P,i} + r_{j,i} (X'_{j,P,i} - X'_{j,Q,i}) & \text{si } f(X'_{P,i}) < f(X'_{Q,i}) \\ X'_{j,P,i} + r_{j,i} (X'_{j,Q,i} - X'_{j,P,i}) & \text{si } f(X'_{Q,i}) < f(X'_{P,i}), \end{cases} \quad (2.13)$$

Donde $X''_{j,P,i}$ es aceptado si el aprendizaje es mejor que el actual. Todos los valores de función aceptados al final de la fase de aprendizaje se mantienen y estos valores se convierten en la entrada para la fase de profesor de la siguiente iteración.

2.4 Evolución diferencial (DE)

El método TLBO puede ser visualizado en el diagrama de la Figura 2.5 donde se identifican el proceso que se lleva a cabo en la fase de profesor y la fase de aprendizaje. Adicionalmente, el método TLBO es resumido en el Algoritmo 3. Como se mostró en esta sección, TLBO se caracteriza por no tener parámetros de ajuste. Esto hace que TLBO sea práctico en el sentido que no tiene que ser ajustado específicamente para cada problema. Sin embargo, el algoritmo es extenso y arduo en cuanto su programación comparada con GPSO causando que su tiempo de procesamiento pueda ser mayor y poco competitivo en aplicaciones tiempo real.

2.4. Evolución diferencial (DE)

La evolución diferencial es un algoritmo de optimización pequeño y simple basado de un proceso de evolución bio-inspirado y naturalmente complejo [Price and Price, 2015]. Además, DE es un algoritmo potente que forma parte de los algoritmos evolutivos o conocidos como evolución artificial, llamados así porque se basan en procesos típicos como la mutación, recombinación y la selección para desarrollar una colección de soluciones candidatas hacia un estado óptimo. Así, DE fue derivado de argumentos naturalmente matemáticos permitiendo una exploración pura y pragmática de la información sin restricciones. El algoritmo fue propuesto por primera vez en 1997 por Storn y Price y descrito con mayor detalle en [Price and Price, 2015], DE es simple pero efectivo y su estructura está basado en el diagrama mostrado en la Figura 2.6. En el diagrama DE se puede observar qué fundamento teórico del algoritmo muestra los tres operadores fundamentales en la implementación de todo algoritmo evolutivo, la Mutación, Recombinación y Selección. Estos tres procesos fundamentales son explicados a continuación.

2.4.1. Mutación

El primer paso para el algoritmo es la mutación, la mutación sirve para evitar la pérdida de diversidad, algorítmicamente está relacionado con el producto de bits que

2.4 Evolución diferencial (DE)

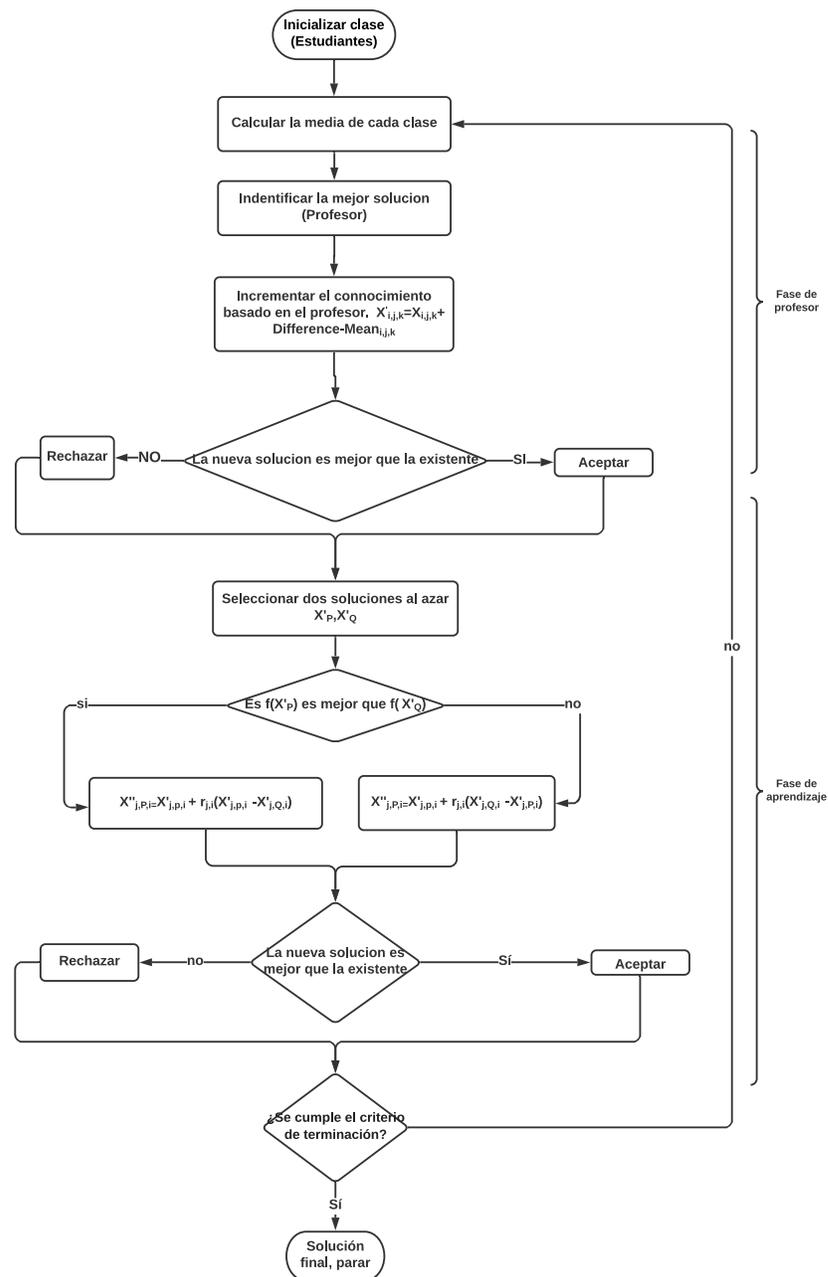


Figura 2.5: Diagrama de flujo del algoritmo TLBO.

han convergido a un cierto valor para toda la población, y que por tanto no pueden ser recuperados por el operador de recombinación. Para cada vector de parámetro,

2.4 Evolución diferencial (DE)

Algorithm 3 TLBO

```

1: procedure INITIALIZATION( $N, D$ )
2:   for  $j = 1$  to  $D$  do                                     ▷  $U(a, b) \sim rand[a, b]$ 
3:      $\mathbf{x}_{ij} \leftarrow rand([\mathbf{x}_{ij}^I, \mathbf{x}_{ij}^S]) \in \mathbb{R}^D$      ▷ Límites Superior e Inferior
4:   end for
5:    $\mathbf{X} \leftarrow [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_i] \in \mathbb{R}^{N \times D}$      ▷ Inicialización de estudiantes
6: end procedure
7: for  $k = 1$  to  $G$  do                                       ▷ Bucle de generaciones
8:   procedure TEACHER PHASE( $N, D, X^k$ )
9:      $f(XBest^k) = \min \{f(\mathbf{X}_0^k), \dots, f(\mathbf{X}_N^k)\}$      ▷ Mejor alumno
10:    for para cada estudiante  $i = 1, \dots, N$  do
11:       $DMean_i = r_i (XBest^k - T_{Fi}M)$                  ▷ Aumento de resultado medio
12:      if  $f(X_i^k + DMean_i) < f(X_i^k)$  then
13:         $X_i'^k = X_i^k + DMean_i$                        ▷ Actualización de conocimiento
14:      else  $X_i'^k = X_i^k$ 
15:      end if
16:    end for
17:  end procedure
18:  procedure LEARNER PHASE( $N, D, X'$ )
19:    for  $i=1$  to  $N$  do
20:       $XP_i^k \leftarrow X_i'^k$ 
21:       $XQ_i^k \leftarrow rand(X_i'^k), XQ_i^k \neq XP_i^k$ 
22:       $b_i \leftarrow rand(0, 1)$ 
23:      if  $f(XP_i^k) < f(XQ_i^k)$  then  $X_i^{k+1} = XP_i^k + b_i(XP_i^k - XQ_i^k)$ 
24:      else  $X_i^{k+1} = XP_i^k + b_i(XQ_i^k - XP_i^k)$      ▷ Valor medio del aprendizaje
25:      end if
26:    end for
27:  end procedure
28:  if (Criterio de paro) then BreakFor() end if     ▷ Convergencia anticipada
29: end for

```

se seleccionan otros tres vectores x_{r1n}^g, x_{r2n}^g y x_{r3n}^g al azar y se suma la diferencia ponderada de dos de los vectores al tercero.

2.4 Evolución diferencial (DE)

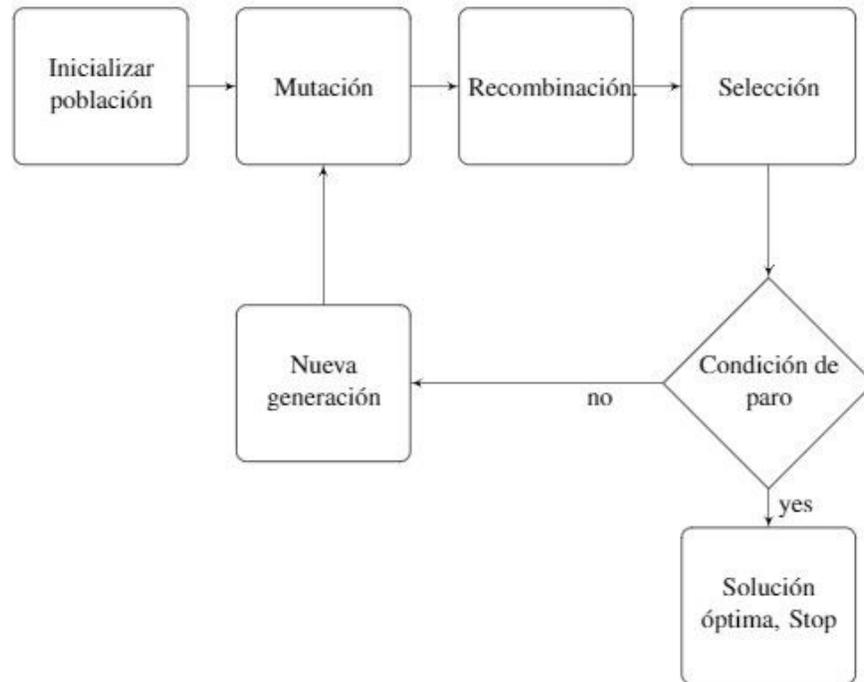


Figura 2.6: Diagrama de bloques del algoritmo de Evolución Diferencial.

Donde v_n^{g+1} es llamado el *Donor vector* (vector donante) y el factor de mutación F generalmente se toma entre 0 y 1.

$$v_n^{g+1} = x_{r1n}^g + F (x_{r2n}^g - x_{r3n}^g) \quad n = 1, 2, 3, \dots N \quad (2.14)$$

2.4.2. Recombinación

La recombinación es el principal operador genético, representa la reproducción sexual, opera sobre dos cromosomas a la vez para generar dos descendientes donde se combinan las características de ambos cromosomas padres.

Un vector de prueba $u_{n,i}^{g+1}$ se desarrolla a partir del vector objetivo o *elemento*

2.4 Evolución diferencial (DE)

poblacional, $x_{n,i}^g$, y el Donor vector, $v_{n,i}^{g+1}$

$$u_{n,i}^{g+1} = \begin{cases} v_{n,i}^{g+1} & \text{si } rand_i \leq C_p \text{ ó } i = I_{\text{rand}}, \quad i = 1, \dots, D, \\ x_{n,i}^g & \text{si } rand_i > C_p \text{ y } i \neq I_{\text{rand}} \quad n = 1, \dots, N \end{cases} \quad (2.15)$$

I_{rand} es un número entero aleatorio entre $[1, D]$, y C_p es la probabilidad de recombinación.

2.4.3. Selección

Después de saber la aptitud de cada cromosoma se procede a elegir los cromosomas que serán cruzados en la siguiente generación. Los individuos con mejor aptitud serán seleccionados. El vector objetivo x_n^g se compara con el vector de prueba $u_{n,i}^{g+1}$ y se selecciona el que tiene el valor de la función de costo más bajo (mejor *fitting*) para la siguiente generación.

$$x_n^{g+1} = \begin{cases} u_{n,i}^{g+1} & \text{si } f(u_n^{g+1}) < f(x_n^g) \\ x_n^g & \text{otro caso.} \end{cases} \quad (2.16)$$

Para todo $n = 1, 2, 3, \dots, N$. Todas las soluciones de la población tienen las mismas posibilidades de ser seleccionadas como progenitoras independientemente de su valor de aptitud. Si el padre es aún mejor, se retiene en la población.

El procedimiento iterativo puede finalizar cuando se cumple un cierto criterio de paro, que puede ser una solución aceptable con el mínimo error cuadrático. En casos especiales, no es fácil determinar si la solución es aceptable. En algunos trabajos, las iteraciones se terminan siempre que los resultados permanecen constantes durante un número fijo de generaciones (estancamiento) o se alcanza el número máximo de generaciones, lo que ocurra primero [Varadarajan and Swarup, 2008]. El método DE se resume en el Algoritmo 4.

Los métodos de optimización descritos en este capítulo comparten una similitud en su estructura fundamental, pero difieren en la conceptualización del modelo en el

2.4 Evolución diferencial (DE)

Algorithm 4 Método evolutivo diferencial

```

1: procedure INITIALIZATION( $N, D$ )
2:   for  $j = 1$  to  $D$  do ▷  $U(a, b) \sim rand[a, b]$ 
3:      $\mathbf{x}_{ij} \leftarrow rand([\mathbf{x}_{ij}^{I_j}, \mathbf{x}_{ij}^{S_j}]) \in \mathbb{R}^D$  ▷ Límites Superior e Inferior
4:   end for
5:    $\mathbf{X} \leftarrow [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_i] \in \mathbb{R}^{N \times D}$  ▷ Población inicial
6: end procedure
7: for  $k = 1$  to  $G$  do ▷ Bucle de generaciones
8:   procedure MUTATION( $N, D, F, \mathbf{x}_i$ ) ▷ Mutación
9:      $r_i \leftarrow Irand(Z) \mid Z \in \{1, 2, \dots, N\} \quad \forall i \in [1, 3]$ 
10:     $\mathbf{u}^{G+1} = \mathbf{x}r_1^G + F(\mathbf{x}r_2^G - \mathbf{x}r_3^G), \quad i \neq r_i \neq r_j \quad \forall i, j \in [1, N]$  ▷ Vector donante
11:  end procedure
12:  procedure CROSSOVER( $N, D, \mathbf{u}_i, \mathbf{x}_i$ ) ▷ Recombinación
13:     $I_{rand} \sim Irand(Z) \mid Z \in \{1, 2, \dots, D\}$  ▷  $Urand(a, b) \sim U[a, b]$ 
14:     $\mathbf{v}_{ij} \leftarrow \begin{cases} \mathbf{u}_{ij} & Urand_{ij} \leq CR \vee j == I_{rand} \\ \mathbf{x}_{ij} & Urand_{ij} \neq CR \wedge j \neq I_{rand} \end{cases} \quad i \in [1, N], j \in [1, D]$  ▷ Vectores
    de prueba
15:  end procedure
16:  procedure SELECTION( $N, D, \mathbf{v}_i, \mathbf{x}_i$ ) ▷ Mejores candidatos
17:    If  $f(\mathbf{v}_i) < f(\mathbf{x}_i)$  then  $\mathbf{x}_i = \mathbf{v}_i$  end if
18:  end procedure
19:  if (Stop Criteria) then BreakFor() end if ▷ Convergencia anticipada
20: end for

```

que se basan. Sin embargo, deben de compartir varias consideraciones generales de operación para poder ser comparadas objetivamente como son la condición de paro, número de iteraciones fijo, exactitud deseada y la función de aptitud (fitness). Estas partes son claves para poder evaluar el desempeño de los algoritmos, en este caso la condición de paro para este trabajo es igual para todos los algoritmos, consiste en completar como máximo 10000 generaciones (iteraciones) para cada algoritmo, la función aptitud que evalúa el desempeño de cada partícula y depende del problema de diseño a resolver. La metodología de diseño del problema de optimización, la

2.4 Evolución diferencial (DE)

aplicación de los algoritmos y la evaluación de su desempeño se presentan en el Capítulo 3.

Capítulo 3

Metodología

Para validar los cuatro métodos de optimización propuestos en este trabajo de tesis, se adoptó un conjunto de 20 funciones de prueba, seleccionados por su complejidad algorítmica. Además, se explica el punto principal de este trabajo de tesis el cual consiste en determinar los 5 parámetros fotovoltaicos basándose en el modelo del diodo único mediante algoritmos de optimización, esto puede llevarse a cabo mediante mediciones experimentales de voltaje y corriente en el panel fotovoltaico en condiciones de irradiancia y temperatura deseadas, también se explica el cálculo de los valores de voltaje en su punto de máxima potencia (MPP) y se propone un método de interpolación con el fin de estimar los parámetros en cualquier condición del panel. Dicho esto, este Capítulo aborda la metodología de trabajo y es explicado con más detalle como se muestra a continuación.

3.1. Funciones de referencia

Con el fin de dar validez a los métodos de optimización propuestos, los algoritmos se someten a pruebas de desempeño que consisten en encontrar los mínimos en las funciones convencionales de alta complejidad (*funciones benchmark*) [Wikipedia, 2020]. Este tipo de funciones presentan un gran reto para los algoritmos y nos permiten

3.2 Modelo del panel fotovoltaico

identificar y comparar el desempeño de los métodos propuestos.

Los algoritmos fueron evaluados con 20 funciones de prueba descritas brevemente, donde se mencionan sus rangos de búsqueda, su formulación matemática y sus mínimos globales teóricos, ver Tabla 3.1. Además, algunas funciones muestran expresiones trigonométricas y exponenciales con una gran cantidad de máximos y mínimos, otras son demasiado extensas y con rangos de búsqueda más amplios, en algunas de ellas tienen su mínimo en diferentes puntos como en la función de Himmelblau's (función 11). La Figura 3.1 muestra la función de prueba correspondiente a las funciones número 2, 8, 9, 14, 15, y 16 de la Tabla 3.1. En estas funciones representativas, se puede observar gráficamente una gran cantidad de mínimos locales. Esto hace que encontrar su mínimo de la función sea un problema más complejo por su descripción matemática.

En este sentido, la verificación de algoritmos con este tipo de funciones es bastante aceptado y de esta manera utilizar los mismos para preceder a calcular los parámetros propuestos del modelo de diseño. En nuestro caso el modelo de diseño determinará las variables que se obtendrán de los datos experimentales del panel fotovoltaico.

3.2. Modelo del panel fotovoltaico

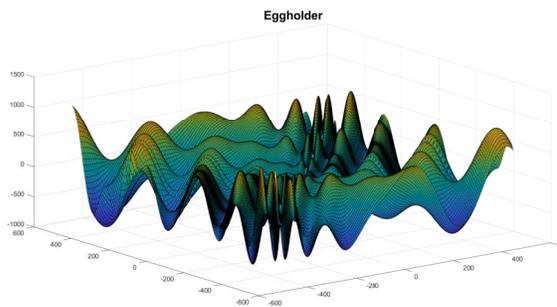
Existen diversos modelos matemáticos para representar un panel fotovoltaico, de entre los cuales, el modelo del diodo único es el más utilizado por su simplicidad y exactitud en el modelado del panel fotovoltaico. Dentro de esta sección se describe el modelo de diodo único, modelo PV-Array, las curvas características del panel fotovoltaico y el punto de máxima potencia (MPP).

3.2 Modelo del panel fotovoltaico

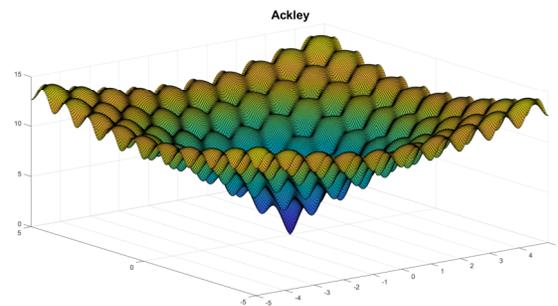
Tabla 3.1: Funciones de referencia para evaluación de algoritmos de optimización

No.	Nombre	Formula	Mínimo global	Dominio de búsqueda
F_1	Rastrigin function	$f(x) = An + \sum_{i=1}^n [x_i^2 - A \cos(2\pi x_i)]$ where: $A = 10$	$f(0, 0) = 0$	$-5.12 \leq x_i \leq 5.12$
F_2	Ackley function	$f(x, y) = -20 \exp \left\{ -0.2 \sqrt{0.5(x^2 + y^2)} \right\} - \exp \{0.5(\cos 2\pi x + \cos 2\pi y)\} + e + 20$	$f(0, 0) = 0$	$-5 \leq x_i \leq 5$
F_3	Sphere function	$f(x) = \sum_{i=1}^n x_i^2$	$f(0, 0) = 0$	$-5 \leq x_i \leq 5$
F_4	Rosenbrock function	$f(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (1 - x_i)^2]$	$f(1, 1) = 0$	$-\infty \leq x_i \leq \infty$
F_5	Beale function	$f(x, y) = (1.5 - x + xy)^2 + (2.25 - x + xy^2)^2 + (2.625 - x + xy^3)^2$	$f(3, 0.5) = 0 - 4.5$	$\leq x, y \leq 4.5$
F_6	Goldstein-Price function	$f(x, y) = [1 + (x + y + 1)^2(19 - 14x + 3x^2 - 14y + 6xy + 3y^2)] [30 + (2x - 3y)^2(18 - 32x + 12x^2 + 48y - 36xy + 27y^2)]$	$f(0, -1) = 3$	$-2 \leq x, y \leq 2$
F_7	Booth function	$f(x, y) = (x + 2y - 7)^2 + (2x + y - 5)^2$	$f(1, 3) = 0$	$-10 \leq x, y \leq 10$
F_8	Bukin function N.6	$f(x, y) = 100\sqrt{ y - 0.01x^2 } + 0.01 x + 10 $	$f(-10, 1) = 0$	$-15 \leq x \leq -5, -3 \leq y \leq 3$
F_9	Matyas function	$f(x, y) = 0.26(x^2 + y^2) - 0.48xy$	$f(0, 0) = 0$	$-10 \leq x, y \leq 10$
F_{10}	Lévi function N.13	$f(x, y) = \sin^2 3\pi x + (x - 1)^2(1 + \sin^2 3\pi y) + (y - 1)^2(1 + \sin^2 2\pi y)$	$f(1, 1) = 0$	$-10 \leq x, y \leq 10$
F_{11}	Himmelblau's function	$f(x, y) = (x^2 + y - 11)^2 + (x + y^2 - 7)^2$	$f(3.0, 2.0) = 0$ $f(-2.805118, 3.131312) = 0$ $f(-3.779310, -3.283186) = 0$ $f(3.584428, -1.848126) = 0$	$-5 \leq x, y \leq 5$
F_{12}	Three-hump camel function	$f(x, y) = 2x^2 - 1.05x^4 + \frac{1}{6}x^6 + xy + y^2$	$f(0, 0) = 0$	$-5 \leq x, y \leq 5$
F_{13}	Easom function	$f(x, y) = -\cos(x) \cos(y) \exp \{-(x - \pi)^2 + (y - \pi)^2\}$	$f(\pi, \pi) = -1$	$-100 \leq x, y \leq 100$
F_{14}	Cross-in-tray function	$f(x, y) = -0.0001 \left[\left \sin x \sin y \exp \left\{ \left 100 - \frac{\sqrt{x^2 + y^2}}{\pi} \right \right\} \right + 1 \right]^0 .1$	$f(\pm 1.34941, \pm 1.34941) = -2.06261$	$-10 \leq x, y \leq 10$
F_{15}	Eggholder function	$f(x, y) = -(y + 47) \sin \sqrt{\frac{x}{2} + (y + 47)} - x \sin \sqrt{ x - (y + 47) }$	$f(512, 404.2319) = -959.6407$	$-512 \leq x, y \leq 512$
F_{16}	Hölder table function	$f(x, y) = - \left \sin x \cos y \exp \left\{ \left 1 - \frac{\sqrt{x^2 + y^2}}{\pi} \right \right\} \right $	$f(\pm 8.05502, \pm 9.66459) = -19.2085$	$-10 \leq x, y \leq 10$
F_{17}	McCormick function	$f(x, y) = \sin(x + y) + (x - y)^2 - 1.5x + 2.5y + 1$	$f(-0.54719, -1.54719) = -1.9133$	$-1.5 \leq x \leq 4, -3 \leq y \leq 4$
F_{18}	Schaffer function N. 2	$f(x, y) = 0.5 + \frac{\sin^2(x^2 - y^2) - 0.5}{[1 + 0.001(x^2 + y^2)]^2}$	$f(0, 0) = 0$	$-100 \leq x, y \leq 100$
F_{19}	Schaffer function N. 4	$f(x, y) = 0.5 + \frac{\cos^2[\sin(x^2 - y^2)] - 0.5}{[1 + 0.001(x^2 + y^2)]^2}$	$f(0, \pm 1.25313) = 0.292579$	$-100 \leq x, y \leq 100$
F_{20}	Styblinski-Tang function	$f(x) = \frac{1}{2} \sum_{i=1}^n x_i^4 - 16x_i^2 + 5x_i$	$f(-2.903534, -2.903534) = -78.33232$	$-5 \leq x_i \leq 5, 1 \leq i \leq n$

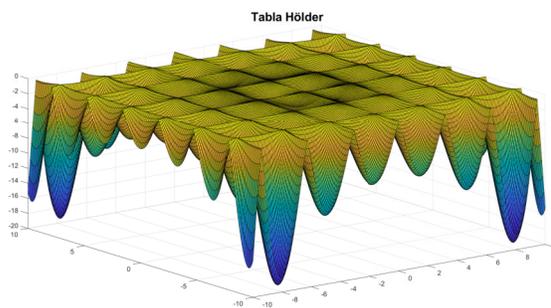
3.2 Modelo del panel fotovoltaico



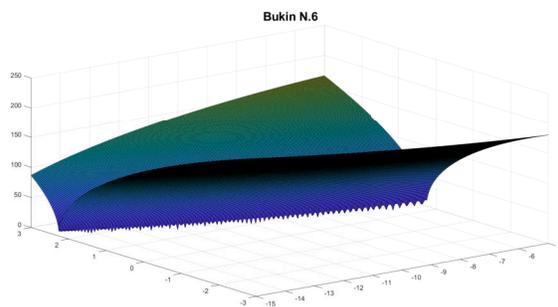
(a) Función de prueba Eggholder



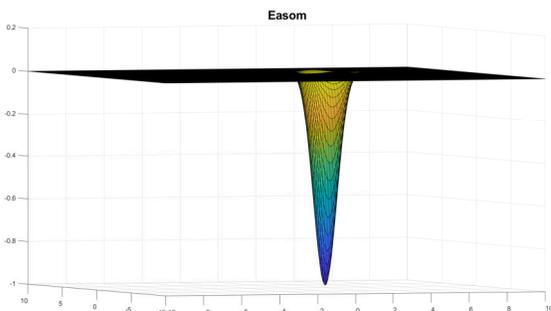
(b) Función de prueba Ackley



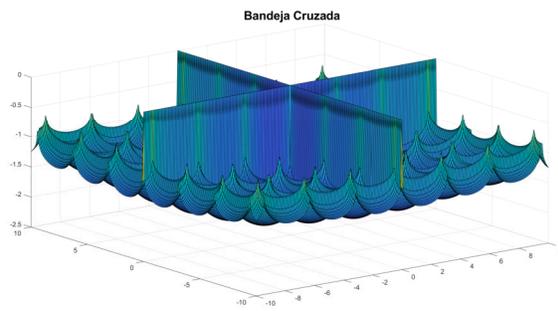
(c) Función de prueba Hölder



(d) Función de prueba Bukin No.6



(e) Función de prueba Easom



(f) Función de prueba Bandeja Cruzada

Figura 3.1: Funciones de prueba para validación de algoritmos de optimización.

3.2.1. Modelo de diodo único

El modelo matemático de una celda fotovoltaica toma como base la ecuación del diodo Shockley y las leyes de Kirchhoff de un circuito eléctrico. Una representación

3.2 Modelo del panel fotovoltaico

gráfica del modelo de diodo único se puede ver en la Figura 3.2. Esta figura muestra

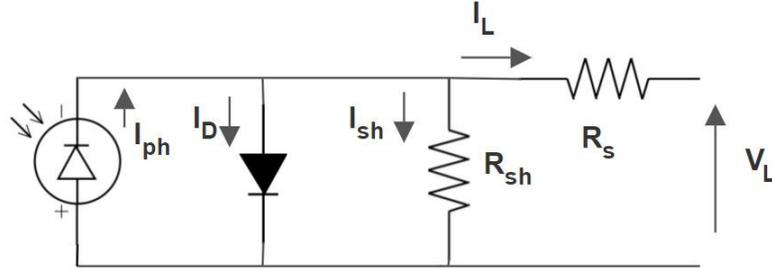


Figura 3.2: Circuito equivalente de una celda fotovoltaica.

el circuito eléctrico equivalente de una celda fotovoltaica de diodo único donde se observa una fuente de corriente I_{ph} , que representa la corriente generada por la radiación solar. La corriente del diodo I_D , donde el diodo representa la unión de *semiconductor p-n* que forma la celda. Dos resistencias, R_s en serie y R_{sh} en paralelo. R_s representa las pérdidas debidas a contactos y conexiones y R_{sh} tiene su origen en imperfecciones en la calidad de la unión *p-n* y es responsable de la existencia de fugas de corriente del diodo.

Basados en la Figura 3.2, la corriente de salida I_L es obtenida mediante las leyes de Kirchhoff dada matemáticamente por,

$$I_{L,cell} = I_{ph,cell} - I_{d,cell} - I_{sh,cell}, \quad (3.1)$$

Donde la corriente $I_{sh,cell}$ es la fuga en la resistencia en paralelo y se calcula como se muestra a continuación,

$$I_{sh,cell} = \frac{V_{sh,cell}}{R_{sh,cell}} = \frac{V_{d,cell}}{R_{sh,cell}}. \quad (3.2)$$

Usando la ley de voltajes de Kirchhoff, donde n_s son las celdas conectadas en serie y n_p las celdas conectadas en paralelo.

$$-V_{sh,cell} + \frac{I_L * R_{s,cell}}{n_p} + \frac{V_L}{n_s} = 0 \quad (3.3)$$

$$V_{sh,cell} = \frac{I_L * R_{s,cell}}{n_p} + \frac{V_L}{n_s} \quad (3.4)$$

3.2 Modelo del panel fotovoltaico

$$I_{sh,cell} = \frac{1}{R_{sh,cell}} \left(\frac{V_L}{n_s} + \frac{I_L * R_{s,cell}}{n_p} \right) \quad (3.5)$$

$I_{d,cell}$ es la corriente del diodo y es proporcional a la corriente de saturación, viene dada por la Ec. (3.7),

$$I_{d,cell} = I_{0,cell} \left[\exp \left(\frac{V_{d,cell}}{n} \right) - 1 \right] \quad (3.6)$$

$$I_{d,cell} = I_{0,cell} \left[\exp \left(\frac{1}{n} \left(\frac{V_L}{n_s} + \frac{I_L}{n_p} \cdot R_{s,cell} \right) \right) - 1 \right] \quad (3.7)$$

Donde n representa la tensión térmica, $I_{0,cell}$ es la saturación inversa, también llamada corriente de fuga del diodo. La tensión térmica n usualmente es calculada como :

$$n = AV_{T,cell} \quad (3.8)$$

$$V_{T,cell} = \frac{KT_c}{q} \quad (3.9)$$

Para el problema algorítmico, se describe las variables del modelo sintetizadas a continuación,

V_T : Es llamado voltaje térmico debido a su dependencia exclusiva de la temperatura

T_c : Es la temperatura real de la celda [K].

k : Es la constante de Boltzmann $1.381 \times 10^{-23} \frac{J}{K}$.

q : Es la carga del electrón $1,602 \times 10^{-19} C$

n_s : Es el número de células fotovoltaicas conectadas en serie.

n_p : Es el número de celadas conectadas en paralelo.

A : Es el factor de idealidad.

3.2 Modelo del panel fotovoltaico

En este aspecto, “ n ” se denomina como “factor de idealidad modificado” y se considera como un parámetro a determinar [Chouder et al., 2012]. Sustituyendo las Ecs. (3.5) y (3.7) y en la Ec. (3.1), obtenemos una ecuación no lineal que representa el comportamiento matemático de una celda usando un modelo de diodo único mostrados en la Ec. (3.10),

$$\frac{I_L}{n_p} = I_{ph,cell} - I_{0,cell} \left[\exp \left(\frac{V_L + \frac{I_L}{n_p} R_{s,cell}}{n V_{T,cell}} \right) - 1 \right] - \frac{1}{R_{sh,cell}} \left(\frac{V_L + \frac{I_L}{n_p} R_{s,cell}}{n_s} \right). \quad (3.10)$$

Este modelo se puede interconectar en diversas configuraciones para formar una red más compleja denominado un arreglo (PV) o panel fotovoltaico.

3.2.2. Modelo del panel fotovoltaico (PV-Array)

El modelo PV-array es un grupo de celdas conectadas en serie y paralelo [Elnagi Mahmoud et al., 2018]. El circuito equivalente puede ser observado en la Figura 3.3. Este arreglo es descrito matemáticamente por,

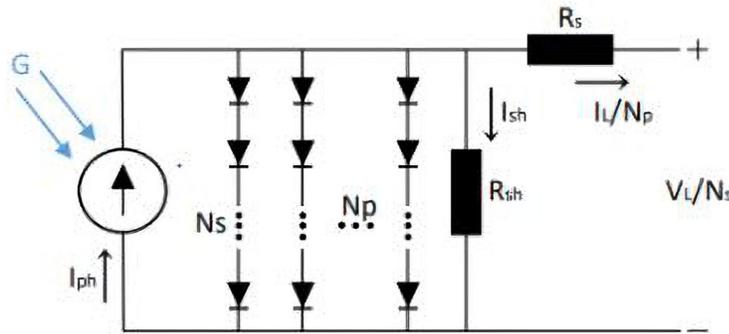


Figura 3.3: Circuito equivalente PV-array.

$$I_L = I_{ph} - I_0 \left[\exp \left(\frac{V_L + I_L \cdot R_s}{a} \right) - 1 \right] - \frac{V_L + R_s I_L}{R_{sh}}, \quad (3.11)$$

3.2 Modelo del panel fotovoltaico

Donde $I_{ph} = n_p * I_{ph,cell}$ y $I_0 = n_p * I_{0,cell}$ representa la corriente equivalente generada por la radiación y la corriente de saturación equivalente del modelo PV -array, respectivamente. Las resistencias equivalentes para el PV -array están dadas como $R_s = (n_s/n_p) R_{s,cell}$ y $R_{sh} = (n_s/n_p) R_{sh,cell}$, la tensión térmica equivalente a es representada por $a = (n_s * n) V_{T,cell}$. La Ec. (3.11) es la base del modelo del diodo único para un panel fotovoltaico conectado de varias celdas en serie y paralelo, la cual representa los 5 parámetros a calcular en este trabajo ($I_{ph}, I_0, R_s, R_{sh}, a$).

3.2.3. Curvas características

El comportamiento del panel fotovoltaico puede ser analizado por las curvas corriente contra voltaje ($I-V$) y potencia contra voltaje ($P-V$), como se muestra en la Figura 3.4. Tales curvas muestran tanto la potencia que entrega a la celda como

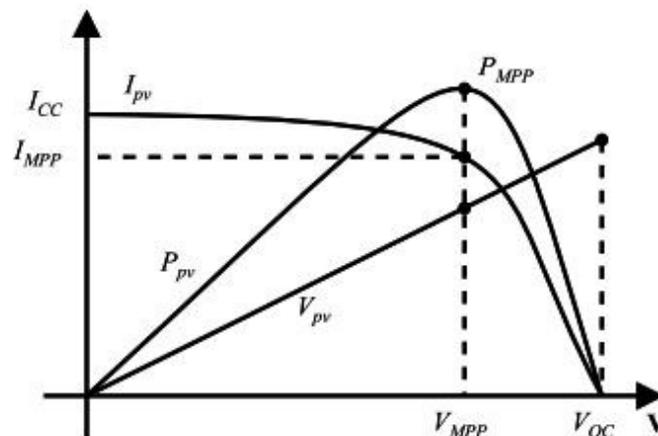


Figura 3.4: Curvas típicas de corriente, potencia y voltaje de una celda fotovoltaica convencional [Ruiz C et al., 2010].

el rango de funcionamiento de una celda fotovoltaica que va desde corto circuito ($V = 0$) hasta circuito abierto ($I = 0$). En estos dos puntos, el panel solar no genera ninguna potencia.

A la existencia del punto llamado máximo punto de potencia (MPP), le corres-

3.2 Modelo del panel fotovoltaico

ponden los valores de voltaje V_{MPP} y de corriente I_{MPP} . El panel entrega la máxima potencia que puede generar, dicho punto es único para cada celda solar, y varía únicamente conforme cambia la irradiancia solar y la temperatura interna del panel.

La forma más simple de obtener las curvas anteriormente descritas es resolviendo la Ec. (3.11) para cada valor de voltaje mediante el método de *Newton-Raphson* multi-variable. El obtener las curvas $I-V$ y $P-V$ es de gran importancia para poder observar el comportamiento del panel fotovoltaico e identificar el punto MPP con mayor facilidad y poder encontrar la utilidad práctica a la caracterización propuesta del panel fotovoltaico.

3.2.4. Punto de Máxima Potencia MPP

El punto de máxima potencia varía conforme a los cambios de temperatura e irradiación en el panel. Los algoritmos de seguimiento del punto de máxima potencia (MPPT, Maximum Power Point Tracking) son usados en sistemas fotovoltaicos para obtener la máxima energía entregada por los mismos. Una de las técnicas MPPT para encontrar el punto máximo de transferencia de potencia es el algoritmo Perturbar y Observar ($P\&O$), el cual es seleccionado en este trabajo debido a su relativa simplicidad y eficiencia.

El algoritmo $P\&O$ se basa en el siguiente criterio: si el voltaje V_p del arreglo fotovoltaico se perturba en cierta dirección y la potencia se incrementa, significa que el punto de operación se acerca hacia el MPP, por lo que el voltaje deberá de perturbarse en la misma dirección. De lo contrario, si la potencia disminuye, el punto de operación se ha movido en dirección contraria de la ubicación del MPP, por consiguiente el voltaje deberá ser perturbado en dirección opuesta a la que se tenía originalmente [Ruiz C et al., 2010].

En la Figura 3.5 se muestra el diagrama de bloques del algoritmo perturbar y observar, implementado en este trabajo, donde P_{act} es la potencia actual de ese instante mientras que la variable P_{ant} es la potencia calculada anteriormente, y delta es el tamaño de la perturbación. El algoritmo $P\&O$ compara la potencia actual con

3.2 Modelo del panel fotovoltaico

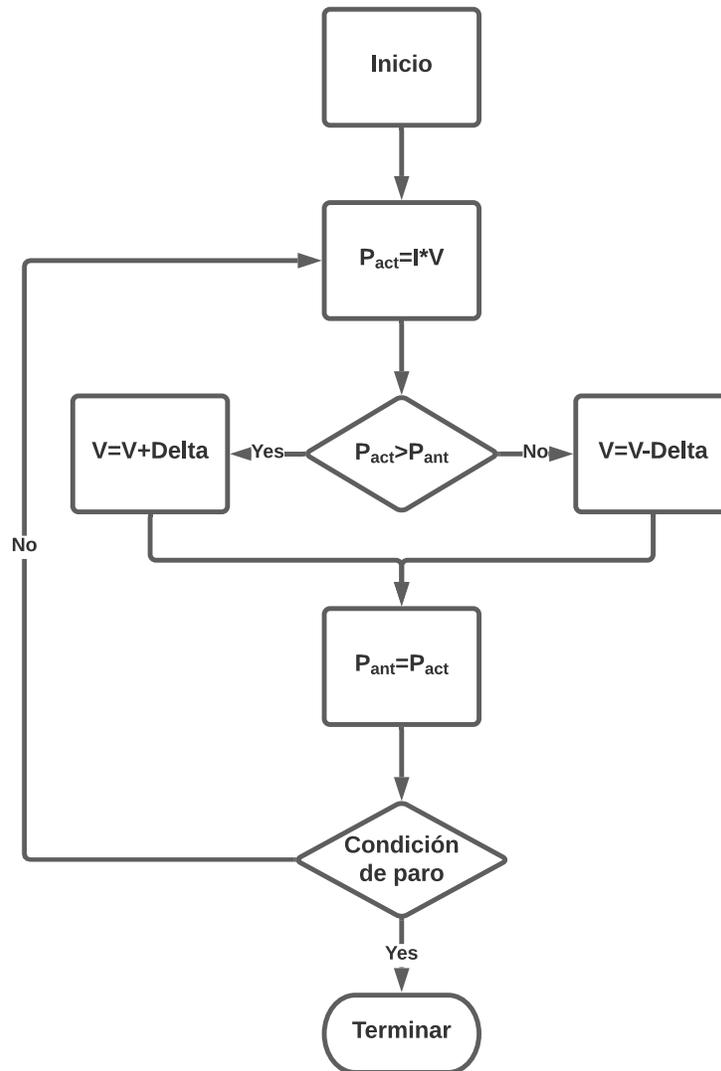


Figura 3.5: Diagrama de flujo del algoritmo Perturbar y Observar.

la anterior y con base a ello decide si se sigue aplicando la misma perturbación o si se invierte en el siguiente ciclo.

3.3. Formulación del problema de optimización

El objetivo del problema de optimización es encontrar los mejores valores de los parámetros PV y que se ajusten mejor a la respuesta real de los datos de medición con base en el error cuadrático, esto puede observarse en el diagrama a bloques de la Figura 3.6, el cual describe el trabajo hecho en esta tesis. En cada algoritmo im-

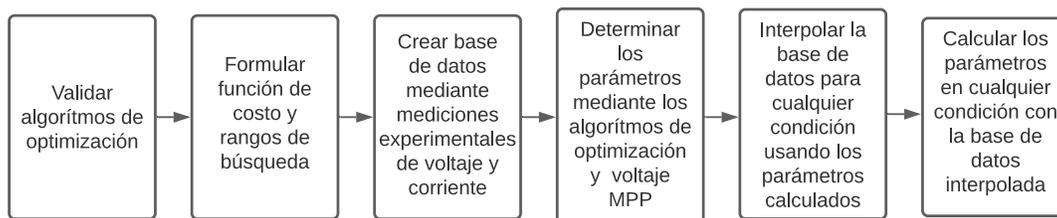


Figura 3.6: Diagrama a bloques de la metodología

plementado, es necesario evaluar las posibles soluciones al problema con una métrica adecuada, para el caso de PSO se evalúa cada partícula, en TLBO se evalúa cada estudiante y en DE se evalúa cada individuo, la métrica de evaluación comúnmente es conocida como Función de Costo o Función de Aptitud (Fitness).

3.3.1. Función de Aptitud (Fitness)

La función de aptitud (fitness) para este trabajo es cuantificada por el Error Cuadrático Medio (MSE) como se muestra en la Ec. (3.12),

$$\text{MSE}(x) = \frac{1}{N} \sum_{k=1}^N f(V_k, I_k, x)^2 \quad (3.12)$$

Donde N es número de datos experimentales, el vector x representa los parámetros calculados por cada algoritmo de optimización,

$$x = \{I_{ph}, I_0, R_s, R_{sh}, a\}, \quad (3.13)$$

3.3 Formulación del problema de optimización

y f representa la Ec. (3.11) del modelo PV de diodo único. La función resultante incluyendo todas las variables del modelo por determinar se define como,

$$f(V_k, I_k, x) = I_{ph} - I_0 \left[\exp \left(\frac{V_k + I_k \cdot R_s}{a} \right) - 1 \right] - \frac{V_k + R_s I_k}{R_p} - I_k, \quad (3.14)$$

Donde valores de I_k y V_k se recopilan experimentalmente a partir de mediciones de voltaje y corriente del panel fotovoltaico. La Ec. (3.14) permite que los algoritmos de optimización determinen el error MSE, en otras palabras, medir la aptitud de cada partícula, estudiante e individuo, por lo que al evaluar una posible solución lo más conveniente es que el error sea cercano a 0.

3.3.2. Interpolación

Dentro de este trabajo de investigación, se implementa la interpolación de dos variables, en este caso es la temperatura y la irradiancia del panel, en casos de dos o mas variables comúnmente se usa una interpolación bilineal, en este sentido la interpolación se basa en [Marion et al., 2004] para efectos de automatizar el estudio de la variación de los parámetros y la potencia de la celda dinámicamente.

El método de interpolación se extiende a casos de dos o más variables. El área de trabajo donde este tipo de aplicaciones son más utilizadas corresponde al procesamiento de imágenes como técnicas básicas de re-muestreo y mapeo de texturas [Hernández Rodríguez and León León, 2016]. En este trabajo se propone calcular los 5 parámetros del modelo de diodo único en cualquier condición de irradiancia y temperatura del panel mediante la interpolación de los datos experimentales.

Interpolación Bilineal

La interpolación bilineal es una extensión de la interpolación lineal para interpolar funciones de dos variables. Una de las maneras más usadas de implementar la interpolación bilineal es mediante cuatro puntos adyacentes

3.3 Formulación del problema de optimización

[Hernández Rodríguez and León León, 2016], por ejemplo, supongamos que queremos encontrar el valor de la función desconocida f en el punto (x, y) . Se supone que conocemos el valor de f en los cuatro puntos $Q_{11} = (x_1, y_1)$, $Q_{12} = (x_1, y_2)$, $Q_{21} = (x_2, y_1)$, y $Q_{22} = (x_2, y_2)$. Primeramente, se hace una interpolación en la dirección x como se muestra a continuación:

$$f(x, y_1) \approx \frac{x_2 - x}{x_2 - x_1} f(Q_{11}) + \frac{x - x_1}{x_2 - x_1} f(Q_{21}) \quad (3.15)$$

$$f(x, y_2) \approx \frac{x_2 - x}{x_2 - x_1} f(Q_{12}) + \frac{x - x_1}{x_2 - x_1} f(Q_{22}) \quad (3.16)$$

El siguiente paso es realizar la interpolación en dirección y para obtener la estimación deseada en este otro eje,

$$f(x, y) \approx \frac{y_2 - y}{y_2 - y_1} f(x, y_1) + \frac{y - y_1}{y_2 - y_1} f(x, y_2) \quad (3.17)$$

La interpolación llega al mismo resultado si se interpola primero en y , y su representación matricial tiene la forma de la Ec. (3.18).

$$f(x, y) = \frac{1}{(x_2 - x_1)(y_2 - y_1)} \begin{bmatrix} x_2 - x \\ x - x_1 \end{bmatrix}^T \begin{bmatrix} f(Q_{11}) & f(Q_{12}) \\ f(Q_{21}) & f(Q_{22}) \end{bmatrix} \begin{bmatrix} y_2 - y \\ y - y_1 \end{bmatrix} \quad (3.18)$$

En nuestro caso, para realizar nuestra interpolación y poder obtener una base de datos en cualquier condición se tomará en cuenta cuatro bases de datos en combinaciones de irradiancia y temperatura del módulo fotovoltaico, en este sentido se eligen dos configuraciones de irradiancia con temperatura constante a $25 \text{ }^\circ\text{C}$ y dos configuraciones de temperatura con irradiancia constante a 1000 W/m^2 del módulo fotovoltaico. Para utilizar las curvas de referencia e interpolar una curva $I-V$ las condiciones G y T deben ser adyacentes, esto es, para la primera condición de irradiancia debe ser mayor que G y la otra condición de irradiancia debe ser menor que G , del mismo sentido para las condiciones de temperatura. Por ejemplo, si queremos obtener una base de datos en condiciones de $(G=500 \text{ W/m}^2, T=50 \text{ }^\circ\text{C})$, usaremos una base de datos para $G_2=600 \text{ W/m}^2$ y $G_1=400 \text{ W/m}^2$ y ambos con temperatura

3.3 Formulación del problema de optimización

de $T_1=T_2=25^\circ C$ y las bases de datos para $T_3=60^\circ C$ y $T_4=40^\circ C$ ambos con irradiancia de $G_3=G_4=1000 W/m^2$, es importante tener en cuenta que previamente se calculan los parámetros para 10 condiciones diferentes los cuales son marcados con una "X", en las cuales 5 de ellas la irradiancia es variable con temperatura constante y las otras 5 con temperatura variable e irradiancia constante.

Tabla 3.2: Condiciones de interpolación $G = 500W/m^2, T = 50^\circ C$

Temperatura [$^\circ C$]	Irradiancia [W/m^2]				
	200	400	600	800	1000
80					X
60		(G,T)			X
40					X
25	X	X	X	X	X
20					X
0					X

La principal característica de esta técnica de interpolación propuesta es que podemos hacer uso de los 5 parámetros ya obtenidos del modelo del diodo único para las 10 condiciones del panel, y de esta manera crear una base de datos de corriente y voltaje de tal forma que sea conveniente para nuestros cálculos, por lo tanto la interpolación sigue los siguientes pasos.

- Paso 1: Crear un vector de voltaje y calcular la base de datos para las condiciones de irradiancia G_1 y G_2 .
- Paso 2: Interpolar la base de datos en dirección de la irradiancia.
- Paso 3: Interpolar la base de datos en dirección de la temperatura.
- Paso 4: Seleccionar un algoritmo de optimización
- Paso 5: Calcular los parámetros usando la base de datos previamente interpolada con el algoritmo de optimización.

3.3 Formulación del problema de optimización

El primer paso es crear un vector de voltaje V el cual tendrá un rango de $[0, V_f]$ donde V_f será considerado por el usuario, en este caso puede ser de 0 a 40 V con incrementos de 0.5 V. Después el vector de corriente será calculado para las dos diferentes condiciones de irradiancia con temperatura de 25 °C, en este sentido cada vector de corriente I se calcula sustituyendo los parámetros en su respectiva condición obtenidos anteriormente por un algoritmo de optimización seleccionado, lo siguiente es sustituir los parámetros en la Ec. 3.11 determinando el valor de corriente mediante *NewtonRaphson* para cada valor de voltaje del vector V . De esta forma tenemos nuestra base de datos para la condición G_1 como $[V_{G1}, I_{G1}]$, y la condición G_2 como $[V_{G2}, I_{G2}]$, donde aseguramos que $V_{G1} = V_{G2}$.

El siguiente paso es interpolar la corriente dentro de las dos bases de datos obtenidas en las condiciones $[G1, T1]$ y $[G2, T2]$ con la siguiente ecuación:

$$I_G = I_{G1} + \frac{(I_{G2} - I_{G1}) * (G - G1)}{G2 - G1} \quad (3.19)$$

Donde G es valor de irradiancia deseado e I_G es la corriente interpolada, de esta manera aseguramos que la base de datos está dentro de las curvas adyacentes y como los vectores de voltaje son iguales no será necesario interpolar el voltaje.

El siguiente paso es interpolar respecto a la temperatura, la interpolación se basa en las gráficas de la Figura 3.7 las cuales corresponden al panel fotovoltaico usado dentro de este trabajo. La irradiancia afecta principalmente la corriente de corto circuito y en menor medida el voltaje de circuito cerrado, mientras que la temperatura afecta en mayor medida el voltaje de circuito abierto y en menor grado a la corriente de circuito cerrado. Dicho esto la interpolación a la base de datos es muy similar a [Marion et al., 2004], por lo que la interpolación al vector de voltaje ed de la siguiente manera.

$$V'_G = \frac{V_G * V_{oc}}{V_{oc,ref}} \quad (3.20)$$

Donde $V_{oc,ref}$ es el voltaje de circuito abierto para la condición de $G=1000 \text{ W/m}^2$

3.3 Formulación del problema de optimización

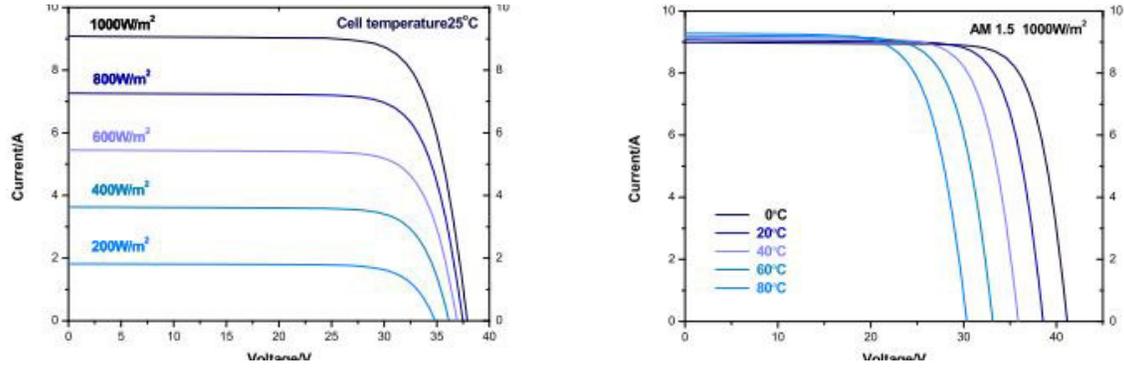


Figura 3.7: Curvas características IV Modulo M-60 Monocrystalline [Tongwei Solar (Hefei) Co., Ltd, 2021].

y $T=25^{\circ}C$, y V_{oc} es voltaje de circuito abierto para la condición en T con irradiancia de $100 W/m^2$ calculado como se muestra en la Ec(3.21).

$$V_{oc} = V_{oc3} + \frac{(V_{oc4} - V_{oc3}) * (T - T3)}{T4 - T3} \quad (3.21)$$

Donde V_{oc3} y V_{oc4} son los voltajes para circuito abierto para condiciones de $T3$ y $T4$ a $1000 W/m^2$ respectivamente.

Similar al Voltaje, la corriente se calcula como:

$$I'_G = \frac{I_G * I_{sc}}{I_{sc,ref}} \quad (3.22)$$

Donde $I_{sc,ref}$ es la corriente de circuito cerrado para la condición de $G=1000 W/m^2$ $T=25^{\circ}C$ y I_{sc} es la corriente de circuito cerrado para la condición en T con irradiancia de $100 W/m^2$ calculada como.

$$I_{sc} = I_{sc3} + \frac{(I_{sc4} - I_{sc3}) * (T - T3)}{T4 - T3} \quad (3.23)$$

Donde I_{sc3} y I_{sc4} son las corrientes de circuito cerrado para condiciones de $T3$ y $T4$ a $1000 W/m^2$. Es importante tener en cuenta de que las corrientes de circuito cerrado y el voltaje de circuito abierto para cada condición son calculadas sustituyendo los parámetros obtenidos mediante un método de optimización seleccionado

3.3 Formulación del problema de optimización

en la Ec. (3.11), para el caso de corriente en circuito cerrado con valor de $V=0$ y para voltaje de circuito abierto con $I=0$. De manera resumida la interpolación a la corriente puede ser obtenida como:

$$I'_G = \frac{I_{sc}}{I_{sc,ref}} \left[I_{G1} + \frac{(I_{G2} - I_{G1}) * (G - G1)}{G2 - G1} \right] \quad (3.24)$$

El último paso es calcular los parámetros al usar la base de datos creada $[I'_G, V'_G]$ como entrada a un método de optimización previamente seleccionado y de esta manera poder calcular los 5 parámetros del modelo de diodo único a diferentes niveles de irradiancia y temperatura.

En este capítulo, se describieron las funciones de validación para los algoritmos de optimización, el modelado del panel fotovoltaico usando el modelo del diodo único, curvas corriente-voltaje del panel, el punto MPP y se planteo un método de interpolación para generar una base de datos de corriente y voltaje en cualquier condición. Globalmente, cada aspecto teórico descrito, conforma el trabajo hecho dentro de esta investigación de tesis. Los resultados numéricos obtenidos de este capítulo son presentados y discutidos en el capítulo siguiente.

Capítulo 4

Resultados numéricos

En este capítulo se presentan los resultados de trabajo de tesis, inicialmente se presentan los resultados para las funciones de prueba junto con un detallado de su desempeño. En segundo lugar, se presentará los cálculos hechos por cada algoritmo de optimización para estimar los 5 parámetros de diodo único; incluyendo el análisis mediante la métrica del error cuadrático medio. Además, se muestran los valores de voltaje para el punto de máxima potencia bajo diferentes condiciones del panel y los resultados de la interpolación. Por último se discuten los resultados obtenidos.

4.1. Validación

El objetivo de las funciones de referencia (*Benchmark functions*) es validar en forma robusta y con casos extremos, los algoritmos de optimización propuestos en este trabajo. Así mismo, los resultados mostrados las Tablas 4.2 a 4.5, presentan el valor mínimo encontrado por cada algoritmo de optimización durante 100 simulaciones. Complementariamente, se presenta la peor estimación, su media y la dispersión de los resultados, la cual es cuantificada con la desviación estándar.

Dicho esto, el primer paso consiste en establecer los factores de ajuste (*tuning*) para cada algoritmo de optimización, los cuales deben de ser revisados cuidadosa-

4.1 Validación

Algoritmo	Factor de ajuste
GPSO	$C_1 = C_2 = 2$
TLBO	Sin factores
LPSO	$C_1 = C_2 = 2, N_s = 20$
DE	$C_p = 0.2, F = 0.1$

Tabla 4.1: Factores de ajuste para los algoritmos de optimización

mente para obtener el máximo rendimiento de cada algoritmo tanto en tiempo de ejecución como en exactitud.

Los factores de ajuste son propios de cada método de optimización y son seleccionados como se muestra en la Tabla 4.1. En el algoritmo GPSO se selecciona $c_1 = c_2 = 2$; el algoritmo LPSO al igual que el GPSO toma los factores de ajuste $c_1 = c_2 = 2$ con una vecindad $N_s = 20$ partículas. El algoritmo TLBO se caracteriza por no tener factores de ajuste. En cambio el algoritmo de DE, se requiere definir una probabilidad de combinación $C_p = 0.2$ y una probabilidad de mutación $F = 0.1$. Es importante hacer notar que los parámetros pueden ser distintos para otro tipo de aplicación pero están contenidos en un rango de valores generales determinados en la literatura para cada algoritmo de optimización. Para homologar las condiciones comunes de operación, en todos los métodos se considera una población, enjambre o grupo inicial de $n = 40$, con un máximo de $N = 10000$ generaciones y sin condición de paro anticipada. Finalmente, se calculan el resultado de desempeño de cada algoritmo de optimización para la aplicación del panel fotovoltaico, los cuales se detallan a continuación.

La Tabla 4.2 muestra los resultados numéricos del algoritmo GPSO sometido a las funciones de referencia descritas en la Tabla 3.1 Sección 3. El objetivo es encontrar los máximos y mínimos de las funciones de prueba con la mejor exactitud posible.

Como se puede observar, el algoritmo muestra un buen resultado al encontrar los mínimos en la mayoría de las funciones. En algunos casos no converge exactamente en su mínimo, pero su aproximación es muy cercana al mínimo de las funciones

4.1 Validación

Tabla 4.2: Resultados obtenidos por el método de optimización GPSO para las funciones de referencia seleccionadas.

Función	Óptimo	GPSO			
		Mejor	Peor	Media	SD
F_1	0	7.09196E-07	0.000845351	0.00019496	0.000178987
F_2	0	0.000306259	0.005306885	0.002266088	0.001095477
F_3	0	1.12586E-08	3.25726E-06	8.32469E-07	8.07493E-07
F_4	0	5.85394E-08	4.94858E-05	9.01244E-06	8.7948E-06
F_5	0	1.53512E-08	0.762069652	0.030484332	0.149334228
F_6	3	3.000000657	3.001255037	3.000269677	0.000237703
F_7	0	1.60157E-08	1.32876E-05	2.43349E-06	2.62417E-06
F_8	0	0.039625746	0.38642072	0.134853283	0.054176386
F_9	0	3.46684E-10	5.19261E-07	9.12895E-08	1.01509E-07
F_{10}	0	1.75482E-08	6.59826E-05	8.17232E-06	1.00631E-05
F_{11}	0	7.21313E-08	0.000158991	2.28109E-05	2.48999E-05
F_{12}	0	1.30715E-08	9.87841E-06	1.19046E-06	1.34162E-06
F_{13}	-1	-0.999999996	-0.999990469	-0.999998803	1.35861E-06
F_{14}	-2.06261	-2.06261187	-2.062611288	-2.062611753	1.34444E-07
F_{15}	-959.6407	-959.6406627	-888.9491252	-958.204666	8.101203717
F_{16}	-19.2085	-19.20850252	-19.20846565	-19.20849504	7.74872E-06
F_{17}	-1.9133	-1.913222938	-1.913217964	-1.913221773	9.03953E-07
F_{18}	0	1.9673E-11	6.88559E-09	9.12821E-10	9.50331E-10
F_{19}	0.292579	0.292578633	0.292578878	0.292578693	5.62378E-08
F_{20}	-78.33232	-78.33233138	-78.33225459	-78.33231848	1.19977E-05

de prueba. Además, la precisión del algoritmo es aceptable ya que la desviación estándar (SD) es muy baja. Es importante remarcar que la obtención de mínimo para una población inicial baja es demandante para los algoritmos metaheurísticos, su eficacia aumenta considerablemente al incrementar el tamaño de la población.

En la Tabla 4.3, se presenta el desempeño del algoritmo TLBO sometido a las mismas funciones de referencia que GPSO. El algoritmo muestra un buen desempeño

4.1 Validación

en la mayoría de las funciones. En algunos casos convergiendo exactamente en los mínimos de las funciones, la función con la que presenta algunas dificultades en cuanto a precisión es la función número 15 con una desviación estándar (SD) de 12.25.

Tabla 4.3: Resultados obtenidos por el método de optimización TLBO para las funciones de referencia.

Función	Óptimo	TLBO			
		Mejor	Peor	Media	SD
No.	F(x,y)				
F_1	0	0	0	0	0
F_2	0	0	0	0	0
F_3	0	0	0	0	0
F_4	0	0	0	0	0
F_5	0	0	0	0	0
F_6	3	3	3	3	1.12259E-15
F_7	0	0	0	0	0
F_8	0	8.23841E-05	0.049128196	0.009823318	0.009471342
F_9	0	0	0	0	0
F_{10}	0	1.34978E-31	1.34978E-31	1.34978E-31	2.62743E-46
F_{11}	0	0	7.88861E-31	2.36658E-32	1.3457E-31
F_{12}	0	0	0	0	0
F_{13}	-1	-1	-1	-1	0
F_{14}	-2.06261	-2.062611871	-2.062611871	-2.062611871	2.66454E-15
F_{15}	-959.6407	-959.6406627	-888.9491253	-957.2768895	12.25714477
F_{16}	-19.2085	-19.20850257	-19.20850257	-19.20850257	3.9117E-14
F_{17}	-1.9133	-1.913222955	-1.913222955	-1.913222955	3.9968E-15
F_{18}	0	0	0	0	0
F_{19}	0.292579	0.292578632	0.292578632	0.292578632	3.33668E-16
F_{20}	-78.33232	-78.33233141	-78.33233141	-78.33233141	1.69163E-13

Los resultados numéricos del algoritmo LPSO son mostrados en la Tabla 4.4. En dicha tabla, se observa que se tiene un buen desempeño en cuanto a exactitud

4.1 Validación

ya que en la mayoría de las funciones se acerca mucho al mínimo de la función, pero no se converge al resultado exacto en algunas de las funciones de prueba, sin embargo, los resultados obtenidos por este algoritmo son aceptables ya que en casos menos extremos como lo es el modelo del diodo único hay certeza de lograr el óptimo requerido.

Tabla 4.4: Resultados obtenidos por el método de optimización LPSO para las funciones de referencia.

Función	Óptimo	LPSO				
		No.	F(x,y)	Mejor	Peor	Media
F_1	0		2.43122E-07	0.001000526	0.000238432	0.000226052
F_2	0		5.0149E-05	0.008040203	0.002800901	0.001570955
F_3	0		2.21125E-08	7.37724E-06	1.4328E-06	1.40954E-06
F_4	0		8.70496E-09	6.77706E-05	1.13072E-05	1.10274E-05
F_5	0		9.18338E-07	0.762069704	0.723966345	0.16608847
F_6	3		3.000004607	3.001847595	3.000390355	0.000378208
F_7	0		2.34103E-08	1.60921E-05	3.21648E-06	3.29287E-06
F_8	0		0.013719084	0.272100578	0.129992195	0.054606802
F_9	0		3.21678E-09	6.00306E-07	1.21117E-07	1.13479E-07
F_{10}	0		1.1746E-07	3.71982E-05	1.03247E-05	8.59701E-06
F_{11}	0		1.30123E-07	0.000125934	2.89545E-05	2.82045E-05
F_{12}	0		1.09238E-08	6.36502E-06	1.57389E-06	1.56061E-06
F_{13}	-1		-0.999999976	-0.999993628	-0.9999984	1.46993E-06
F_{14}	-2.06261		-2.062611866	-2.062610929	-2.062611718	1.65631E-07
F_{15}	-959.6407		-959.6406627	-888.9491248	-940.4712497	15.82234633
F_{16}	-19.2085		-19.20850248	-19.20845889	-19.20849443	8.59865E-06
F_{17}	-1.9133		-1.913222952	-1.913215932	-1.913221556	1.43433E-06
F_{18}	0		3.57149E-11	6.29312E-09	1.26661E-09	1.19618E-09
F_{19}	0.292579		0.292578633	0.29257895	0.292578702	6.0907E-08
F_{20}	-78.33232		-78.33233121	-78.33221599	-78.3323121	1.97282E-05

En la Tabla 4.5, podemos observar que el desempeño del algoritmo DE, en exac-

4.1 Validación

titud y precisión es muy similar al TLBO, acercándose mucho a los mínimos de las funciones de prueba e incluso encontrando el valor más cercano de su mínimo. Además, en términos de exactitud, el método DE muestra un mejor desempeño con la función número 15 con la cual, los algoritmos GPSO, LPSO y TLBO tuvieron problemas. Así mismo, el desempeño que muestran los algoritmos de optimización

Tabla 4.5: Resultados obtenidos por el método de optimización DE para las funciones de referencia.

Función No.	Óptimo F(x,y)	DE			
		Mejor	Peor	Media	SD
F_1	0	0	0	0	0
F_2	0	0	0	0	0
F_3	0	1.25845E-77	5.08135E-69	5.41905E-71	5.05358E-70
F_4	0	0	0	0	0
F_5	0	0	0	0	0
F_6	3	3	3	3	1.11554E-15
F_7	0	0	0	0	0
F_8	0	0.009662436	0.067451297	0.035338945	0.012847224
F_9	0	6.10423E-74	3.25059E-64	5.56701E-66	3.40372E-65
F_{10}	0	1.34978E-31	1.34978E-31	1.34978E-31	2.62743E-46
F_{11}	0	0	0	0	0
F_{12}	0	9.23437E-40	1.12707E-23	1.67331E-25	1.24054E-24
F_{13}	-1	-1	-1	-1	0
F_{14}	-2.06261	-2.062611871	-1.889938046	-2.021170151	0.073746077
F_{15}	-959.6407	-959.6406627	-959.6394577	-959.6406091	0.000174015
F_{16}	-19.2085	-19.20850257	-19.20850252	-19.20850256	7.88473E-09
F_{17}	-1.9133	-1.913222955	-1.913222955	-1.913222955	3.9968E-15
F_{18}	0	0	0	0	0
F_{19}	0.292579	0.292578632	0.292578632	0.292578632	3.97516E-16
F_{20}	-78.33232	-78.33233141	-78.33233141	-78.33233141	1.70394E-13

ante las funciones de prueba, ofrece una validación clara de que los métodos pro-

4.2 Cálculo de parámetros y RMSE

puestos pueden obtener el óptimo global incluso con problemas complejos, rangos de búsqueda extensos y con varios óptimos locales, esto implica de que los algoritmos son implementados correctamente, por lo tanto, podemos proceder a calcular los parámetros del panel.

Recordemos que las funciones de prueba (benchmark) son funciones muy complejas y que van a demandar métodos verdaderamente efectivos para poder realizar la estimación de máximos y mínimos. En problemas reales, como la celda fotovoltaica, no se tiene ese caso extremo y los métodos son garantía de poder lograr el óptimo requerido, sin embargo un validación con las funciones de prueba asegura que los algoritmos funcionan y están programados correctamente.

4.2. Cálculo de parámetros y RMSE

El proceso de optimización se relaciona con la minimización de la función de aptitud (fitness) ó también llamada función de costo usada por los métodos de optimización GPSO, LPSO, TLBO y DE. Al mismo tiempo, en el problema planteado en este tema de tesis, el objetivo es encontrar los 5 parámetros que describan mejor el comportamiento óptimo del panel fotovoltaico. Dicho panel es mostrado en la Figura 4.1. Las especificaciones técnicas del panel usado dentro de este traba-

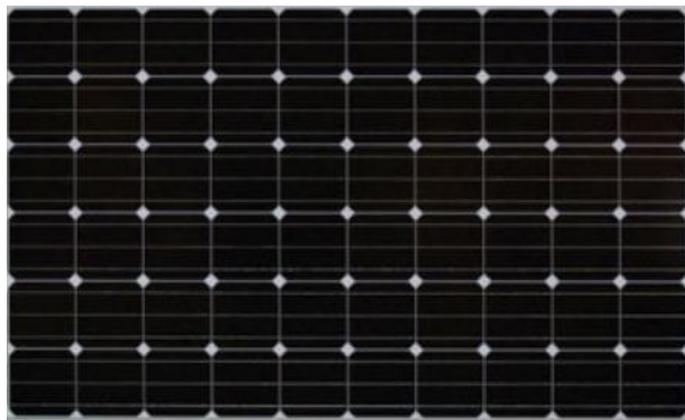


Figura 4.1: Módulo M-60 Monocrystalline [Tongwei Solar (Hefei) Co., Ltd, 2021].

4.2 Cálculo de parámetros y RMSE

jo corresponden al módulo fotovoltaico M-60 Monocrystalline con dimensiones de 1640*990*40 mm (L×W×H) y peso de 19.1 kg, las cuales pueden ser consultadas en [Tongwei Solar (Hefei) Co., Ltd, 2021] o en la página web del fabricante.

Para los métodos poblacionales que se estudiaron en esta obra, el primer paso consiste en crear el enjambre, población o grupo inicial de partículas para cada método de optimización. La población inicial es igual para todos los algoritmos y se crea aleatoriamente con los rangos de parámetros establecidos de la Tabla 4.6, en caso del parámetro a se toma como límite $a = 100 * Vt$ donde $Vt = .0257V$.

Tabla 4.6: Rango valores aceptables para cada parámetro de los algoritmos.

Parámetros	Min.	Max.	Unit
I_{ph}	0	10	[A]
I_0	0	50	[μA]
R_s	0	10	[Ω]
R_{sh}	0	2000	[Ω]
a	1	2.57	[V]

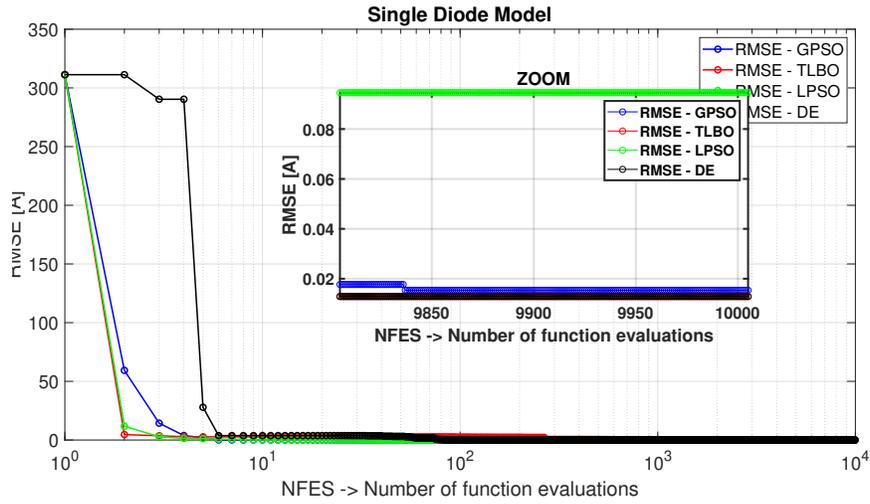
Además, los factores de ajuste son iguales a los usados en la Sección 4.1 donde se midió el desempeño de los algoritmos con las funciones de prueba.

En la siguiente etapa, se realiza un análisis gráfico del error cuadrático medio (RSME).

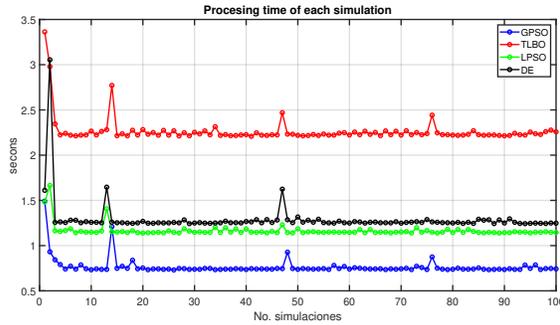
4.2.1. Análisis RMSE a diferente valor de irradiancia

Las gráficas en las Figuras 4.2 a 4.11, muestran el mejor comportamiento de entre 100 simulaciones para cada método de optimización. En esas mismas gráficas, se observa la disminución del error cuadrático medio (RMSE), tiempo de procesamiento y la diferencia absoluta entre la corriente calculada sustituyendo los parámetros determinados para cada valor de voltaje experimental con la corriente medida experimentalmente. En particular, la masa de aire se mantiene constante para todos los

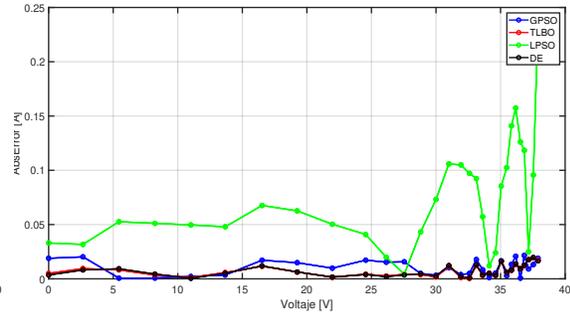
4.2 Cálculo de parámetros y RMSE



(a) RMSE



(b) Tiempo de procesamiento



(c) Error absoluto

Figura 4.2: Gráficas RMSE, tiempo y error absoluto $G = 1000 \text{ W/m}^2$, $T = 25^\circ\text{C}$, $AM = 1.5$

casos en $AM = 1.5$.

De la misma manera las Tablas 4.7 y 4.9 muestran el análisis RMSE de cada método, se muestra el valor más bajo de RMSE (best RMSE), el valor más alto de RMSE (worst RSME), la media del RMSE (mean RMSE), la desviación estándar (std dev) y tiempo promedio dentro de las 100 simulaciones de cada algoritmo. Adicionalmente, el resultado del cálculo de los parámetros obtenidos se presenta en las Tablas 4.8 y 4.10 para cada algoritmo con diferente nivel de irradiancia y

4.2 Cálculo de parámetros y RMSE

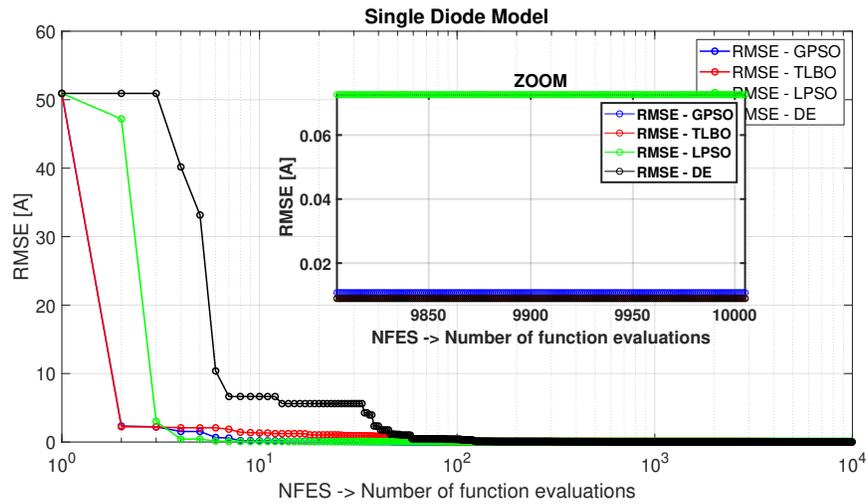
temperatura.

En la Figura 4.2 (a) podemos observar la disminución del error RMSE en cada método, donde podemos observar que los algoritmos se aproximan a su mínimo error RMSE cerca de las 100 primeras generaciones. Aunque, en el algoritmo GPSO se logra mejorar un poco su desempeño cerca de la generación 9800, además, muestra un error RMSE en LPSO por encima de 0.08 mientras que los demás algoritmos tienen un error por debajo de 0.02. Esto se ve reflejado en la Figura 4.2(c) donde se observa la diferencia obtenida del cálculo de los valores de corriente comparados con los experimentales con valor de 0.05A y con un pico máximo por encima de 0.2A para LPSO mientras que los algoritmos están por debajo de 0.05A, en cuanto al tiempo de ejecución, el método más rápido fue el algoritmo GPSO y el más lento fue el algoritmo TLBO.

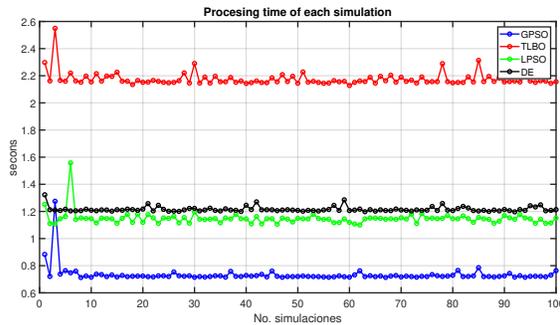
En la Figura 4.3, se observa un comportamiento similar a las gráficas de la Figura 4.2. En esta, los algoritmos se acercan a su error RMSE mínimo aproximadamente en las 100 primeras generaciones para cada método. De forma semejante, se observa que el que tuvo el peor desempeño es el algoritmo LPSO con un error por encima de 0.06 y un error absoluto con un pico máximo cercano a 0.2A mientras los demás algoritmos están por debajo de 0.02A. El tiempo de procesamiento para cada una de las 100 simulaciones es estable y muestra que el algoritmo GPSO el más rápido y el algoritmo TLBO es el más lento con una diferencia mayor de 1.5 segundos.

El desempeño de los algoritmos metaheurísticos al determinar los parámetros del panel fotovoltaico para una irradiancia de $G = 600 \text{ W/m}^2$, son mostrados en la Figura 4.4. Para una irradiancia de $G = 600 \text{ W/m}^2$, se observa numéricamente que el algoritmo LPSO muestra un mejor desempeño respecto a las condiciones anteriores con un error RMSE solo por encima 0.04, aunque los métodos DE y TLBO muestran un mejor desempeño que LPSO por debajo de 0.01. Este comportamiento se observa en las Figuras 4.4(a) y 4.4(c) donde el error absoluto de LPSO tiene picos por debajo de 0.09A y los demás algoritmos cercanos a 0.02A. Por otro lado el tiempo de procesamiento de cada modelo es estable con pocos picos de incrementos de tiempo en algunas simulaciones. El tiempo de ejecución máximo fue para TLBO con valor

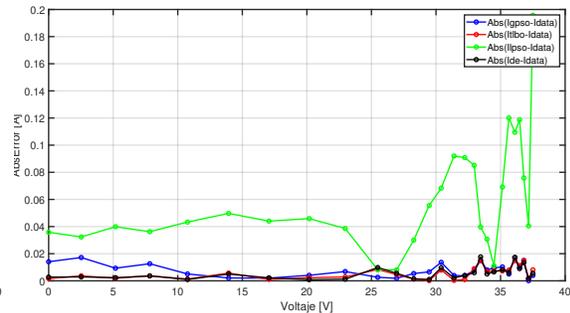
4.2 Cálculo de parámetros y RMSE



(a) RSME



(b) Tiempo de procesamiento



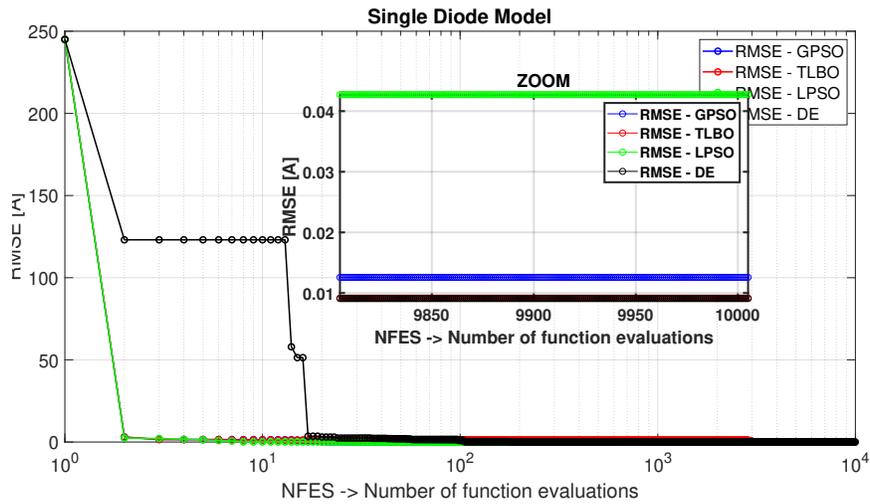
(c) Error absoluto

Figura 4.3: Gráficas RMSE, tiempo y error absoluto $G = 800 \text{ W/m}^2$, $T = 25^\circ\text{C}$, $AM = 1.5$

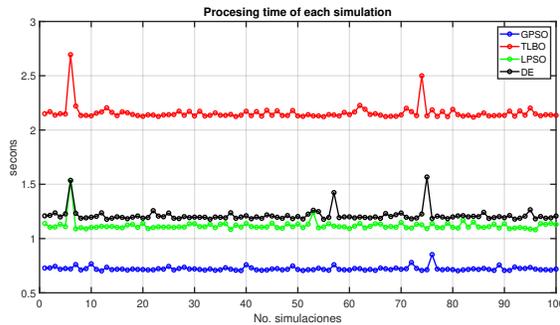
promedio de cercano a 2 segundos y algunos incrementos llegando a estar por encima de 2.5 segundos, LPSO y DE con tiempos cercanos a 1 segundo y algunos valores cercanos a 1.5 segundos, GPSO se mantiene con el más rápido con un valor promedio cercano a medio segundo.

En la Figura 4.5 muestra resultados similares a las gráficas obtenidas para las condiciones de operación con irradiancias de $G=1000, 800$ y 600 W/m^2 . Así mismo, en la Figura 4.5(c) se observa por medio del error absoluto que el algoritmo LPSO tiene

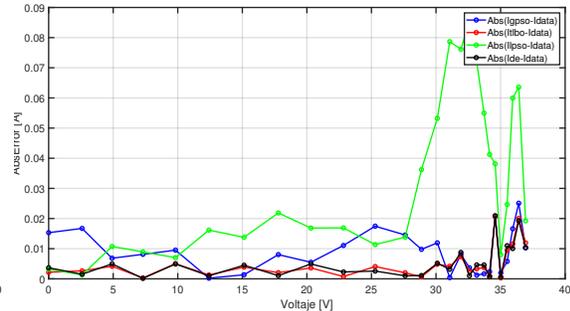
4.2 Cálculo de parámetros y RMSE



(a) RSME



(b) Tiempo de procesamiento



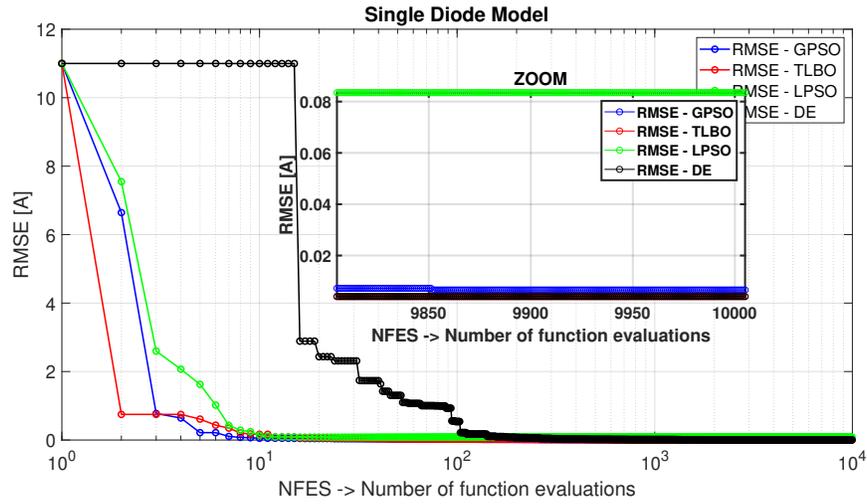
(c) Error absoluto

Figura 4.4: Gráficas RMSE, tiempo y error absoluto $G = 600 \text{ W/m}^2$, $T = 25^\circ\text{C}$, $AM = 1.5$

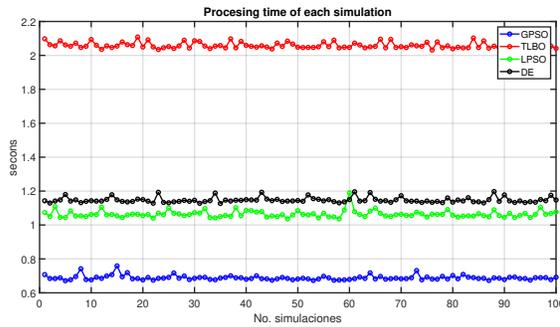
una mayor cota de error, superior a 0.02A entre la corriente calculada al sustituir los parámetros y la corriente de la base obtenida de los datos experimentales. Mientras los demás algoritmos tienen diferencias por debajo de 0.02A. Además, se observa que el tiempo de ejecución no presenta grandes variaciones dentro de las 100 simulaciones para cada algoritmo.

En la gráfica (b) de la Figura 4.6 muestra pequeños incrementos de tiempo en las simulaciones de cada algoritmo. Además, se observa que el algoritmo DE se

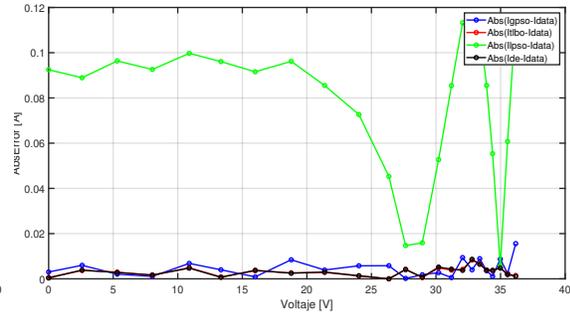
4.2 Cálculo de parámetros y RMSE



(a) RMSE



(b) Tiempo de procesamiento

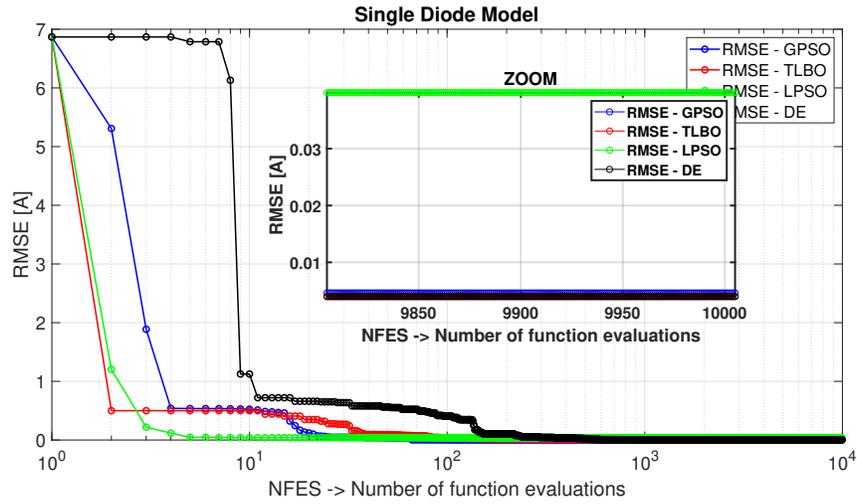


(c) Error absoluto

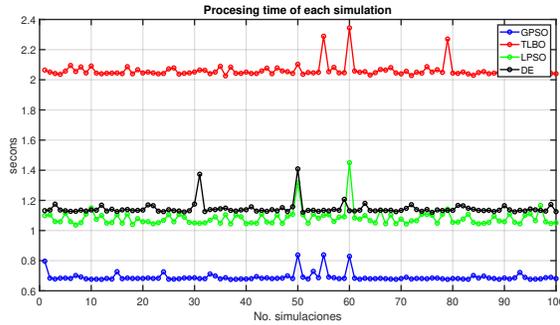
Figura 4.5: Gráficas RMSE, tiempo y error absoluto $G = 400 \text{ W/m}^2$, $T = 25^\circ\text{C}$, $AM = 1.5$

acerca al error mínimo RMSE después de las 100 primeras generaciones, lo cual es algo inusual en este algoritmo que casi siempre se desempeña satisfactoriamente. También se puede observar que el algoritmo del LPSO tiene un buen desempeño con un error RMSE un poco mayor con 0.03 y los demás, muestran un error menor a 0.01. En la Figura 4.6(c) se observa un error absoluto en el desempeño del algoritmos LPSO con picos menores de 0.07A mientras los demás algoritmos están por debajo de 0.01A. Estos picos en la gráfica de error absoluto son más frecuentes entre los valores de 25 a 35V. Lo cual puede verse reflejado en el análisis del error cuadrático

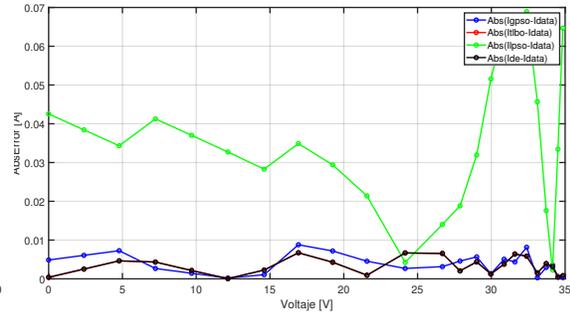
4.2 Cálculo de parámetros y RMSE



(a) RMSE



(b) Tiempo de procesamiento



(c) Error absoluto

Figura 4.6: Gráficas RMSE, tiempo y error absoluto $G = 200 \text{ W/m}^2$, $T = 25^\circ\text{C}$, $AM = 1.5$

medio como se muestra a continuación.

4.2.2. Evaluación de algoritmos a distintos valores de irradiancia.

La Tabla 4.7 muestra un análisis más detallado sobre el desempeño de los métodos de optimización para varios niveles de irradiancia con temperatura constante a

4.2 Cálculo de parámetros y RMSE

Tabla 4.7: RMSE y desviación estándar para diferente nivel de irradiancia

Algoritmo	Mejor RMSE	Peor RMSE	Media RMSE	SD RMSE.	Tiempo promedio
$G = 1000W/m^2, T = 25^\circ C, AM = 1.5$					
GPSO	0.015380526	2.09719418	0.121630962	0.217583767	0.764609542
LPSO	0.094585582	2.735838174	0.82266769	0.543671787	1.165063019
TLBO	0.012855649	0.255704084	0.063421026	0.037548927	2.264890074
DE	0.012870038	0.033459485	0.014839223	0.003166298	1.288526457
$G = 800W/m^2, T = 25^\circ C, AM = 1.5$					
GPSO	0.010744442	1.688859389	0.12588153	0.322895153	0.733490411
LPSO	0.072618377	2.43029466	1.775983427	0.734118086	1.147766797
TLBO	0.009011021	1.688859389	0.106939259	0.323624847	2.174547083
DE	0.008931197	0.019182491	0.010647739	0.002084345	1.215378074
$G = 600W/m^2, T = 25^\circ C, AM = 1.5$					
GPSO	0.012581327	1.65771025	0.088744351	0.22229007	0.721996494
LPSO	0.042720219	3.621099622	1.676173635	0.940196342	1.11942477
TLBO	0.009164226	1.159315433	0.077904389	0.22795241	2.156896963
DE	0.009083218	0.018763734	0.00995206	0.001372848	1.211906607
$G = 400W/m^2, T = 25^\circ C, AM = 1.5$					
GPSO	0.006584548	1.65967577	0.070408702	0.177009133	0.688741184
LPSO	0.083472009	5.104855139	2.107487498	1.296800219	1.064342486
TLBO	0.004023267	0.765174833	0.028806783	0.105373184	2.059374509
DE	0.004035724	0.013770053	0.005152153	0.001821659	1.146961479
$G = 200W/m^2, T = 25^\circ C, AM = 1.5$					
GPSO	0.004607412	0.538242868	0.083805784	0.151542629	0.690805654
LPSO	0.039870397	0.536443254	0.310014352	0.185325287	1.082530116
TLBO	0.003974767	0.407755166	0.035792694	0.105166822	2.060267797
DE	0.003975523	0.005784382	0.00422019	0.000333778	1.143948354

$25^\circ C$. En esta tabla, se pueden observar en especial los valores resaltados en color azul para los algoritmos con el valor más bajo de RMSE. Siendo en este caso los algoritmos TLBO y DE los que tienen mejor desempeño bajo el criterio del error RMSE más bajo. En especial, el algoritmo TLBO en los valores de irradiancia $G=1000 W/m^2$, $400 W/m^2$ y $200 W/m^2$ y el algoritmo de DE en $G=800 W/m^2$ y $600 W/m^2$. Sin embargo, el algoritmo LPSO muestra el peor desempeño en todas las pruebas, sin que el error sobrepase del 0.1.

4.2 Cálculo de parámetros y RMSE

El algoritmo más preciso resultó ser el DE con la desviación estándar más pequeña en todas las pruebas lo que implica que los resultados de las 100 simulaciones son menos dispersas, mientras el que tiene menos precisión es LPSO.

Además, el algoritmo GPSO se destaca por su excepcional tiempo de ejecución de aproximadamente de 0.7 segundos, mientras que el algoritmo TLBO casi lo triplica con un tiempo promedio superior a los 2 segundos. De esta manera, podemos tener la certeza de elegir el mejor algoritmo de optimización y los mejores parámetros para la solución correcta de nuestro modelo planteado. Enseguida se presentan los resultados estimados para los parámetros del modelo fotovoltaico para los diferentes algoritmos de optimización.

4.2.3. Estimación de parámetros a diferente valor de irradiancia.

La Tabla 4.8 de resultados finales para la estimación de parámetros, nos permite observar que los parámetros calculados por los algoritmos DE y TLBO tienen una mayor cercanía entre sí, mientras los algoritmos que se basan en el enjambre de partículas GPSO y LPSO tienen problemas estancándose en un mínimo local. Esto hace que algún parámetro se sature y llegue al valor máximo de su rango de búsqueda, esto se puede observar en los parámetros “ a ” y “ R_{sh} ” calculados por GPSO y LPSO.

4.2.4. Análisis RMSE a diferente valor de temperatura

La Figura 4.7 muestra el desempeño de cada algoritmo para calcular los 5 parámetros con una temperatura de $0^{\circ}C$ e irradiancia de $G=1000 W/m^2$. En la Figura 4.7(a), se observa que el algoritmo LPSO tiene un el peor desempeño con un valor RMSE por encima de 0.12 esto se ve reflejado en la Figura 4.7(a), mientras que los algoritmos DE y TLBO están por debajo de 0.02 y GPSO por encima de 0.02. Finalmente, en la Figura 4.7 (c) se observan picos en LPSO cercanos a 0.25A y los demás algoritmos por debajo de 0.05A. La Figura 4.7 (b) referente a los tiempos de

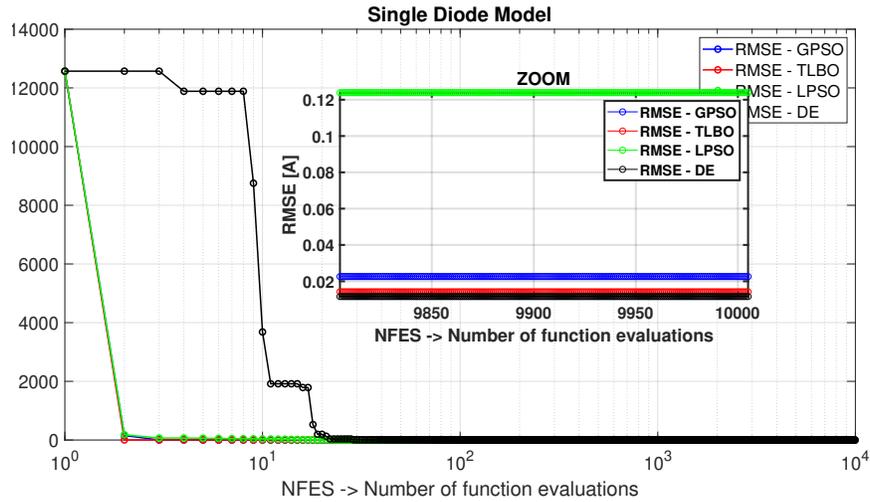
4.2 Cálculo de parámetros y RMSE

Tabla 4.8: Estimación de parámetros a diferente irradiación

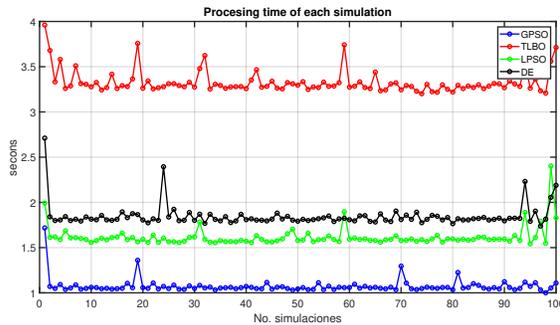
Algoritmo	$I_{ph}[A]$	$I_0[A]$	$R_s[\Omega]$	$R_{sh}[\Omega]$	a[V]
$G = 1000W/m^2, T = 25^\circ C, AM = 1.5$					
GPSO	9.061734612	3.11849E-08	0.144317708	2000	1.9459
LPSO	9.11318868	1.88968E-06	0.034656535	1998.366991	2.459
TLBO	9.077354896	1.93206E-08	0.150817898	594.0305283	1.8995
DE	9.078857013	1.94209E-08	0.150605032	570.1095106	1.90007
$G = 800W/m^2, T = 25^\circ C, AM = 1.5$					
GPSO	7.249013587	2.36884E-08	0.147169035	808.4593931	1.9204
LPSO	7.297577272	2.11116E-06	0.002072289	734.7570624	2.4882
TLBO	7.265659271	2.18386E-08	0.146655654	474.9345857	1.9125
DE	7.266952122	1.84345E-08	0.150205869	447.1495089	1.8963
$G = 600W/m^2, T = 25^\circ C, AM = 1.5$					
GPSO	5.428624537	3.408E-08	0.135177494	1837.870047	1.9564
LPSO	5.446911853	7.32942E-07	0.033137418	1343.895131	2.3355
TLBO	5.4472201	1.9485E-08	0.146413008	534.7332204	1.9007
DE	5.448855372	1.68765E-08	0.150211711	497.3628535	1.8868
$G = 400W/m^2, T = 25^\circ C, AM = 1.5$					
GPSO	3.622860151	2.35558E-08	0.140029344	874.5769404	1.9201
LPSO	3.717792035	2.72711E-06	0.004698889	732.6449156	2.57
TLBO	3.626944072	1.02994E-08	0.174613728	605.4005653	1.8401
DE	3.626745815	9.91643E-09	0.176210723	605.910304	1.8366
$G = 200W/m^2, T = 25^\circ C, AM = 1.5$					
GPSO	1.80232602	2.72081E-08	0.12806046	2000	1.9366
LPSO	1.849620822	7.20776E-07	0.003190476	582.6470956	2.3731
TLBO	1.806973128	1.67269E-08	0.15453184	1119.990232	1.8861
DE	1.806905391	1.70992E-08	0.152860406	1127.74843	1.8884

cómputo, muestra que las 100 simulaciones de cada algoritmo se comportan estables. Existe un ligero aumento en el tiempo de ejecución del algoritmo TLBO en compara-

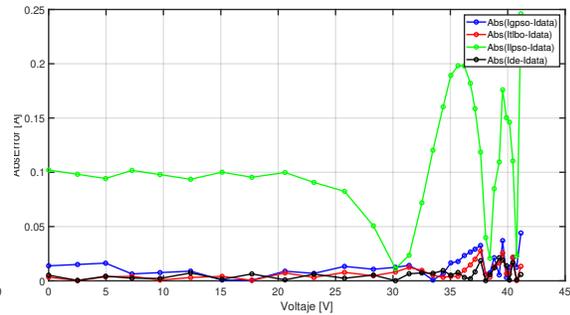
4.2 Cálculo de parámetros y RMSE



(a) RSME



(b) Tiempo de procesamiento



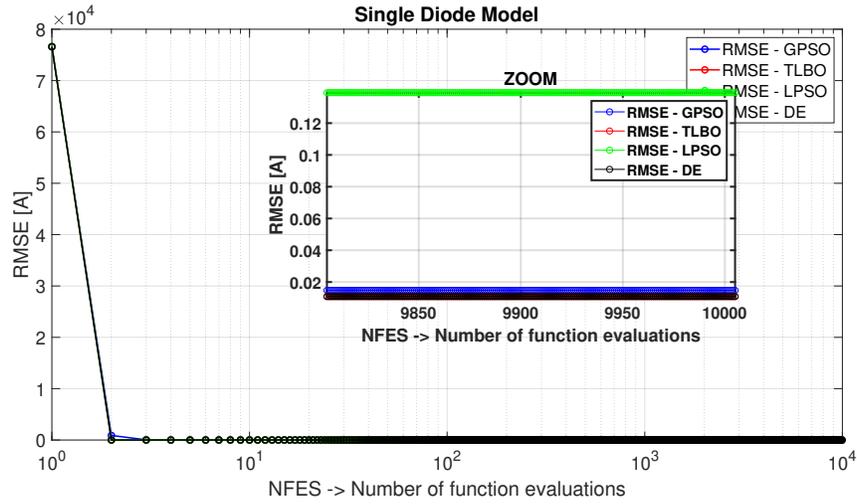
(c) Error absoluto

Figura 4.7: Gráficas RMSE, tiempo y error absoluto $T = 0^{\circ}C$, $G=1000 W/m^2$, $AM = 1.5$

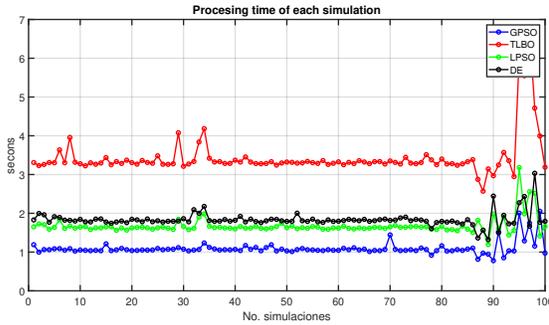
ción con la estimación de los parámetros calculados a diferente nivel de irradiancia. Así, el algoritmo TLBO está por encima de los 3 segundos, siendo claramente el más afectado en cuestión del tiempo de procesamiento pero ventajoso por no requerir parámetros de ajuste (tuning) manual.

El desempeño de los algoritmos de optimización a una temperatura de $20^{\circ}C$ e irradiancia $1000 W/m^2$ es mostrado en la Figura 4.8. En este último experimento, se observa un incremento de tiempo de procesamiento en las últimas 20 simulaciones

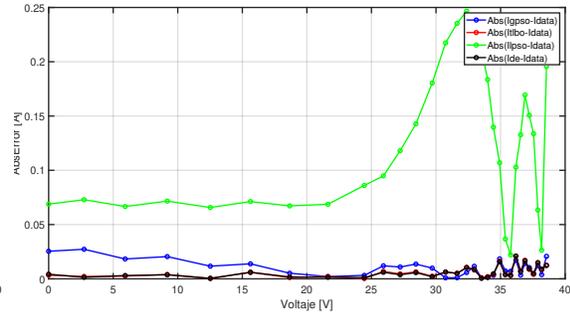
4.2 Cálculo de parámetros y RMSE



(a) RMSE



(b) Tiempo de procesamiento



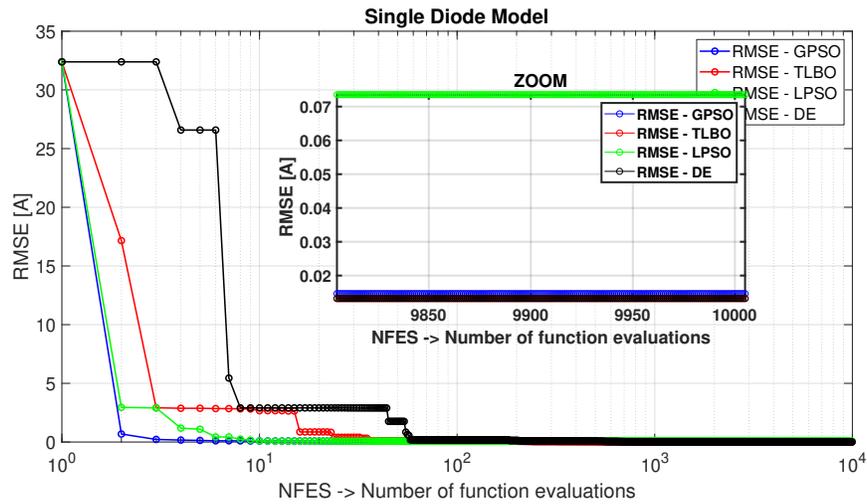
(c) Error absoluto

Figura 4.8: Gráficas RMSE, tiempo y error absoluto $T = 20^{\circ}C$, $G=1000 W/m^2$, $AM = 1.5$

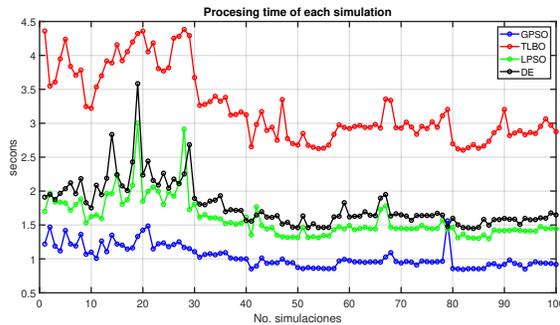
en cada algoritmo. Nuevamente el algoritmo LPSO tiene el peor comportamiento con un error RMSE superior a 0.12 mientras que los demás algoritmos tienen un error por debajo de 0.02. Sin embargo, podemos observar en la Figura 4.8 (a) que los algoritmos se acercan más rápido al mínimo error RMSE incluso cerca de la generación 10, esto también se ve reflejado en la diferencia de la corriente calculada y la corriente experimental de la Figura 4.8 (c).

En la Figura 4.9, se muestra el desempeño de los algoritmos de optimización a

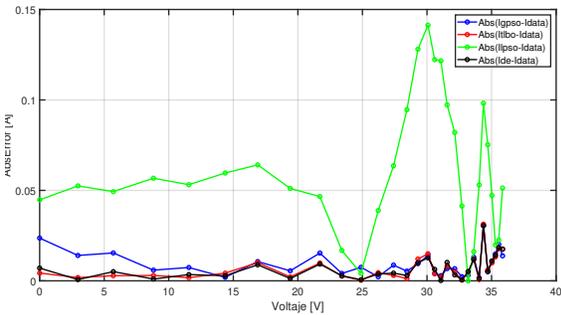
4.2 Cálculo de parámetros y RMSE



(a) RMSE



(b) Tiempo de procesamiento



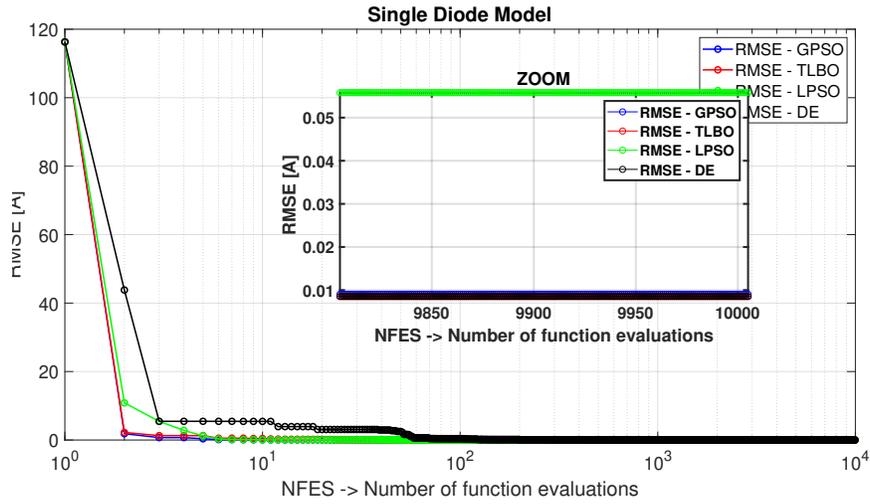
(c) Error absoluto

Figura 4.9: Gráficas RMSE, tiempo y error absoluto $T = 40^{\circ}C$, $G=1000 W/m^2$, $AM = 1.5$

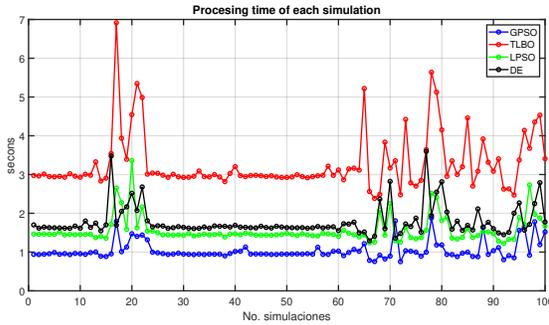
una temperatura de $40^{\circ}C$ e irradiancia $1000 W/m^2$. En la Figura 4.9(b) se observan tiempos simulación muy variables entre todos los algoritmos. El algoritmo LPSO tiene un error RSME superior a 0.07 mientras que los demás algoritmos tienen un error por debajo de 0.02. Además, el error absoluto del LPSO llega a valores cercanos a 0.15A en el intervalo de voltaje entre 25V y 35V, mientras que los demás algoritmos están por debajo de 0.05A.

La Figura 4.10 muestra el desempeño a una temperatura de $60^{\circ}C$ e irradiancia

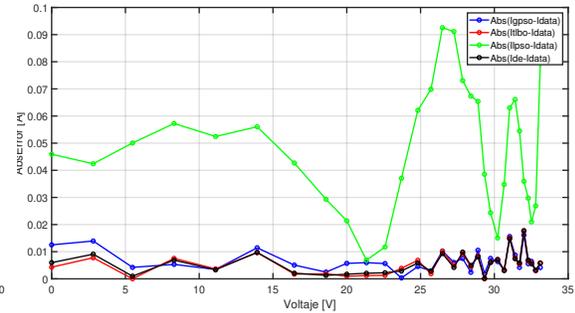
4.2 Cálculo de parámetros y RMSE



(a) RMSE



(b) Tiempo de procesamiento



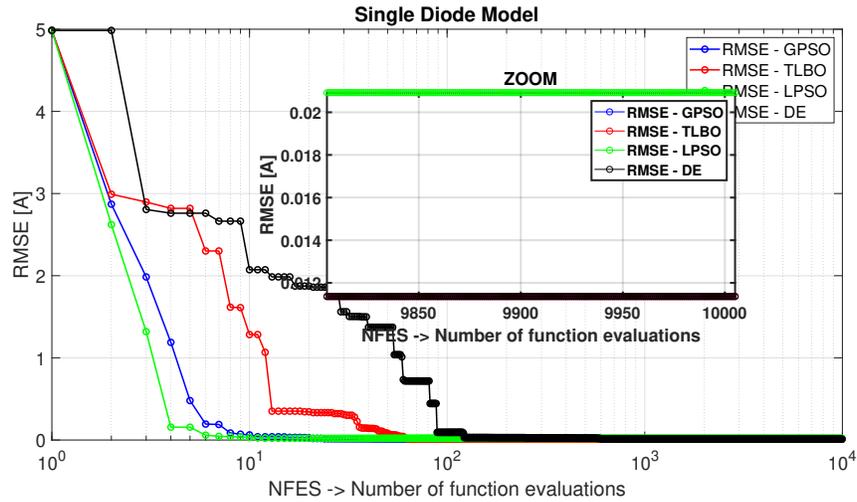
(c) Error absoluto

Figura 4.10: Gráficas RMSE, tiempo y error absoluto $T = 60^{\circ}C$, $G=1000 W/m^2$, $AM = 1.5$

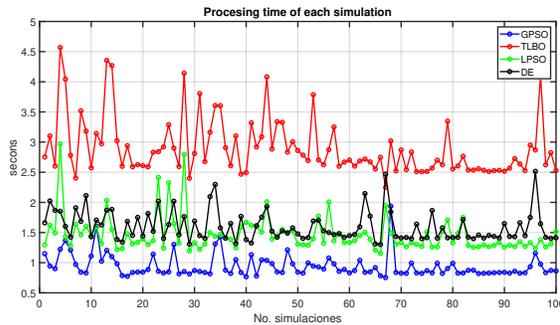
de $G=1000 W/m^2$. En la Figura 4.10(b) se observa que el tiempo de procesamiento de las ultimas 40 simulaciones tiene varias fluctuaciones al alza de tiempos de procesamiento. Sin embargo, se puede observar que el desempeño RMSE de cada algoritmo es por arriba de 0.05 para LPSO y por debajo cercano de 0.01 para los demás algoritmos, y el valor del error absoluto en la Figura 4.10(c) para LPSO no presenta picos superiores a 0.1A.

El desempeño de los algoritmos mostrados en la Figura 4.11 con temperatura de

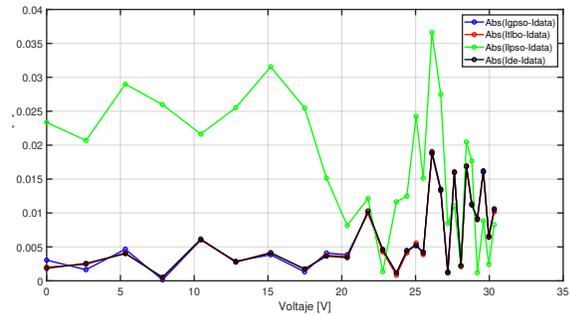
4.2 Cálculo de parámetros y RMSE



(a) RSME



(b) Tiempo de procesamiento



(c) Error absoluto

Figura 4.11: Gráficas RMSE, tiempo y error absoluto $T = 80^{\circ}C$, $G=1000 W/m^2$, $AM = 1.50$.

$80^{\circ}C$ e irradiancia de $1000 W/m^2$ es interesante desde el punto de comparación del error RMSE y error absoluto. Los cuatro métodos presentan un buen desempeño con errores cercanos a 0.02 incluyendo LPSO y en error absoluto con valores por debajo de 0.04A para LPSO y por debajo de 0.02A para los demás. Además, se observa que todos los algoritmos se ven afectados en el tiempo de procesamiento con variaciones significativas en las 100 simulaciones.

4.2 Cálculo de parámetros y RMSE

4.2.5. Evaluación de algoritmos a distintos valores de temperatura.

En la Tabla 4.9, se observa con más detalle el desempeño de cada algoritmo de optimización a diferentes niveles de temperatura e irradiancia constante. El algoritmo con el mejor desempeño en cuanto exactitud, resaltado sus valores en color azul, es el algoritmo TLBO el cual obtiene valores más bajos de RMSE en niveles de temperatura $T = 20, 40, 60, 80$ ($^{\circ}C$) y el DE solo en $T = 0^{\circ}C$, como se observa en la Tabla 4.7. Sin embargo, los resultados de mejor RMSE entre DE, TLBO y GPSO son muy cercanos entre sí. También se puede observar que el algoritmo TLBO tiene un incremento de tiempo promedio cercano a 1 segundo respecto al cálculo de parámetros en condiciones de irradiancia variable y temperatura constante. Así mismo, el algoritmo DE se muestra como el algoritmo más preciso debido a que su desviación estándar es la más baja. Esto significa que los resultados de sus 100 simulaciones son las menos dispersas, por otra parte el algoritmo LPSO es el que tiene peor desempeño en cuanto a precisión y exactitud. Sin embargo, los errores más bajos de RMSE en LPSO no sobrepasan un error de 0.2.

4.2.6. Estimación de parámetros a diferente valor de temperatura.

El cálculo de los 5 parámetros para el modelo del diodo único a diferentes niveles de temperatura del panel con irradiancia constante son mostrados en la Tabla 4.10, los algoritmos basados en enjambre de partículas presentan los mismos problemas de la Tabla 4.8, los algoritmos tienden a estancarse en mínimos locales llegando a su valor máximo en su rango de búsqueda de los parámetros " R_{sh} " y " a ".

Habiendo calculado los 5 parámetros para diferentes niveles de irradiancia y temperatura, permite obtener las curvas características del panel fotovoltaico como se muestra a continuación.

4.2 Cálculo de parámetros y RMSE

Tabla 4.9: RMSE y desviación estándar para diferente nivel de temperatura

Algoritmo	Mejor RMSE	Peor RMSE	Media RMSE	SD RMSE.	Tiempo promedio
$T = 0^{\circ}\text{C}, G = 1000\text{W}/\text{m}^2, AM = 1.5$					
GPSO	0.022582696	2.074523289	0.275865529	0.503468057	1.073121951
LPSO	0.123889969	5.698644464	0.831815163	0.853891359	1.61642913
TLBO	0.014177487	2.074523289	0.261468905	0.570857602	3.328602513
DE	0.011570927	0.060680649	0.019490094	0.008290522	1.846428398
$T = 20^{\circ}\text{C}, G = 1000\text{W}/\text{m}^2, AM = 1.5$					
GPSO	0.014753705	2.708573169	0.355256087	0.705317314	1.093190419
LPSO	0.13918428	7.093101938	2.795662372	0.796314488	1.673408005
TLBO	0.010863306	2.126380822	0.178532325	0.493170014	3.429378291
DE	0.010879872	0.043186466	0.014383959	0.005183347	1.834584912
$T = 40^{\circ}\text{C}, G = 1000\text{W}/\text{m}^2, AM = 1.5$					
GPSO	0.014649481	0.260843955	0.080654427	0.052101941	1.033190103
LPSO	0.073533375	2.876674343	0.659959332	0.832164867	1.594725896
TLBO	0.013201607	0.130109342	0.048125164	0.026121534	3.236722265
DE	0.013212309	0.02631282	0.01585368	0.002967958	1.787566609
$T = 60^{\circ}\text{C}, G = 1000\text{W}/\text{m}^2, AM = 1.5$					
GPSO	0.009042339	0.285469225	0.102345113	0.06786483	1.040068451
LPSO	0.055797542	3.960339417	0.785096076	0.84819384	1.563810027
TLBO	0.008504183	2.170743732	0.052169928	0.213972227	3.274064737
DE	0.008532773	0.018803375	0.00943974	0.001461071	1.78315795
$T = 80^{\circ}\text{C}, G = 1000\text{W}/\text{m}^2, AM = 1.5$					
GPSO	0.011364759	0.278809047	0.057987648	0.091626957	0.941783524
LPSO	0.020920374	2.872038456	1.520760902	1.183669436	1.465404458
TLBO	0.011358531	0.230268156	0.026703649	0.038012324	2.900494319
DE	0.011361129	0.012138565	0.011472874	0.000123142	1.599858524

4.2 Cálculo de parámetros y RMSE

Tabla 4.10: Estimación de parámetros a diferente temperatura

Algoritmo	$I_{ph}[A]$	$I_0[A]$	$R_s[\Omega]$	$R_{sh}[\Omega]$	$a[V]$
$T = 0^\circ C, G = 1000W/m^2, AM = 1.5$					
GPSO	8.964607847	2.11505E-09	0.132766379	2000	1.8562
LPSO	9.079931393	1.02614E-06	0.000233612	635.130251	2.57
TLBO	8.983009362	9.15252E-10	0.146039596	707.5113882	1.7893
DE	8.985661347	4.58964E-10	0.154538352	525.1575146	1.7374
$T = 20^\circ C, G = 1000W/m^2, AM = 1.5$					
GPSO	9.030920776	1.22515E-08	0.149396942	1489.427579	1.8894
LPSO	8.986832157	2.12336E-06	0.015230045	666.2990243	2.5248
TLBO	9.061399411	1.13919E-08	0.148504476	500.1564547	2.5248
DE	9.062491578	1.09725E-08	0.148978137	481.4966165	1.8793
$T = 40^\circ C, G = 1000W/m^2, AM = 1.5$					
GPSO	9.109992089	2.31394E-07	0.135247662	1994.742737	2.0511
LPSO	9.178375059	5.60102E-06	0.058385571	882.8288785	2.5057
TLBO	9.130837995	1.93264E-07	0.13763239	591.5484513	2.0305
DE	9.127977358	1.8416E-07	0.138528369	625.5983619	2.0250
$T = 60^\circ C, G = 1000W/m^2, AM = 1.5$					
GPSO	9.187600573	2.16317E-06	2.1705 0.133921478	1999.813386	2.1705
LPSO	9.246237045	1.8522E-05	0.070426934	811.1816121	2.5230
TLBO	9.196751862	1.87477E-06	0.136476201	814.5657899	2.1506
DE	9.194928627	1.88042E-06	0.13654335	905.4707132	2.1510
$T = 80^\circ C, G = 1000W/m^2, AM = 1.5$					
GPSO	9.271589931	8.31229E-06	0.156051985	573.1176394	2.1801
LPSO	9.290665655	1.52221E-05	0.143216486	1028.769407	2.2784
TLBO	9.270426344	8.46029E-06	0.155677998	605.7134067	2.1829
DE	9.270231053	8.40334E-06	0.155894749	609.2330458	2.1818

4.2 Cálculo de parámetros y RMSE

4.2.7. Curvas de corriente y potencia contra voltaje.

El objetivo de obtener los parámetros en diferentes niveles de irradiancia y temperatura es determinar las curvas $I-V$ y realizar una comparación con las curvas proporcionadas por el fabricante, mostradas en la Figura 4.12.

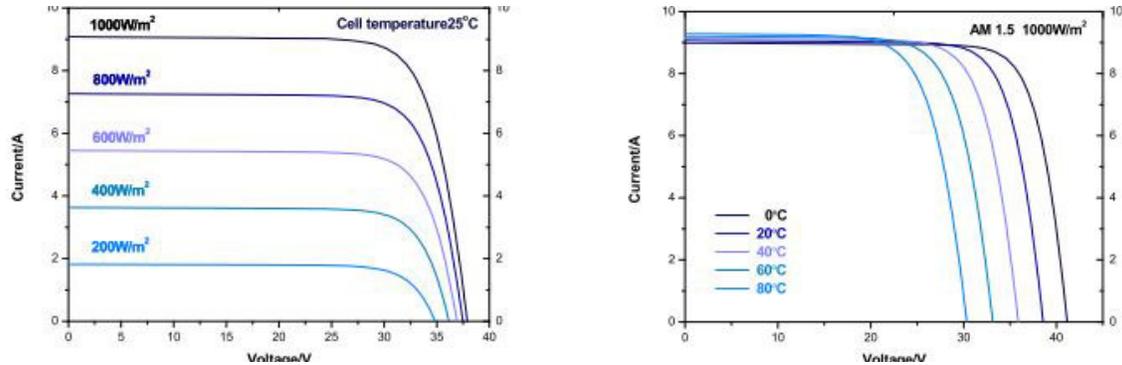
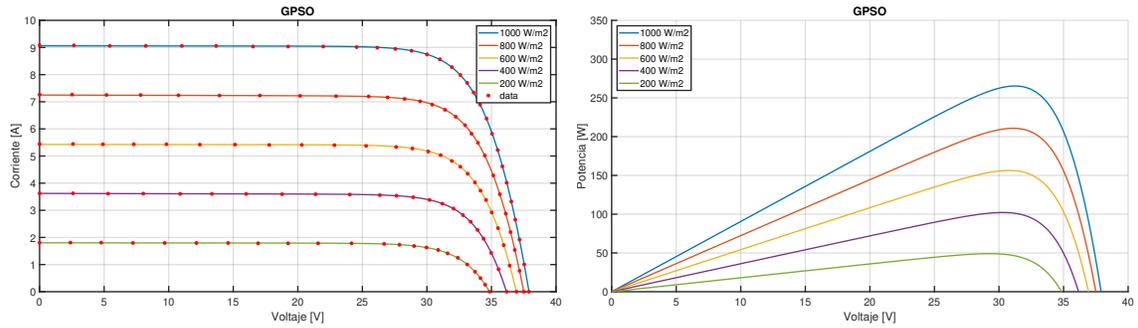


Figura 4.12: Curvas $I-V$ Modulo M-60 Monocrystalline [Tongwei Solar (Hefei) Co., Ltd, 2021].

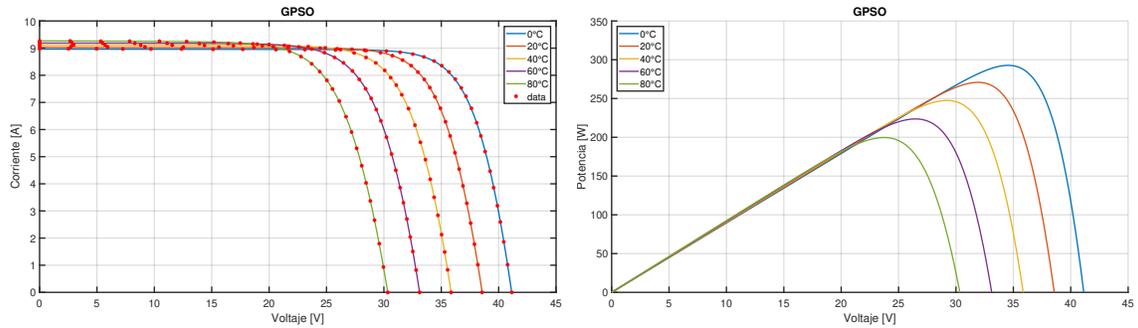
Las Figuras 4.13 a 4.16 se obtienen al sustituir los parámetros de las Tablas 4.8 y 4.10 para determinar la corriente para cada valor de voltaje resolviendo la Ec. (3.11) usando el método iterativo de Newton-Raphson. En las gráficas, se muestran las curvas de corriente-voltaje y potencia-voltaje obtenidas por cada modelo y para diferentes niveles de irradiancia y temperatura en cada algoritmo de optimización. Además, también se incluyen en las gráficas de $I-V$ los valores de la base de datos experimentales de corriente y voltaje usados para calcular los parámetros como referencia. Las Figura 4.13(a) y 4.13(c) muestran una buena concordancia con las curvas proporcionadas por el fabricante presentadas en la Figura 4.12. Adicionalmente, se observa en las curvas un buen ajuste con los valores experimentales de voltaje y corriente utilizados en este experimento, así mismo, es importante destacar que el algoritmo GPSO fue el más rápido según las curvas del tiempo de procesamiento.

Las curvas obtenidas por el algoritmo TLBO se muestran en las Figura 4.14(a) y 4.14(c), donde se puede observar que tienen una buena concordancia con las cur-

4.2 Cálculo de parámetros y RMSE



(a) Gráfica I-V a diferente nivel de irradiancia, (b) Gráfica P-V a diferente nivel de irradiancia,
 $T = 25^{\circ}C$, $AM=1.5$



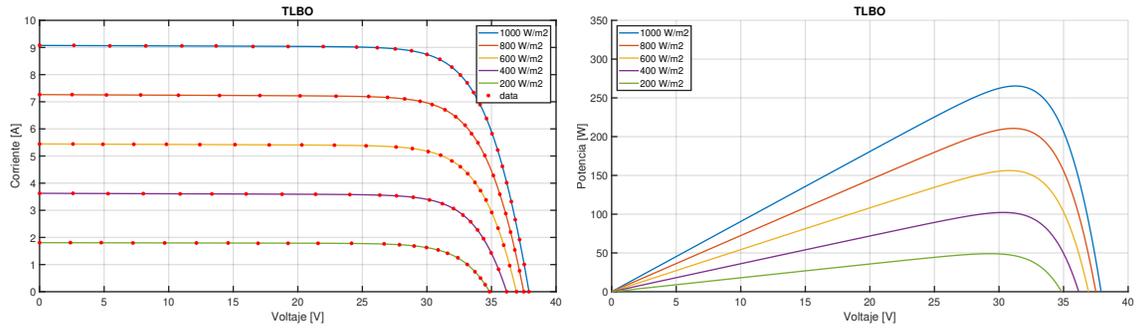
(c) Gráfica I-V a diferente nivel de temperatura, (d) Gráfica P-V a diferente nivel de temperatura,
 $G = 1000 \frac{W}{m^2}$, $AM=1.5$

Figura 4.13: Curvas características obtenidas con el algoritmo GPSO.

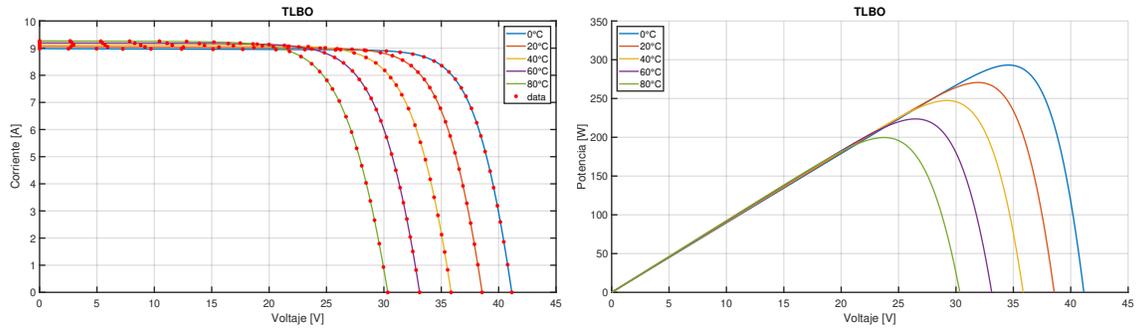
vas proporcionadas por el fabricante. Además, se observa que las curvas tienen un ajuste más suave con los datos experimentales. El algoritmo TLBO se caracterizó en este trabajo por tener el mejor desempeño de exactitud en varias condiciones de irradiancia y temperatura, estas curvas obtenidas muestran la mejor descripción del comportamiento del panel fotovoltaico, sin embargo, en cuestión de tiempo de procesamiento tiene el peor desempeño lo cual para un aplicación en tiempo real DE es más práctico.

En la Figura 4.15, se observan las curvas obtenidas al sustituir los parámetros determinados por el algoritmo LPSO, en ellas se muestra que las curvas obtenidas tienen problemas al ajustarse a la base de datos usada. Este efecto negativo es más

4.2 Cálculo de parámetros y RMSE



(a) Gráfica I-V a diferente nivel de irradiancia, (b) Gráfica P-V a diferente nivel de irradiancia, $T = 25^\circ\text{C}$, $\text{AM}=1.5$



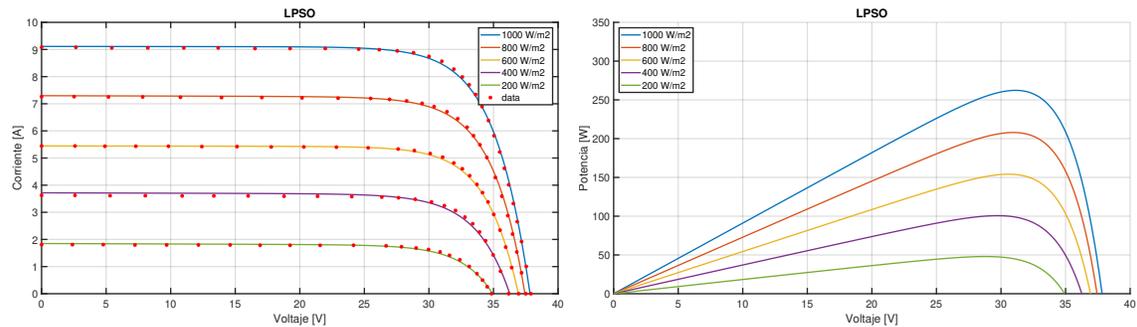
(c) Gráfica I-V a diferente nivel de temperatura, (d) Gráfica P-V a diferente nivel de temperatura, $G = 1000 \frac{\text{W}}{\text{m}^2}$, $\text{AM}=1.5$

Figura 4.14: Curvas características obtenidas con el algoritmo TLBO.

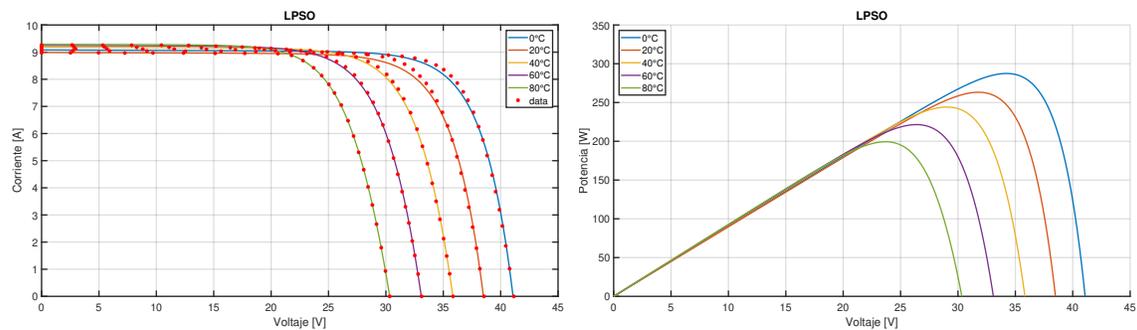
visible en la gráfica Figura 4.15(c) entre los valores de voltaje de 25V y 35V, aunque LSPO tiene el peor desempeño en el cálculo de parámetros, las curvas obtenidas dan una buena aproximación respecto a las curvas proporcionadas por el fabricante.

Por ultimo, en la Figura 4.16 se muestran las curvas obtenidas por el algoritmo DE. En estos resultados, se observar que las curvas obtenidas con el algoritmo de DE, al igual que para el algoritmo TLBO tienen un ajuste más suave a los valores experimentales usados. El algoritmo DE tiene un buen desempeño teniendo un error RMSE similar e incluso superándolo en algunos casos al TLBO. Además, es importante resaltar que DE es el algoritmo más preciso y en la literatura es ampliamente utilizado varias aplicaciones debido a que TLBO es relativamente nuevo.

4.2 Cálculo de parámetros y RMSE



(a) Gráfica I-V a diferente nivel de irradiancia, (b) Gráfica P-V a diferente nivel de irradiancia,
 $T = 25^\circ\text{C}$, $AM=1.5$



(c) Gráfica I-V a diferente nivel de temperatura, (d) Gráfica P-V a diferente nivel de temperatura,
 $G = 1000 \frac{\text{W}}{\text{m}^2}$, $AM=1.5$

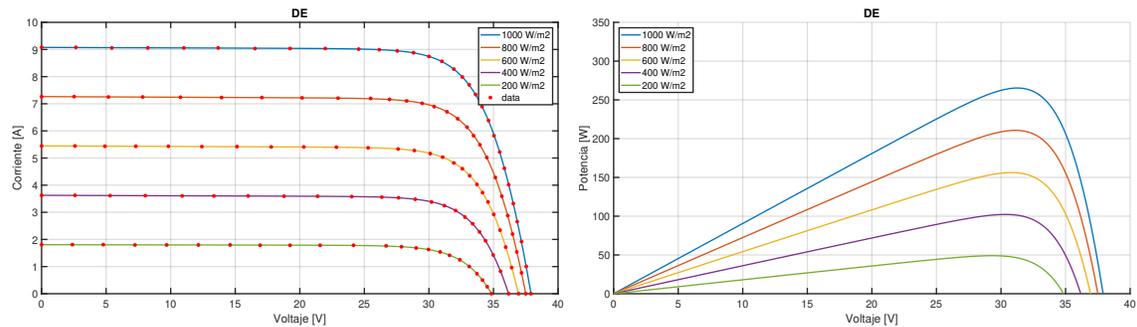
Figura 4.15: Curvas características obtenidas con el algoritmo LPSO.

En términos generales, los resultados numérico permiten detectar que la obtención de las curvas mediante los algoritmos de optimización es muy similar a las curvas proporcionadas por el fabricante. En este tenor, el siguiente paso es determinar el punto de máxima potencia (MPP) como se muestra a continuación.

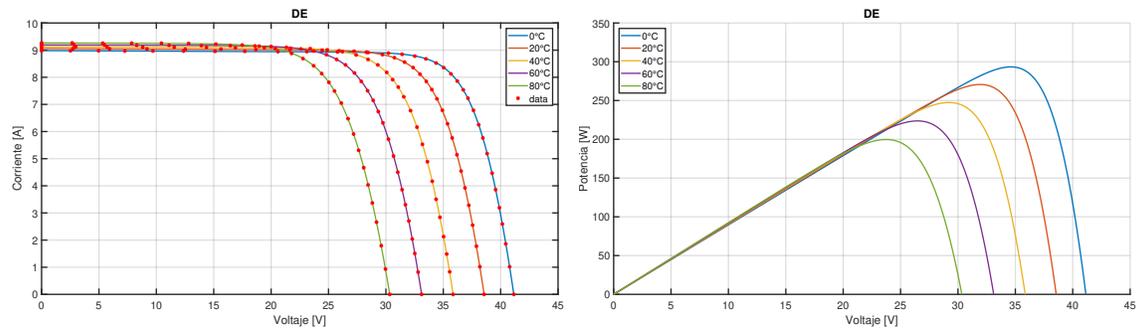
4.2.8. Valores del Punto de Máxima Potencia

Uno de los objetivos de este trabajo es determinar los puntos de máxima potencia (MPP) mediante la determinación de los parámetros ideales para diferentes condiciones de irradiancia y temperatura. Dichos valores son obtenidos mediante el

4.2 Cálculo de parámetros y RMSE



(a) Gráfica I-V a diferente nivel de irradiancia, (b) Gráfica P-V a diferente nivel de irradiancia, $T = 25^{\circ}C$, $AM=1.5$



(c) Gráfica I-V a diferente nivel de temperatura, (d) Gráfica P-V a diferente nivel de temperatura, $G = 1000 \frac{W}{m^2}$, $AM=1.5$

Figura 4.16: Curvas características obtenidas con el algoritmo DE.

algoritmo perturbar y observar (P&O) descrito en la Sección 3.2.4, y son presentados enseguida. Las Tablas 4.11 y 4.12 muestran el valor del voltaje en el punto máximo de potencia en cada curva $I-V$ obtenida. Los valores V_{mpp} calculados son muy similares entre los algoritmos bajo la misma condición de irradiancia y temperatura. La diferencia fundamental entre el valor más alto de voltaje con el más bajo en las mismas condiciones no sobrepasa notablemente los 0.6V. Además, se puede observar que el punto de MPP tiene una variación más amplia con el cambio de temperatura del panel que va desde los 23V a 34V. En este sentido, al calcular los parámetros en distintas condiciones nos permitiría conocer su valor V_{MPP} en distintas condiciones de operación para lo cual será necesario utilizar diversas técnicas de interpolación para estimar valores no comprendidos dentro de las mediciones o curvas encontradas.

4.2 Cálculo de parámetros y RMSE

Tabla 4.11: Voltaje MPP a diferentes valores de irradiancia

Irradiancia	VMPP			
	GPSO	TLBO	LPSO	DE
1000W/m ²	31.233	31.26	31.126	31.261
800W/m ²	31.091	31.102	31.126	31.110
600W/m ²	30.771	30.809	30.587	30.816
400W/m ²	30.291	30.333	29.717	30.335
200W/m ²	29.251	29.292	28.769	29.290

Tabla 4.12: Voltaje MPP a diferentes niveles de temperatura

Temperatura	VMPP			
	GPSO	TLBO	LPSO	DE
0°C	34.545	34.571	34.226	34.607
20°C	31.915	31.9254	31.783	31.927
40°C	29.199	29.211	29.031	29.214
60°C	26.467	26.476	26.386	26.476
80°C	23.734	23.733	23.691	23.734

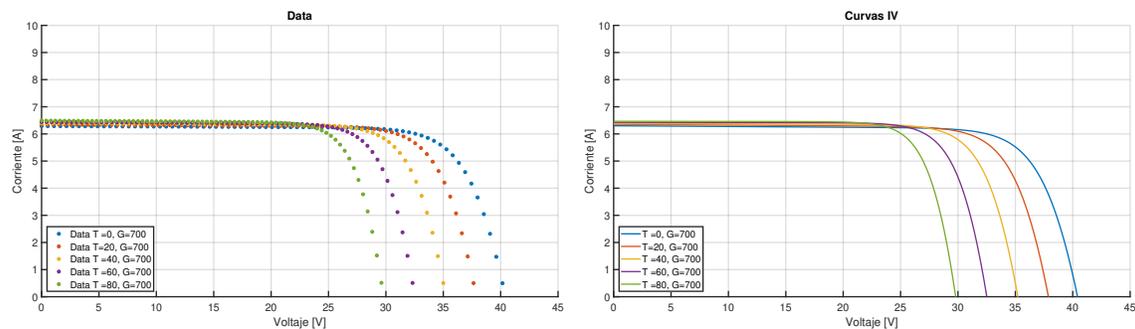
4.2.9. Interpolación

El objetivo de la interpolación en este trabajo es crear una base de datos en cualquier condición de irradiancia y temperatura y de esta manera obtener los 5 parámetros de diodo único mediante un algoritmo de optimización previamente seleccionado. Los parámetros utilizados en este trabajo fueron los calculados por el modelo TLBO, los parámetros de este modelo fueron seleccionados ya que TLBO presentó el mejor desempeño en cuanto exactitud en la mayoría de las condiciones, de esta manera los parámetros calculados por el algoritmo son los que mejor describen el comportamiento del panel fotovoltaico.

Para este trabajo, se pondrá a prueba la interpolación descrita en el Capítulo 3

4.2 Cálculo de parámetros y RMSE

Sección 3.3.2, en condiciones de irradiancia de 700 W/m^2 a temperaturas de $0, 20, 40, 60, 80^\circ\text{C}$. El algoritmo de optimización que se usará para calcular los parámetros será el diferencial evolutivo DE, se eligió este algoritmo debido a que tiene una exactitud muy similar a TLBO pero además su precisión es la mejor entre los algoritmos propuestos.



(a) Base de datos I-V a diferente nivel de temperatura , $G = 700 \text{ W/m}^2$ (b) Gráfica I-V a diferente nivel de temperatura , $G = 700 \text{ W/m}^2$

Figura 4.17: Interpolación obtenidas con el algoritmo DE.

La Figura 4.17 gráfica (a) muestra la obtención de la base de datos mediante la interpolación propuesta y la gráfica (b) muestra las curvas obtenidas al sustituir los parámetros de la Tabla 4.13 obtenidos mediante el algoritmo DE.

Tabla 4.13: Estimación de parámetros a diferente temperatura con irradiancia $G=700 \text{ W/m}^2$

Temperatura	$I_{ph}[\text{A}]$	$I_0[\text{A}]$	$R_s[\Omega]$	$R_{sh}[\Omega]$	$a[\text{V}]$
$G = 700\text{W/m}^2$					
$T = 0^\circ\text{C}$	6.3020	1.59E-08	0.16188	377.0249	2.0436
$T = 20^\circ\text{C}$	6.3319	2.92E-08	0.147862339	1161.612	1.973
$T = 40^\circ\text{C}$	6.40	3.17E-08	0.13561425	435.127	1.8425
$T = 60^\circ\text{C}$	6.43082	2.28E-08	0.12623	706.686	1.6719
$T = 80^\circ\text{C}$	6.47111	1.97E-08	0.11565	1486.02	1.5197

4.3 Discusión

Como se puede observar, el objetivo fue estimar los parámetros en diferentes condiciones, y en este caso es posible hacerlo mediante la interpolación de base de datos experimentales. Por lo que podemos concluir que esta puede ser una herramienta útil para quien trabaja con paneles solares fotovoltaicos.

4.3. Discusión

La simulación numérica fue codificada en una PC de 64 bits con 2,60 GHz de procesador y 4 GB de RAM en plataforma MATLAB. Es posible ver una muy buena concordancia entre las curvas obtenidas por los métodos de optimización con las proporcionadas por el fabricante en la hoja de datos.

A pesar de que el algoritmo LPSO tiene el peor desempeño con el error RMSE y el error absoluto, las curvas de LPSO tienen una aproximación muy cercana a las curvas dadas por el fabricante. Esto es posible a que en términos generales todos los métodos de optimización tienen un desempeño que puede ser aceptable según las condiciones o posiblemente requieren mucha más cantidad de iteraciones para lograr la convergencia a los valores de error deseados.

Además, Es posible observar que GPSO es el algoritmo más rápido, el segundo es LPSO con un tiempo similar a DE, y en la posición más lenta está el TLBO. La precisión observada en los algoritmos de optimización muestra que DE tiene una desviación estándar más estrecha comparado con los demás algoritmos, además, su comportamiento de RMSE es bajo y en algunos casos supera a TLBO.

El algoritmo menos apto para este problema en específico comparado con los demás métodos es sin duda LPSO ya que obtiene el mayor error RSME. Además, los algoritmos TLBO y DE dominan los otros dos métodos en términos de exactitud para todos los valores de irradiancias y temperatura. Las curvas de corriente contra voltaje $I-V$ muestran una muy buena concordancia con las curvas proporcionadas por el fabricante y se ajusta mucho a los datos experimentales usados para este trabajo. Adicionalmente, el error absoluto entre los datos extraídos y los calculados, muestra

4.3 Discusión

que DE, GPSO y TLBO tienen un resultado similar en las gráficas, el cual se puede cuantificar. El punto MPP es muy similar en todos los modelos con una variación muy baja, aquí se puede observar que el cambio de irradiancia no afecta demasiado el valor de voltaje V_{mpp} , ya que los valores son de 29V a 31V, a diferencia de la temperatura la cual varía su voltaje de máxima potencia que va desde 23V a 34V.

La interpolación bilineal a la base de datos presenta buenos resultados, esto hace que sea posible estimar los parámetros dentro del rango de operación del panel fotovoltaico, además, de ser una herramienta útil para quien trabaja con paneles solares fotovoltaicos.

Capítulo 5

Conclusión

Los algoritmos metaheurísticos permiten encontrar de manera óptima los parámetros $P-V$, sin ningún tipo de suposición sobre modelos matemáticos, a diferencia de los tradicionales como basados en gradientes y métodos analíticos. Sin embargo, el inconveniente es restringir los parámetros a un espacio de trabajo alrededor de una posible solución, esto significa tener noción y experiencia sobre el problema tratado. En este trabajo fueron comparados algoritmos heurísticos GP-SO, LPSO, TLBO y DE, utilizando funciones de prueba (benchmark) y mediante el desempeño al estimar los parámetros del panel fotovoltaico.

A partir de los resultados, es posible concluir que los algoritmos TLBO y DE son los mejores para esta tarea específica en términos de exactitud. Este resultado sobre TLBO puede deberse al hecho de que no necesita ajustar parámetros iniciales como velocidad, probabilidad de mutación etc. Sin embargo, en términos de precisión el modelo DE muestra un mejor resultado que los demás algoritmos teniendo una desviación estándar menor que los demás.

En término de tiempo de cálculo, GPSO lleva la ventaja con tiempo medio aproximado de 0.7 segundos en irradiancia variable y cerca de 1 segundo para temperatura variable, mientras que TLBO lo triplica con 2.2 segundos en irradiancia variable y 3 segundos con temperatura variable aproximadamente. Los algoritmos

Conclusión

DE y LPSO tienen resultados muy parecidos con un tiempo promedio de 1.2 y 1.1 segundos en irradiancia variable, y 1.4 y 1.5 segundos con temperatura variable, respectivamente. Por otra parte los resultados obtenidos en las primeras 100 iteraciones se acercan bastante a la solución final. Además, todos los algoritmos presentan una buena concordancia con las curvas presentadas por el fabricante.

Los puntos MPP obtenidos para cada modelo con diferentes niveles de irradiancia y temperatura son muy similares entre los calculados para cada método de optimización. En la parte de la interpolación, es posible estimar los parámetros dentro del rango de operaciones del panel fotovoltaico que en este caso va desde $0^{\circ}C$ a $80^{\circ}C$ y de $200 W/m^2$ a $1000 W/m^2$.

Bibliografía

- [Aly et al., 2019] Aly, S. P., Ahzi, S., and Barth, N. (2019). An adaptive modelling technique for parameters extraction of photovoltaic devices under varying sunlight and temperature conditions. *Applied Energy*, 236(December 2018):728–742.
- [Baquela and Redchuk, 2013] Baquela, E. G. and Redchuk, A. (2013). *Optimización Matemática con R. Volumen I: Introducción al modelado y resolución de problemas*. Bubok Publishing.
- [Bellia et al., 2014] Bellia, H., Youcef, R., and Fatima, M. (2014). A detailed modeling of photovoltaic module using MATLAB. *NRIAG Journal of Astronomy and Geophysics*, 3(1):53–61.
- [Bernardelli, 2010] Bernardelli, F. (2010). Energía solar termodinámica en América Latina. Los casos del Brasil, Chile y México. *Naciones Unidas, CEPAL*, 53:49.
- [Chouder et al., 2012] Chouder, A., Silvestre, S., Sadaoui, N., and Rahmani, L. (2012). Modeling and simulation of a grid connected PV system based on the evaluation of main PV module parameters. *Simulation Modelling Practice and Theory*, 20(1):46–58.
- [Coelho and Castro, 2012] Coelho, A. and Castro, R. (2012). Experimental validation of PV power output prediction models. *2012 IEEE International Conference on Industrial Technology, ICIT 2012, Proceedings*, pages 705–710.
- [Elnagi Mahmoud et al., 2018] Elnagi Mahmoud, M. E., Zaki Diab, A. A., and Kottin, D. A. (2018). Simulation and Experimental Validation of Two-Diode Model of

BIBLIOGRAFÍA

- Photovoltaic (PV) Modules. In *2018 14th International Scientific-Technical Conference on Actual Problems of Electronic Instrument Engineering, APEIE 2018 - Proceedings*, 3, pages 244–251. IEEE.
- [Engelbrecht, 2007] Engelbrecht, A. P. (2007). *Computational Intelligence*. John Wiley & Sons, 2 edition.
- [Hernández Rodríguez and León León, 2016] Hernández Rodríguez, G. M. and León León, E. M. (Mayo 2016). Métodos de Interpolación Multivariable . *Escuela de Matemática Universidad de El Salvador*.
- [Ishaque et al., 2012] Ishaque, K., Salam, Z., Amjad, M., and Mekhilef, S. (2012). An improved particle swarm optimization (PSO)-based MPPT for PV with reduced steady-state oscillation. *IEEE Transactions on Power Electronics*, 27(8):3627–3638.
- [Karamirad et al., 2013] Karamirad, M., Omid, M., Alimardani, R., Mousazadeh, H., and Heidari, S. N. (2013). ANN based simulation and experimental verification of analytical four- and five-parameters models of PV modules. *Simulation Modelling Practice and Theory*, 34:86–98.
- [Kennedy and Eberhart, 1995] Kennedy, J. and Eberhart, R. (1995). Optimización del enjambre de partículas. In *Actas de ICNN'95 - Conferencia internacional sobre redes neuronales*, volume 4, pages 1942–1948 vol.4.
- [Li et al., 2019] Li, S., Gong, W., Yan, X., Hu, C., Bai, D., and Wang, L. (2019). Parameter estimation of photovoltaic models with memetic adaptive differential evolution. *Solar Energy*, 190(July):465–474.
- [Marion et al., 2004] Marion, B., Rummel, S., and Anderberg, A. (2004). Current-voltage curve translation by bilinear interpolation. *Progress in Photovoltaics: Research and Applications*, 12(8):593–607.
- [Metatla et al., 2013] Metatla, A., Talbi, N., and Benzahoul, S. (2013). On the modelling of photovoltaic generators: A comparative study. *2013 8th International*

BIBLIOGRAFÍA

- Conference and Exhibition on Ecological Vehicles and Renewable Energies, EVER 2013*, pages 1–5.
- [Pandey and Sandhu, 2015] Pandey, P. K. and Sandhu, K. S. (2015). Multi diode modelling of PV cell. *India International Conference on Power Electronics, IICPE*, 2015-May(1):1–4.
- [Pearce, 2002] Pearce, J. M. (2002). Photovoltaics - A path to sustainable futures. *Futures*, 34(7):663–674.
- [Posidoniaecosports, 2021] Posidoniaecosports (2021). Cardumen. <https://posidoniaecosports.com/trabajando-como-una-unica-mente-los-cardumenes/>.
- [Price and Price, 2015] Price, K. V. and Price, K. V. (2015). Differential evolution. *Natural Computing Series*, 28:83–93.
- [Rao et al., 2012a] Rao, R. V., Savsani, V. J., and Balic, J. (2012a). Teaching-learning-based optimization algorithm for unconstrained and constrained real-parameter optimization problems. *Engineering Optimization*, 44(12):1447–1462.
- [Rao et al., 2012b] Rao, R. V., Savsani, V. J., and Vakharia, D. P. (2012b). Teaching-Learning-Based Optimization: An optimization method for continuous non-linear large scale problems. *Information Sciences*, 183(1):1–15.
- [Ruiz C et al., 2010] Ruiz C, L. J., Beristáin J, J. A., Sosa T., I. M., and Hernández, H. (2010). Estudio del Algoritmo de Seguimiento de Punto de Máxima Potencia Perturbar y Observar. *Revista De Ingeniería Eléctrica, Electrónica Y Computación*, 8(1):17–23.
- [Smartbitt, 2021] Smartbitt (2021). Radiación solar méxico. <http://energiasolar.smartbitt.com/radiacion-solar/>.
- [Tongwei Solar (Hefei) Co., Ltd, 2021] Tongwei Solar (Hefei) Co., Ltd (2021). Specifications of TW (250 ~ 270) M-60 Monocrystalline solar module. <http://www.tw-solar.com/en/Products/PVModules/5.html>.

BIBLIOGRAFÍA

- [Varadarajan and Swarup, 2008] Varadarajan, M. and Swarup, K. S. (2008). Differential evolutionary algorithm for optimal reactive power dispatch. *International Journal of Electrical Power and Energy Systems*, 30(8):435–441.
- [Wikipedia, 2020] Wikipedia (2020). Test functions for optimization. https://es.qaz.wiki/wiki/Test_functions_for_optimization.
- [Yu et al., 2017] Yu, K., Chen, X., Wang, X., and Wang, Z. (2017). Parameters identification of photovoltaic models using self-adaptive teaching-learning-based optimization. *Energy Conversion and Management*, 145:233–246.
- [Yudong Zhang and Ji, 2015] Yudong Zhang, S. W. and Ji, G. (2015). A Comprehensive Survey on Particle Swarm Optimization Algorithm and Its Applications. *Mathematical Problems in Engineering*, 2015.