

DIAGNÓSTICO DE FALLAS EN UN PANEL FOTOVOLTAICO USANDO UN ALGORITMO GENÉTICO

Jhon Jairo Rojas Montano

Maestría
en Automatización y Control Industrial

Directores: Ms.C. A.F. Tobón Mejía
Ph.D. J. Peláez Restrepo



Institución Universitaria

Instituto Tecnológico Metropolitano
Facultad de Ingenierías
Medellín, 2020

DEDICATORIA

"Nadie que es curioso es tonto. Las personas que no hacen preguntas permanecen ignorantes el resto de sus vidas". Neil deGrasse Tyson

Por eso este trabajo es dedicado a mi familia, quienes me han apoyado en cada paso de mi vida.

*Jhon Jairo Rojas Montano
Medellín, 2019*

AGRADECIMIENTOS

Quiero agradecer al Laboratorio de Electrónica y Energías Renovables del Instituto Tecnológico Metropolitano y a todos sus integrantes por su apoyo en el desarrollo de esta tesis, principalmente a **Andrés Felipe Tobón Mejía** por su apoyo constante en mi carrera de investigación y el desarrollo metodológico de esta tesis. A **Julián Peláez Restrepo** por su acompañamiento en el desarrollo de este trabajo. A **Daniel Gonzalez Montoya** por su asesoría y el conocimiento brindado. A **Luis Fernando Grisales Noreña** por el conocimiento brindado en técnicas de optimización. A **Mariana Durango Flórez** por su apoyo con las pruebas experimentales y finalmente a todos los docentes y compañeros del grupo de investigación que contribuyeron al desarrollo personal y culminación de este trabajo.

ÍNDICE GENERAL

Agradecimientos	V
Índice general	VIII
Índice de figuras	IX
Índice de Tablas	XI
Referencias.	XV
1 Caracterización de perfil V-I de un PV a partir del modelo matemático	1
1.1 Introducción	1
1.2 Conceptos preliminares de un PV.	2
1.2.1 Modelo circuital de un diodo equivalente de un panel PV	4
1.2.2 Modelo de dos diodos equivalente.	4
1.3 Caracterización y Simulación de perfiles PV	5
1.3.1 Simulación De Un Panel Solar	7
1.4 Adquisición De Perfil PV Con La Menor Cantidad De Datos Posibles	8
1.4.1 Método Integral Trapezoidal	8
1.4.2 Conclusiones	9
Referencias.	12
2 Estimación de pesos y determinación de la función objetivo	15
2.1 Introducción	15
2.2 Rango de búsqueda de los parámetros de un módulo PV	16
2.3 Formulación Matemática	18
2.3.1 Función Objetivo	18
2.3.2 Conclusiones	20
Referencias.	21
3 Estimación de parámetros de un PV mediante el uso de un algoritmo de optimización	25
3.1 Introducción	25
3.2 Técnicas de optimización utilizadas para la estimación de parámetros del modelo matemático equivalente de un diodo de un panel PV	26
3.2.1 Algoritmo de búsqueda de patrones mejorado – IPSM	26
3.2.2 Grasshopper Algorithm	33
3.2.3 Algoritmo de Optimización Genético Continuo	40
3.2.4 Conclusiones	44
Referencias.	46
4 Diagnóstico de fallas en un panel PV mediante el uso de un algoritmo genético continuo	49
4.1 Introducción	49
4.2 Tipos de Fallas que se pueden estimar en un panel PV a partir de los parámetros de su modelo matemático equivalente	52
4.3 Diagnóstico de fallas en un panel PV a partir de la estimación de parámetros del SDM de un panel PV.	54
4.3.1 Conclusiones	57
Referencias.	58

5 ANEXOS	61
5.1 Función objetivo del modelo matemático equivalente de un diodo de un panel PV.	61
5.2 Código del Algoritmo Genético Continuo	62
5.3 Artículos publicados en el marco de la investigación de la tesis	65
5.4 Artículos aceptados en el marco de la investigación de la tesis	68
5.5 Artículos sometidos en el marco de la investigación de la tesis	71
Referencias	73
Capítulo 0	73
Capítulo 1	74
Capítulo 2	75
Capítulo 3	79
Capítulo 4	80

ÍNDICE DE FIGURAS

1.1	Partes que componen un Panel solar (Celda, Módulo y Panel PV)	2
1.2	Perfiles de V-P y V-I bajo condiciones estándar	3
1.3	Diagrama del circuito equivalente de un PV con un diodo	4
1.4	Diagrama del circuito equivalente de un PV con dos diodos	5
1.5	Perfiles fotovoltaicos a partir de la función LambertW	7
1.6	Perfiles fotovoltaicos mediante simulación en Matlab/Simulink	8
1.7	Método gráfico integral trapezoidal Tomado de [26]	8
1.8	Cantidad de mínima de puntos requeridos para la representación de un panel PV BP585	10
2.1	Diagrama del circuito equivalente de un PV con un diodo (SDM).	19
3.1	Procedimiento para la estimación de los parámetros del modelo matemático de un panel PV del algoritmo de optimización IPSM	27
3.2	Diagrama de actividades de la optimización IPSM de los parámetros del modelo de la celda fotovoltaica.	28
3.3	Perfiles fotovoltaicos a partir de la función LambertW	29
3.4	Curva experimental del panel BP MSX-60 vs. Modelo matemático estimado aplicando el IPSM.	30
3.5	Curva experimental del panel JS65 vs. Modelo matemático estimado aplicando el IPSM.	30
3.6	Curva experimental del panel KC200GT vs. Modelo matemático estimado aplicando el IPSM.	30
3.7	Curva experimental del panel STP245S vs. Modelo matemático estimado aplicando el IPSM.	30
3.8	Comparación entre los datos de referencia del panel BP MSX-60, la estimación según IPSM y tres estimaciones según PSO.	31
3.9	Comparación entre los datos de referencia del panel JS65 series, la estimación según IPSM y tres estimaciones según PSO.	31
3.10	Comparación entre los datos de referencia del panel KC200GT series, la estimación según IPSM y tres estimaciones según PSO.	32
3.11	Comparación entre los datos de referencia del panel STP245S series, la estimación según IPSM y tres estimaciones según PSO.	32
3.12	Diagrama de flujo de la aplicación propuesta	36
3.13	Diagrama de caja del panel PV (a) MSX60, (b) SOLARJS65, (c) KC200GT y (d) STP245S	37
3.14	Diagrama de caja del rendimiento de los algoritmos de optimización	38
3.15	Simulación con los parámetros encontrados para los errores más bajos y más altos de los módulos PV (a) KC200GT, (b) MSX60 , (c) SOLARJS65 y (d) STP245S.	39
3.16	Minimización del RMSE del modelo de un diodo equivalente de un panel PV por las diferentes técnicas de optimización	44
3.17	Tiempo de procesamiento requerido por cada método en cada tipo de panel PV empleado	44
4.1	Sweep Device Dispositivo eléctrico encargado de realizar los barridos de V-I	51
4.2	Implementación para la adquisición de datos V-I o V-P de un panel PV	51
4.3	Perfil V-P real obtenido con Sweep Device y la menor cantidad de datos representativos	52
4.4	Diagrama representativo de funcionamiento total para el diagnóstico de fallas	53
4.5	Perfiles PV para el diagnóstico de fallas del panel BP585 (1)	56
4.6	Perfiles PV para el diagnóstico de fallas del panel BP585 (2)	56

ÍNDICE DE TABLAS

1.1	Paneles fotovoltaicos y sus características	7
1.2	Resultados integral trapezoidal en generación de la menor cantidad de puntos que permitan generar un perfil PV	9
2.1	Rangos de búsqueda para celdas solares	16
2.2	Rangos de búsqueda celdas de silicio monocristalino	16
2.3	Rangos de búsqueda a partir de la información suministrada por la hoja de datos del fabricante	17
2.4	Restricciones y rango de búsqueda para paneles PV MSX60 y SOLAR JS65	17
2.5	Restricciones y rango de búsqueda para paneles PV KC200GT y STP245S	17
2.6	Paneles fotovoltaicos y sus características definidas por hoja de datos del fabricante	18
3.1	Paneles fotovoltaicos empleados para comparar la curva característica a partir de la hoja de datos del fabricante	29
3.2	Rangos para la estimación de las variables n , I_o , R_{ser} , R_{par} , I_{ph} ([15])	31
3.3	Mínimo global encontrado para: n , I_o , R_{ser} , R_{par} , I_{ph} de 4 paneles diferentes	32
3.4	Error de corriente en las estimaciones.	33
3.5	PV panels characteristic data	34
3.6	Boundaries for parameters evaluation in MSX60 and JS65 solar panels	34
3.7	Boundaries for parameters evaluation in KC200GT and STP245S solar panels	35
3.8	Parámetros de sintonización de PSO	35
3.9	Parámetros de sintonización de GA	35
3.10	Parámetros de sintonización de GOA	35
3.11	Tiempos de ejecución promedio	39
3.12	Paneles fotovoltaicos y sus características	42
3.13	Resultados obtenidos para el SDM	43
4.1	Fallas que se pueden representar a partir de los parámetros del modelo matemático de un panel PV	53
4.2	Paneles fotovoltaicos y sus características principales de la hoja de datos del fabricante	54
4.3	Resultados obtenidos por la técnica de optimización CGA en la estimación de parámetros del SDM	55
4.4	Resultados de los pesos obtenidos a partir de datos reales de un panel PV	55
4.5	Productos derivados de la tesis de maestría	57

INTRODUCCIÓN

Actualmente, en el mundo existe una creciente demanda energética que viene siendo suplida a través de diferentes medios de transformación de electricidad, como combustibles fósiles y energía nuclear, que ponen en riesgo la salud humana y amenazan la estabilidad climática del planeta [1]. Por este motivo, la energía solar aparece como una de las alternativas de fuentes de energías renovables más populares y prometedoras, de las que se encuentran disponibles para satisfacer la demanda energética a nivel mundial [2].

Un panel fotovoltaico (PV, por su nombre en inglés Photovoltaic Panel) es una unidad de potencia de múltiples componentes que transforma directamente la energía solar en eléctrica [3]. Además de esto, el comportamiento del panel puede ser descrito mediante el perfil de voltaje y corriente (V-I), el cual puede ser obtenido mediante un circuito eléctrico equivalente que representa los fenómenos eléctricos que ocurren dentro de los módulos PV. Existen varios modelos matemáticos que satisfacen el comportamiento de un panel PV, entre los más clásicos se encuentran: el modelo de un diodo (SDM, por su nombre en inglés Single Diode Model) y el modelo de dos diodos (DDM, por su nombre en inglés Double Diode Model) [4–6].

La principal diferencia entre el uso de los modelos, es el material utilizado en el panel PV y la cantidad de parámetros que deben estimarse; por un lado, el SDM es comúnmente utilizado para paneles de silicio mono-cristalino y es descrito con cinco parámetros principales, y por otra, el DDM para paneles de silicio policristalino, representado por siete parámetros principales [7, 8]. La estimación de parámetros se realiza con el objetivo de poder conocer el comportamiento de un panel PV ante distintos entornos alejados de las condiciones estándar definidas por la hoja de datos del fabricante [9]. Es muy importante realizar la evaluación de un panel PV que permita pronosticar su comportamiento físico con el objetivo de realizar simulaciones del seguimiento del punto de potencia máxima (MPPT por su nombre en inglés Maximum Power Point Tracking) o hacer estimaciones del desgaste de un panel. Existen varios enfoques de la literatura que permiten extraer los parámetros de un panel PV, los cuales dependen de los perfiles característicos de V-I medidos experimentalmente o por los niveles del seguimiento del MPPT [10–12]. Por lo tanto, en la literatura se han propuesto varios algoritmos de optimización para la estimación de parámetros y diagnóstico de fallas de un panel PV, algunos de los cuales están basados en técnicas estocásticas, tales como técnicas heurística y metaheurística [13].

Dentro de los algoritmos más utilizados en la extracción de parámetros y diagnóstico de fallas en paneles PV son: el método por búsqueda de patrones (PSM, por su nombre en inglés Pattern Search Method) [14], algoritmo basado en forrajeo bacteriano (BFA, por su nombre en inglés Bacterial Foraging Algorithm) [15], optimización de enjambre de abejas artificiales (ABSO, por su nombre en inglés Artificial Bee Swarm Optimization Algorithm) [16], algoritmo de polinización de flor híbrida (BFPA, por sus siglas en inglés), optimización por enjambre de partículas (PSO, por sus siglas en inglés) [8], entre otros, comúnmente usados para la estimación de parámetros de los modelos de uno y dos diodos de un panel PV. Aunque estos métodos de optimización se presentan con probabilidades de obtener soluciones globales, algunos de estos algoritmos como el PSM, BFA, PSO, no son trabajados para la estimación de los cinco y siete parámetros del SDM y DDM.

En la literatura no se ha llegado a realizar la implementación de estimación de parámetros a partir de los datos de V-I obtenidos de un panel PV, debido a que en algunos casos, autores han utilizado datos PV simulados en conjunto con métodos como ABSO, BFPA, donde estas técnicas de optimización han presentado valores de función objetivo con mínimos locales negativos, producto de los bajos niveles de irradiancia bajo los casos de análisis de los perfiles PV. Además de lo mencionado anteriormente, no es claro el poder observar las similitudes de los perfiles PV de V-I o voltaje versus potencia (V-P).

Es por esto que se propone el uso de un Algoritmo Genético (GA, por su nombre en inglés Genetic Algorithm), el cual no ha sido implementado para la estimación de parámetros y diagnóstico de fallas en un panel PV para los modelos SDM y DDM. Por lo tanto, en este trabajo, se propone el uso de un GA continuo, que presenta como ventaja una mejoría en el procesamiento de información, ya que no realiza conversión de binario a decimal, sino que éste hace todos los procesos numéricos directamente en decimal y su población es generada de forma aleatoria. Independientemente del espacio de búsqueda y las variaciones en los niveles de potencia del panel

PV, el algoritmo es capaz de trabajar tanto con el SDM, como el DDM.

OBJETIVO GENERAL

Proponer una metodología basada en algoritmos genéticos, que permita realizar el diagnóstico de un panel fotovoltaico con base a los parámetros del modelo matemático de un diodo.

OBJETIVOS ESPECÍFICOS

- A. Proponer un método que permita estimar los parámetros de la curva característica de un panel fotovoltaico con la menor cantidad de datos posibles, para realizar comparaciones mediante el uso de un algoritmo genético.
- B. Proponer una metodología de asignación de pesos a las variables de la función matemática del modelo de un panel de un diodo ideal.
- C. Desarrollar un método de comparación que permita diagnosticar un panel fotovoltaico con base en los parámetros del modelo matemático de un diodo ideal y los obtenidos del panel fotovoltaico evaluado.

ESTRUCTURA GENERAL DE LA TESIS

En el primer capítulo, se introducen los conceptos básicos de los modelos matemáticos de un panel fotovoltaico, su circuito electrónico equivalente, al igual que su caracterización de perfiles PV de V-I y V-P. Además de esto, se determina el método que define cual es la menor cantidad de datos posibles permitidos para la presentación de dichos perfiles PV.

El segundo capítulo presenta la asignación de pesos para las variables a estimar del SDM de un panel PV y la función objetivo para trabajar.

Posteriormente en el tercer capítulo se presentan las diversas técnicas de optimización utilizadas para la estimación de los parámetros del SDM de un PV y los resultados obtenidos con estos ante condiciones estándar de laboratorio.

En el cuarto capítulo, se muestran los resultados obtenidos experimentalmente, al igual que la validación de la técnica de optimización seleccionada (CGA) en la estimación de los parámetros y el diagnóstico de las posibles fallas que se pueden presentar en un panel PV. Por último, se finaliza el documento con las conclusiones obtenidas en los objetivos.

REFERENCIAS

- [1] M Azab, F Salem, and MI Mosaad. Pv parameters estimation using different evolutionary algorithms. *Journal of Electrical Engineering*, 13(4), 2013.
- [2] Francesco Bonanno, Giacomo Capizzi, G Graditi, C Napoli, and Giuseppe Marco Tina. A radial basis function neural network based approach for the electrical characteristics estimation of a photovoltaic module. *Applied Energy*, 97:956–961, 2012.
- [3] H Wang, Y Liu, M Li, H Huang, HM Xu, RJ Hong, and H Shen. Multifunctional tio₂ nanowires-modified nanoparticles bilayer film for 3d dye-sensitized solar cells. *Optoelectron. Adv. Mater. Rapid Commun*, 4(8):1166–1169, 2010.
- [4] Mohammed Q Taha, Qusay H Eesse, and Salih Mohammed Salih. Mathematical modeling of different photovoltaic modules. *Journal of telecommunications*, 11(2):59–64, 2011.
- [5] B Chitti Babu and Suresh Gurjar. A novel simplified two-diode model of photovoltaic (pv) module. *IEEE journal of photovoltaics*, 4(4):1156–1161, 2014.
- [6] Vivek Tamrakar, SC Gupta, and Yashwant Sawle. Single-diode and two-diode pv cell modeling using matlab for studying characteristics of solar cell under varying conditions. *Electrical & Computer Engineering: An International Journal (ECIJ)*, 4(2):67–77, 2015.
- [7] Kashif Ishaque, Zainal Salam, et al. A comprehensive matlab simulink pv system simulator with partial shading capability based on two-diode model. *Solar energy*, 85(9):2217–2227, 2011.
- [8] JC Sánchez Barroso, JPM Correia, N Barth, S Ahzi, and MA Khaleel. A pso algorithm for the calculation of the series and shunt resistances of the pv panel one-diode model. In *2014 International Renewable and Sustainable Energy Conference (IRSEC)*, pages 1–6. IEEE, 2014.
- [9] Jieming Ma, TO Ting, Ka Lok Man, Nan Zhang, Sheng-Uei Guan, and Prudence WH Wong. Parameter estimation of photovoltaic models via cuckoo search. *Journal of Applied Mathematics*, 2013, 2013.
- [10] Nouredine Maouhoub. Photovoltaic module parameter estimation using an analytical approach and least squares method. *Journal of Computational Electronics*, 17(2):784–790, 2018.
- [11] Giuseppina Ciulla, Valerio Lo Brano, Vincenzo Di Dio, and Giovanni Cipriani. A comparison of different one-diode models for the representation of i–v characteristic of a pv cell. *Renewable and Sustainable Energy Reviews*, 32:684–696, 2014.
- [12] Hugo Nunes, José Pombo, João Fermeiro, Sílvio Mariano, and Maria do Rosário Calado. Particle swarm optimization for photovoltaic model identification. In *2017 International Young Engineers Forum (YEF-ECE)*, pages 53–58. IEEE, 2017.
- [13] Rabah Benkercha, Samir Moulahoum, Ilhami Colak, and Bilal Taghezouit. Pv module parameters extraction with maximum power point estimation based on flower pollination algorithm. In *2016 IEEE International Power Electronics and Motion Control Conference (PEMC)*, pages 442–449. IEEE, 2016.
- [14] MR AlRashidi, MF AlHajri, KM El-Naggar, and AK Al-Othman. A new estimation approach for determining the i–v characteristics of solar cells. *Solar Energy*, 85(7):1543–1550, 2011.
- [15] N Rajasekar, Neeraja Krishna Kumar, and Rini Venugopalan. Bacterial foraging algorithm based solar pv parameter estimation. *Solar Energy*, 97:255–265, 2013.
- [16] Alireza Askarzadeh and Alireza Rezazadeh. Artificial bee swarm optimization algorithm for parameters identification of solar cell models. *Applied Energy*, 102:943–949, 2013.

1

CARACTERIZACIÓN DE PERFIL V-I DE UN PV A PARTIR DEL MODELO MATEMÁTICO

Contenido

1.1	Introducción	1
1.2	Conceptos preliminares de un PV	2
1.2.1	Modelo circuital de un diodo equivalente de un panel PV	4
1.2.2	Modelo de dos diodos equivalente	4
1.3	Caracterización y Simulación de perfiles PV.	5
1.3.1	Simulación De Un Panel Solar	7
1.4	Adquisición De Perfil PV Con La Menor Cantidad De Datos Posibles	8
1.4.1	Método Integral Trapezoidal	8
1.4.2	Conclusiones	9
	Referencias	12

1.1. INTRODUCCIÓN

Con la creciente demanda en las energías renovables y la aplicación de estas en el uso de las microrredes, nuevos retos se afrontan como los relacionados a los sistemas de transformación de energía, entre ellos los paneles fotovoltaicos, los cuales son fundamentales en el uso de las microrredes, ya que estos proveen energía limpia. Los paneles PV, actualmente son prometedores en distintos países, debido a que estos aprovechan la irradiancia solar y la transforman en energía, estos cuentan con una vida útil de aproximadamente 25 años y no precisan de mantenimiento a cortos plazos de tiempo. Por otra parte, existen varios tipos de materiales de fabricación de los panel PV, ya que dependiendo de estos el panel tendrá un efecto en la eficiencia de transformación de energía y su costo económico [1, 2]. Sin embargo, los paneles PV se pueden ver afectados por los cambios climáticos y ocasionar daños que se convierten en pérdidas de energía en los sistemas o arreglos PV. Por esto, una de las principales herramientas que permiten observar el comportamiento de un panel PV es la caracterización de su perfil o perfiles PV de voltaje y corriente (V-I) ya que estos suministran información importante de la energía transformada y las variaciones de estas ante un panel que presente fallos, por otra parte, sirven como herramienta base para el diagnóstico de fallas en un panel PV [3]. La información obtenida por los perfiles PV permite adquirir los parámetros característicos que representan un perfil PV en específico, a partir del modelo matemático de un diodo de un panel PV ideal, los cuales varían entre cinco y siete parámetros de referencia con ecuaciones diferenciales no lineales, el cual depende de su modelo matemático equivalente para este caso si es el SDM o el DDM [4]. El uso de técnicas de optimización, al igual que un conjunto de herramientas computacionales como LABVIEW®, Matlab® y PSIM®, entre otros, permiten obtener valores ideales y calculados mediante la simulación y emulación de los comportamientos estándar de un panel PV [5, 6].

Este capítulo presenta una descripción más detallada del comportamiento de un panel PV, partiendo desde su composición física, su funcionamiento antes los datos de V-I o V-P conocidos comúnmente como los que permiten realizar la representación de un perfil PV ideal, seguido de los conceptos básicos definidos a partir de cada una de las variables que representa la ecuación matemática y el circuito equivalente. Como parte final se muestra la representación de los perfiles PV mediante el software Matlab ® y el análisis matemático para la adquisición de un perfil con la menor cantidad de datos posibles que permitan generar el perfil PV. Esto con el fin de trabajar con la menor cantidad de datos posibles sin perder información importante a la hora de representar el perfil PV.

1.2. CONCEPTOS PRELIMINARES DE UN PV

Un panel PV es un dispositivo electrónico que transforma la luz solar en electricidad, los dispositivos PV están fabricados de materiales que absorben la luz, elevando un electrón a un estado mayor de energía para transportarlo a un circuito externo. Su composición de una gran cantidad de celdas conectadas en serie produce una corriente y un voltaje de unión directo que incide en el material semiconductor del panel los cuales, a escala comercial de fabricación, tienen las celdas PV normalmente fabricadas del material de silicio monocristalino y policristalino con eficiencias de $26,7\% \pm 0,5$ y $22,3\% \pm 0,4$ respectivamente [7]. Con lo anterior mencionado se considera como un grupo de celdas conectadas en serie a un diodo en antiparalelo (diodo de derivación) que conforman un módulo PV y grupos de dos o tres módulos en conexión serie forman un panel PV los cuales son los dispositivos PV comercialmente disponibles en el mercado. La relación entre celdas, módulos y panel PV se puede observar en la Figura 1.1. Así mismo, se puede considerar un panel PV como una fuente generadora de energía variable debido a que el voltaje y la potencia que entrega depende directamente de la radiación solar (G) y de la temperatura ambiente (T) [8].




Figura 1.1: Partes que componen un Panel solar (Celda, Módulo y Panel PV)

Por otra parte, un panel solar puede ser representado mediante un circuito electrónico equivalente, este tiene como objetivo principal representar los perfiles de corriente-voltaje (V-I) o voltaje-potencia (V-P) de un panel PV ante distintas condiciones ambientales. Su comportamiento se puede representar de forma gráfica, como se ve en la Figura 1.2.

Existen varios modelos basados en el circuito eléctrico equivalente de un PV, comúnmente se utiliza SDM




Figura 1.2: Perfiles de V-P y V-I bajo condiciones estándar

y el DDM [9]. Donde cada uno de estos cuenta con diferentes parámetros que deben definirse para realizar el análisis requerido en un panel PV. Es por esto que se definen los parámetros fundamentales que permiten representar un perfil PV.

- **Irradiación solar (G):** Es la potencia irradiada por unidad de área (W/m^2).
- **Temperatura (T):** es la temperatura ambiente del sistema dada en grados centígrados ($^{\circ}C$).
- **Corriente (I):** Es la corriente que entrega el panel PV del sistema en amperios (A).
- **Voltaje (V):** Es el voltaje del panel que se entrega en voltios (V).
- **Voltaje de circuito abierto (V_{oc}):** es el voltaje que se mide a través del panel cuando no pasa corriente por el panel se entrega en (V)
- **Voltaje de punto máximo de potencia (V_{mp}):** es el voltaje donde se encuentra el punto de potencia máximo dado en (V)
- **Corriente de corto circuito (I_{sc}):** es el valor máximo de la corriente dada en (A)
- **Corriente de punto máximo de potencia (I_{mp}):** es la corriente donde se encuentra el punto de potencia máximo dado en (A)
- **Potencia de punto máximo (P_{mp}):** es la potencia máxima que entrega el panel PV dado en (W)

Los paneles PV normalmente son evaluados bajo condiciones de laboratorio o condiciones estándar STC (Standard Test Conditions, por su nombre en inglés) y bajo una irradiancia de $1000 (W/m^2)$ a una temperatura ambiente de $25^{\circ}C$. Entre mayor sea la complejidad del modelo matemático equivalente de un panel PV, mayor será la complejidad para estimar los parámetros. En otras palabras, debe tenerse en cuenta la selección adecuada del modelo matemático equivalente de un panel PV que satisfaga una relación entre precisión y tiempo de procesamiento de la información para la estimación de parámetros. Es por esto que se describe a continuación los modelos SDM y DDM; al igual que la cantidad de constantes y variables a tener en cuenta para el proceso de estimación.

1.2.1. MODELO CIRCUITAL DE UN DIODO EQUIVALENTE DE UN PANEL PV

El SDM es un modelo no lineal, el cual permite representación de los perfiles V-I, al igual que las pérdidas y variaciones de potencia tanto de una celda como de un panel PV, esto a partir de distintos cambios bajo STC [9].

El circuito eléctrico equivalente de un panel PV, consiste en una fuente de corriente en paralelo con un diodo y dos resistencias conectadas, una en paralelo y otra en serie como se muestra en la Figura 1.3, su modelo matemático se expresa en la ecuación (1.1), en donde V_t es el voltaje térmico de la juntura PN del panel PV y depende del N_s , que es el número de celdas conectadas en serie, k es la constante de Boltzmann, T la temperatura del panel y q es la carga del electrón. Finalmente V_{pv} es el voltaje de salida del panel [10–12].




Figura 1.3: Diagrama del circuito equivalente de un PV con un diodo

$$I_{pv} = I_{ph} - I_{d1} \left[e^{\left(\frac{V_{pv} + R_s I_{pv}}{\eta_1 V_t} \right)} - 1 \right] - \left(\frac{V_{pv} + R_s I_{pv}}{R_h} \right) \quad (1.1)$$

$$V_t = \frac{N_s k T}{q} \quad (1.2)$$

Para el modelo matemático equivalente de un diodo la ecuación (1.1), se ajusta para paneles PV con celdas de silicio mono-cristalino. Por lo que su modelo matemático se representa a partir de las siguientes variables más significativas: (η_1) es el factor de idealidad del diodo, (I_{d1}) es la corriente de saturación del diodo, la resistencia en serie (R_s), la resistencia en paralelo (R_h), la corriente foto inducida (I_{ph}) [13, 14].

1.2.2. MODELO DE DOS DIODOS EQUIVALENTE

Por otra parte, un panel PV se puede representar con un modelo equivalente de orden superior al de un diodo. Es por esto que existe el modelo equivalente de dos diodos el cual se puede observar en la Figura 1.4, este se ajusta para paneles con celdas de silicio poli-cristalino y su modelo matemático equivalente se expresa en la ecuación (1.3) [15, 16].

$$I_{pv} = I_{ph} - I_{d1} \left[e^{\left(\frac{V_{pv} + R_s I_{pv}}{\eta_1 V_{t1}} \right)} - 1 \right] - I_{d2} \left[e^{\left(\frac{V_{pv} + R_s I_{pv}}{\eta_2 V_{t2}} \right)} - 1 \right] - \left(\frac{V_{pv} + R_s I_{pv}}{R_h} \right) \quad (1.3)$$

El modelo DDM contiene los mismos parámetros del SDM más dos elementos adicionales, que le agregan una nueva corriente de saturación del diodo (I_{d2}) y un nuevo factor de idealidad del diodo (η_2), lo que lo convierte en dos nuevos parámetros. Por lo tanto, pasa de tener cinco variables a siete. Como se observó en la definición de las variables a estimar en el SDM y DDM, se establece trabajar con el SDM debido a que este modelo matemático equivalente de un diodo de un panel PV contiene cinco parámetros a estimar y contiene menor cantidad de variables, al igual que menor será su proceso de estimación de parámetros.




Figura 1.4: Diagrama del circuito equivalente de un PV con dos diodos

Con lo anterior mencionado y con el punto de partida definido de modelo matemático equivalente a resolver, es necesario obtener un perfil ideal de V-I o V-P de un panel PV que permita representar dicho perfil con la menor cantidad de datos posibles sin perder información importante. Es por esto que se hace uso de la información suministrada en [17]. Replicando así el modelo matemático a partir del uso de la función Lambert W, que permite obtener perfiles PV de cualquier panel solar bajo STC al igual que los parámetros que permiten la representación de dicho perfil ante su modelo matemático equivalente. Todo esto con el fin de garantizar un escenario de pruebas para realizar un diagnóstico de fallas a partir de la estimación de los parámetros y la adquisición de dichos perfiles con la menor cantidad de datos posibles.

1.3. CARACTERIZACIÓN Y SIMULACIÓN DE PERFILES PV

Existen distintos modelos matemáticos que se pueden aplicar a la representación de un perfil PV de un panel solar tal y como se mencionaron anteriormente, entre los métodos más comúnmente usados están los modelos matemáticos y el uso de técnicas inteligentes como la optimización y modelos matriciales de las celdas solares, las cuales son técnicas que comúnmente son utilizadas en la literatura y requieren soluciones de sistemas de ecuaciones no lineales de al menos un segundo orden, lo cual no es fácil de determinar debido a la no linealidad del problema, permitiendo así que no se alcance una convergencia de forma estable ya que se deben determinar los valores de R_h y R_s . Para los cálculos de los primeros tres parámetros I_{ph} , I_o , η , algunos autores toman la R_s como despreciable o es igualada a cero [18–20], otros autores toman la resistencia a partir de un valor inicial y esta va incrementando de forma iterativa hasta alcanzar un punto cercano al cual se ajuste el parámetro y a un error mínimo definido por el usuario, lo que permite determinar la resistencia en paralelo de forma explícita sin resolver ningún tipo de ecuaciones, aunque no garantice una precisión en esta, es la que se ajusta al modelo que permite realizar la representación de un perfil PV de un panel de forma ideal y bajo STC [21, 22]. Por lo anterior mencionado es requerido un proceso que permita a partir de un perfil experimental bajo STC, identificar los parámetros del SDM mediante un proceso inteligente que obtenga los pesos que mejor se ajusten al modelo ideal de un panel PV. Es por esto, que es necesario determinar un método que permita obtener el perfil de V-I característico de un panel PV con la menor cantidad de datos (puntos representativos), satisfaciendo los datos aportados por el fabricante de un panel PV en específico.

Los parámetros mencionados en la sección 1.2.1, son los que permiten determinar un perfil PV de un panel a partir del despeje de estas variables, las cuales son las más representativas. Estas variables son obtenidas a partir del despeje de la ecuación (1.1) y por consiguiente son usadas para que representen un barrido de voltaje de puntos linealmente espaciados hasta V_{oc} , esto con el fin de determinar la corriente del panel PV bajo STC, que permita representar los perfiles de V-I y una aproximación a los parámetros ideales de un panel PV, todo esto a partir de su modelo matemático equivalente [23].

La ecuación (1.1) no admite una solución basada en funciones elementales, pero sí una solución explícita basada en la función Lambert W [24]. Reescribiendo la ecuación (1.1) obtenemos la ecuación (1.4).

$$e^{\left(\frac{R_s}{\eta V_t} I_{pv} + \frac{V_{pv}}{\eta V_t}\right)} = -I_{pv} \frac{R_s + R_h}{R_h I_s} + \frac{(I_{ph} + I_s) R_h - V_{pv}}{R_h I_s} \quad (1.4)$$

Esta ecuación es de la forma dada en la ecuación (1.5).

$$P^{a \cdot x + b} = c \cdot x + d \quad (1.5)$$

Donde P es la base de los logaritmos naturales, $x = I_{pv}$, $a = \frac{R_s}{\eta V_t}$, $b = \frac{V_{pv}}{\eta V_t}$, $c = -\frac{R_s + R_h}{R_h I_s}$ y $d = \frac{(I_{ph} + I_s) R_h - V_{pv}}{R_h I_s}$.
Con la sustitución dada en (1.6) la ecuación (1.5) se convierte en la ecuación (1.7).

$$-t = a \cdot x + \frac{a \cdot d}{c} \quad (1.6)$$

$$t \cdot P^t = -\frac{a}{c} P^{\left(b - \frac{a \cdot d}{c}\right)} \quad (1.7)$$

Por definición de la función trascendente Lambert's W obtenemos la ecuación (1.8), cuya solución está dada en la ecuación (1.9) [24].

$$t = \frac{W\left(-\frac{a}{c} P^{\left(b - \frac{a \cdot d}{c}\right)} \ln(P)\right)}{\ln(P)} \quad (1.8)$$

$$x = -\frac{1}{a \cdot \ln(P)} W\left(-\frac{a \cdot \ln(P)}{c} P^{\left(b - \frac{a \cdot d}{c}\right)}\right) - \frac{d}{c} \quad (1.9)$$

Para el caso del modelo de un solo diodo de la celda fotovoltaica la relación de I_{pv} en función de V_{pv} , según la ecuación (1.9), está expresada en la ecuación (1.10).

$$I_{pv} = \frac{(I_s + I_{ph}) R_h - V_{pv}}{R_s + R_h} - \frac{\eta V_t}{R_s} W\left(\frac{R_s R_h I_s}{(R_s + R_h) \eta V_t} e^{\left(\frac{V_{pv}}{\eta V_t} + \frac{R_s ((I_s + I_{ph}) R_h - V_{pv})}{(R_s + R_h) \eta V_t}\right)}\right) \quad (1.10)$$

Estas ecuaciones son representadas para el modelo matemático el cual no admite una solución basada en funciones elementales, pero sí una solución explícita basada en la función Lambert W [24]. Después de la representación simbólica y el uso de la función Lambert W se puede observar en la Figura 1.5 como mediante la aplicación de estas se representa un perfil PV de distintos paneles solares de distintas potencias, los cuales serán definidos en la Tabla 1.1. Esta presenta de izquierda a derecha, las características básicas como el número de celdas ($N.Celdas$), los valores de potencia máxima (P_{max}), voltaje de máximo punto (V_{max}), corriente de máximo punto (I_{max}) y la corriente de corto circuito (I_{sc}) y ($N.puntos$) es el número de puntos generados para representar el perfil PV.

Panel	BP585	Solar JS65	ERDM30	ERDM10
N. Celdas	36	36	36	36
$P_{max}[W]$	85	65	30	10
$V_{mp}[V]$	18	17.5	17.2	17.4
$I_{mp}[A]$	4.72	3.71	1.74	0.58
$I_{sc}[A]$	5	4.0	1.93	0.63
N. puntos	222	218	217	219

Tabla 1.1: Paneles fotovoltaicos y sus características

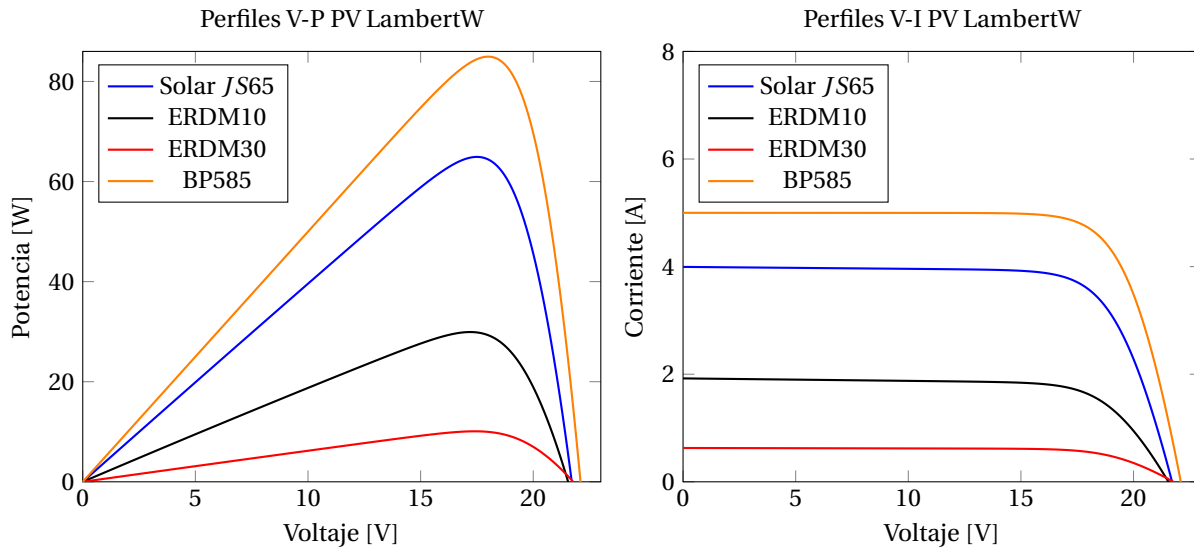


Figura 1.5: Perfiles fotovoltaicos a partir de la función LambertW

Por otra parte al realizar la representación de un perfil PV a partir de la hoja de datos del fabricante y sus ecuaciones matemáticas obtenidas mediante el despeje de estas, se considera necesario compararla con otro método generador de perfiles PV, es por esto que en la siguiente subsección se describe el procedimiento realizado para obtener un método distinto.

1.3.1. SIMULACIÓN DE UN PANEL SOLAR

Como se mencionó anteriormente se requiere representar un panel solar en un software que permita realizar la simulación de su comportamiento, como es el caso de Matlab®. Es por esto que para realizar el diseño, se da uso de las herramientas de Matlab ó la cual es conocida como Simulink en donde se busca uno de los componentes básicos que conforman un panel PV y son las celdas solares, las cuales serán conectadas para un número necesario de celdas hasta que estas conformen un módulo PV y por ende luego agrupar los submódulos PV hasta que estos formen un panel PV. Para nuestro caso de trabajo, se diseña un panel PV celda por celda como se ve en la Figura 1.6. Cuando se completa el diseño del panel solar, a este se le puede modificar la irradiancia (G) y la temperatura (T) para que este puede generar los perfiles fotovoltaicos a distintos niveles de potencia. Para extraer el perfil PV se hace uso de un diodo conectado a la salida positiva del panel PV, con el fin de evitar valores negativos al momento de la adquisición de datos de V-I. Después de realizar la conexión al diodo se le conecta en serie un sensor de corriente el cual va a una fuente controlada de voltaje que es la encargada de realizar el barrido para poder representar el perfil PV en el osciloscopio (scope de Simulink) y poder enviar estos datos a un archivo que los almacenara para estudios futuros.

Con la información obtenida por los generadores de perfiles PV bajo STC, son tomados para determinar un método que permita obtener la menor cantidad de datos posibles de un perfil PV sin que este pierda información importante en su representación.

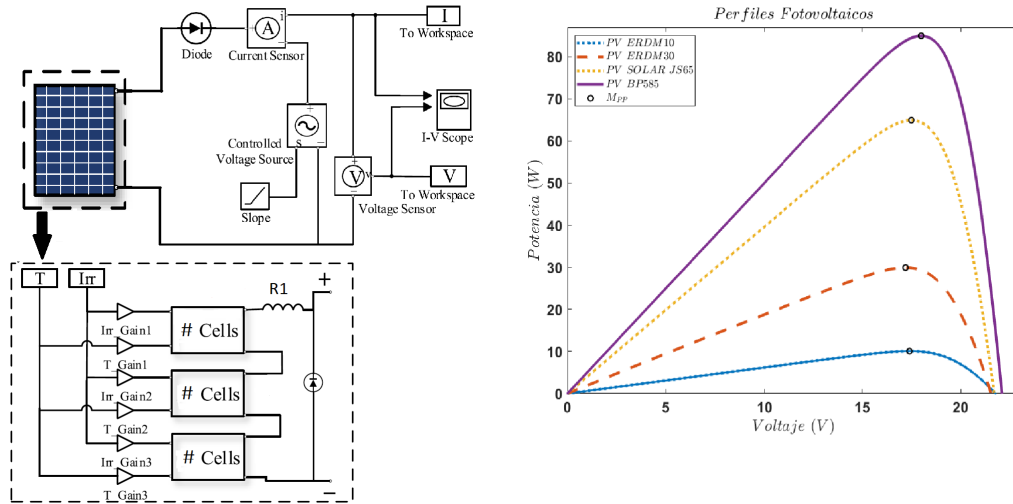


Figura 1.6: Perfiles fotovoltaicos mediante simulación en Matlab/Simulink

1.4. ADQUISICIÓN DE PERFIL PV CON LA MENOR CANTIDAD DE DATOS POSIBLES

Una vez obtenidos los perfiles PV a partir del modelo matemático y su simulación celda a celda, se procede a determinar la cantidad de puntos necesarios con los que fueron generados cada uno de los perfiles PV, cuando se determinan los puntos de cada uno de estos, se procede a disminuir de forma empírica los puntos del perfil PV. Esto se hace con el fin de ver cuántos son los puntos mínimos soportados para su representación PV, ya que estos puntos serán de importancia a la hora de obtener la estimación de los parámetros de un panel PV y el futuro diagnóstico de fallas. Por esto se opta por usar un método numérico que permita determinar esta cantidad de puntos de forma más simple. A continuación se describe el método utilizado.

1.4.1. MÉTODO INTEGRAL TRAPEZOIDAL

El método de la integral trapezoidal o regla del trapecio es un método numérico de integración, que permite calcular de forma aproximada el valor de una integral definida. Es decir, la regla se basa en aproximar el valor de una función $f(x)$ por el de una función lineal, que pasa a través de los puntos de origen a y b , el cual es su punto final en la curva. Tal y como se observa en la Figura 1.7, va de un punto (a) hasta un punto (b) que permite determinar la integral que es igual al área del trapecio [25].




Figura 1.7: Método gráfico integral trapezoidal Tomado de [26]

Como se observa en la Figura 1.7, esta representa de forma visual el uso del método de la integral trapezoidal, la cual es obtenida a partir de una función $\sin(x)$ que es tomada como ejemplo para la implementación del método del trapecio. Dicha función va de un punto inicial (0) a uno final (2π) y es dividida por una cantidad de puntos, que permiten realizar el cálculo del área del trapecio bajo la gráfica de la función.

De acuerdo a lo mencionado en este capítulo, se escoge un panel PV de la Tabla 1.1, cuya referencia es BP585, con el fin de obtener a partir de sus puntos un error mínimo que permita representar el perfil PV sin perder información importante de este. Adquirir un punto base de la menor cantidad de datos posibles para la generación de un perfil PV se hace con la finalidad de disminuir costos de cómputo a la hora de implementar la estimación de los parámetros, mediante técnicas de optimización, y a su vez, facilitar los procesos de adquisición de datos PV. Adicionalmente a esto, los resultados del error serán tomados como base para adquirir datos del mismo panel PV y realizar pruebas en el diagnóstico de fallas. Las Tabla 1.2 de resultados muestra como referencia los puntos que se escogieron para representar el perfil PV, dichas pruebas se pueden observar en la tabla de izquierda a derecha, donde se muestra el número de puntos seleccionados para la representación del perfil PV y el error obtenido al aplicar la integral trapezoidal. Cabe resaltar que esta prueba se realizó de un punto de partida hasta el valor máximo de puntos que se mencionan en la Tabla 1.1. Es decir, que a partir de dos puntos se realizó una gráfica del perfil PV y se fue incrementando la cantidad de puntos hasta llegar a un valor mínimo, en los que este siguiera el perfil PV sin perder mucha información. Como muestra de esto se puede observar en la Fig 1.8 algunos de los puntos seleccionados para observar el comportamiento del perfil PV cuando tiene una menor cantidad de puntos; y estos van incrementándose hasta llegar a una representación cercana a la ideal.

Método de integral trapezoidal	
Número de datos V-P	Error
2	240,90213
6	25,02458
12	4,09648
18	0,71016
32	0,53322
56	0,08363

Tabla 1.2: Resultados integral trapezoidal en generación de la menor cantidad de puntos que permitan generar un perfil PV

1.4.2. CONCLUSIONES

Como se mencionó anteriormente, los datos seleccionados en las gráficas dependen del número de puntos que se desean obtener para que se pueda representar el perfil PV del panel solar. La Fig. 1.8(a) se representa el perfil PV con dos datos de V-P mostrando el error calculado al ser comparado con el perfil PV completo. En la Fig. 1.8(b) se hace representación del perfil PV con seis puntos y su error disminuye respecto al de dos puntos. Esta prueba se realiza en todos los puntos uno a uno hasta llegar a un valor mínimo por eso en el perfil PV de la Fig 1.8(c) se observa como el perfil se va acoplando poco a poco a uno que se asemeje al ideal. En la Fig 1.8(d) se ve cada vez más cercano el ajuste hasta llegar a la Fig 1.8(e) concluyendo con los resultados de los errores por eso, se determinó que la cantidad mínima permitida para la representación de un perfil PV es de 50 datos como se observa en la Fig 1.8(f) ya que este entrega un error por debajo del 0,05% como se observa en la Tabla 1.2 y es un valor mínimo permitido para las futuras estimaciones de parámetros de un panel PV a partir de su modelo matemático equivalente.

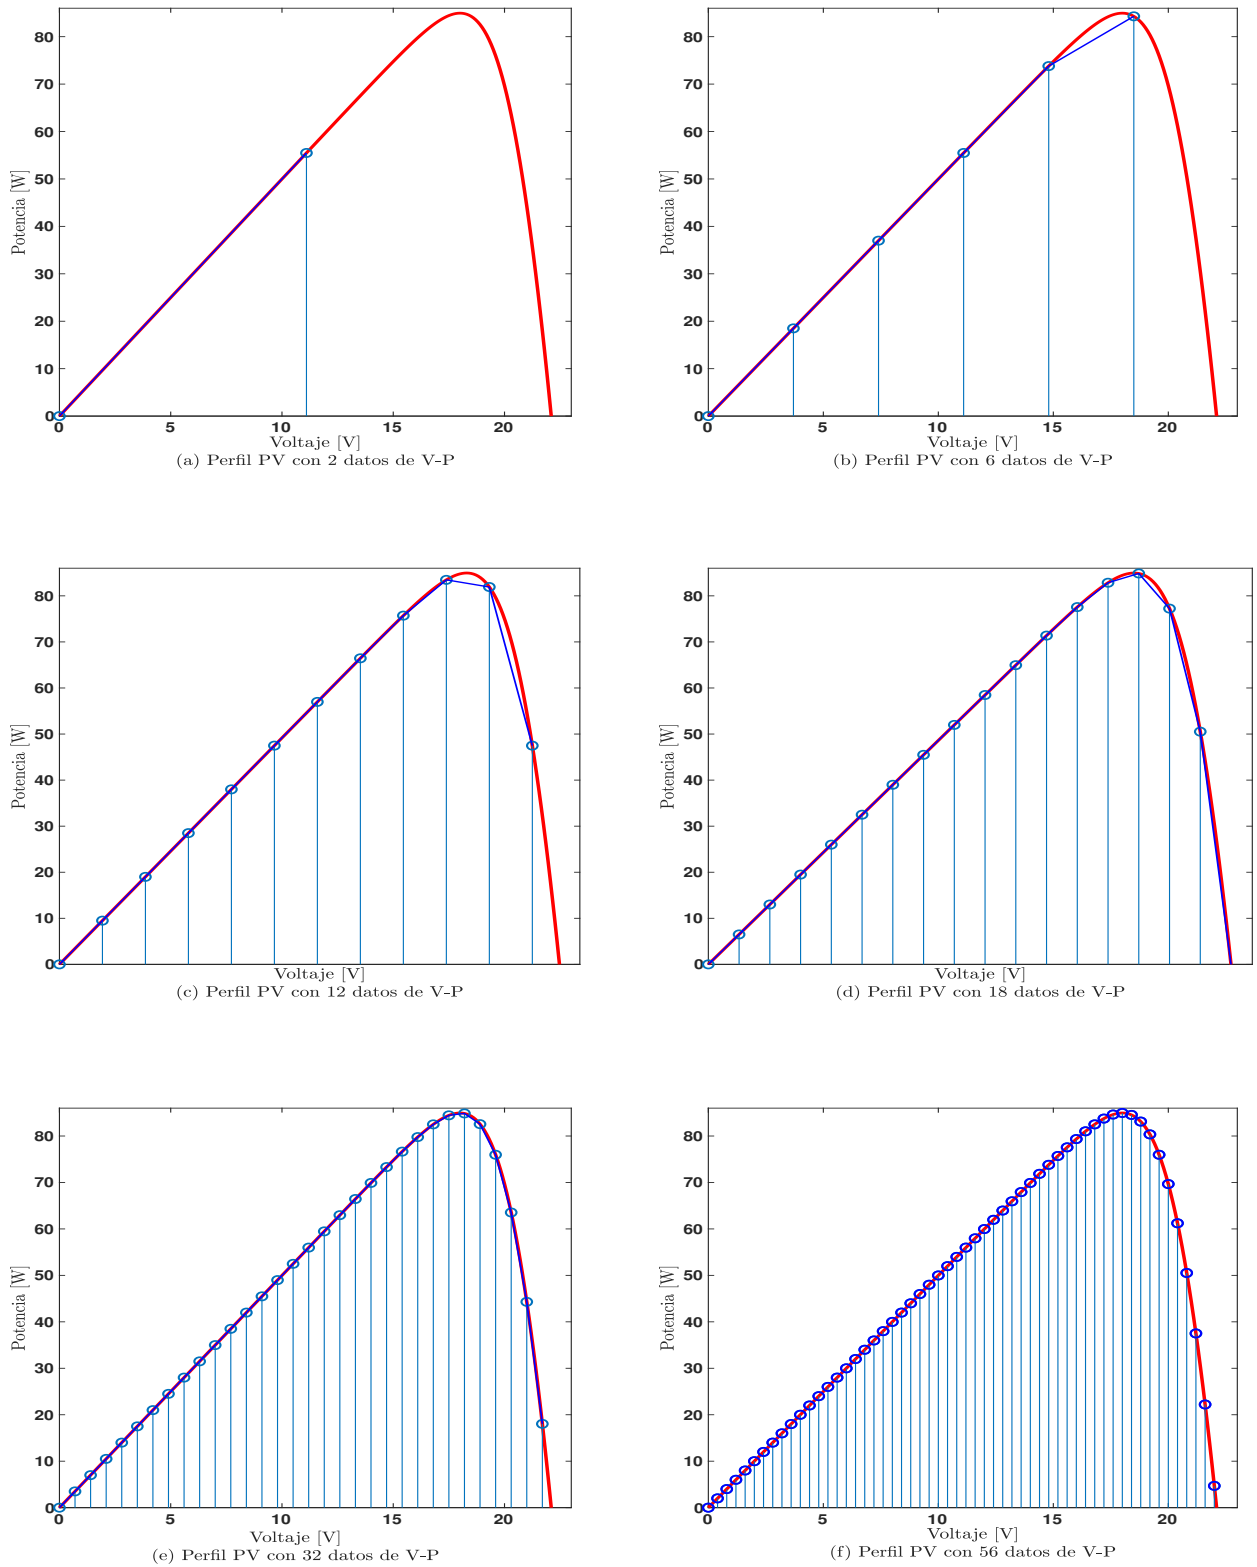


Figura 1.8: Cantidad de mínima de puntos requeridos para la representación de un panel PV BP585

En la búsqueda del cumplimiento del primer objetivo, se realizó la simulación de un panel PV para poder observar su comportamiento, con esta información se logro llevar a la emulación en un computador industrial Speedgoat de MathWorks. Dicho trabajo dio pie a la elaboración de un trabajo del seguimiento de máximo punto de potencia, el cual fue publicado en la revista Energies-MDPI con categorización Q1 [27].

REFERENCIAS

- [1] Ali Q Al-Shetwi, Muhamad Zahim Sujod, and Frede Blaabjerg. Low voltage ride-through capability control for single-stage inverter-based grid-connected photovoltaic power plant. *Solar energy*, 159:665–681, 2018.
- [2] Albert Polman, Mark Knight, Erik C Garnett, Bruno Ehrler, and Wim C Sinke. Photovoltaic materials: Present efficiencies and future challenges. *Science*, 352(6283):aad4424, 2016.
- [3] Nikola L Georgijevic, Marko V Jankovic, Srdjan Srdic, and Zoran Radakovic. The detection of series arc fault in photovoltaic systems based on the arc current entropy. *IEEE Transactions on Power Electronics*, 31(8):5917–5930, 2016.
- [4] Juan David Bastidas-Rodriguez, Giovanni Petrone, Carlos Andrés Ramos-Paja, and Giovanni Spagnuolo. A genetic algorithm for identifying the single diode model parameters of a photovoltaic panel. *Mathematics and Computers in Simulation*, 131:38–54, 2017.
- [5] Nuri Gokmen, Engin Karatepe, Santiago Silvestre, Berk Celik, and Pablo Ortega. An efficient fault diagnosis method for pv systems based on operating voltage-window. *Energy conversion and management*, 73:350–360, 2013.
- [6] Nuri Gokmen, Engin Karatepe, Berk Celik, and Santiago Silvestre. Simple diagnostic approach for determining of faulted pv modules in string based pv arrays. *Solar Energy*, 86(11):3364–3377, 2012.
- [7] Martin A Green, Ewan D Dunlop, Dean H Levi, Jochen Hohl-Ebinger, Masahiro Yoshita, and Anita WY Ho-Baillie. Solar cell efficiency tables (version 54). *Progress in Photovoltaics: Research and Applications*, 27(7):565–575, 2019.
- [8] Shah Arifur Rahman, Rajiv K Varma, and Tim Vanderheide. Generalised model of a photovoltaic panel. *IET Renewable Power Generation*, 8(3):217–229, 2014.
- [9] Kashif Ishaque, Zainal Salam, Saad Mekhilef, and Amir Shamsudin. Parameter extraction of solar photovoltaic modules using penalty-based differential evolution. *Applied Energy*, 99:297–308, 2012.
- [10] Sabir Messalti, Abdelghani Harrag, and Abdelhamid Loukriz. A new variable step size neural networks mppt controller: Review, simulation and hardware implementation. *Renewable and Sustainable Energy Reviews*, 68:221–233, 2017.
- [11] Marcelo Gradella Villalva, Jonas Rafael Gazoli, and Ernesto Ruppert Filho. Comprehensive approach to modeling and simulation of photovoltaic arrays. *IEEE Transactions on power electronics*, 24(5):1198–1208, 2009.
- [12] Dominique Bonkougou, Zacharie Koalaga, and Donatien Njomo. Modelling and simulation of photovoltaic module considering single-diode equivalent circuit model in matlab. *International Journal of Emerging Technology and Advanced Engineering*, 3(3):493–502, 2013.
- [13] Simon Lineykin, Moshe Averbukh, and Alon Kuperman. Five-parameter model of photovoltaic cell based on stc data and dimensionless. In *2012 IEEE 27th Convention of Electrical and Electronics Engineers in Israel*, pages 1–5. IEEE, 2012.
- [14] J Prasanth Ram, T Sudhakar Babu, and N Rajasekar. A comprehensive review on solar pv maximum power point tracking techniques. *Renewable and Sustainable Energy Reviews*, 67:826–847, 2017.
- [15] Sourov Roy, Mohammed Khorshed Alam, Faisal Khan, Jay Johnson, and Jack Flicker. An irradiance-independent, robust ground-fault detection scheme for pv arrays based on spread spectrum time-domain reflectometry (sstdr). *IEEE Transactions on Power Electronics*, 33(8):7046–7057, 2018.
- [16] Charles R Sullivan, Jonathan J Awerbuch, and Alexander M Latham. Decrease in photovoltaic power output from ripple: Simple general calculation and the effect of partial shading. *IEEE Transactions on Power Electronics*, 28(2):740–747, 2013.

-
- [17] J Accarino, G Petrone, CA Ramos-Paja, and G Spagnuolo. Symbolic algebra for the calculation of the series and parallel resistances in pv module model. In *2013 International Conference on Clean Electrical Power (ICCEP)*, pages 62–66. IEEE, 2013.
- [18] Kashif Ishaque, Zainal Salam, and Hamed Taheri. Accurate matlab simulink pv system simulator based on a two-diode model. *Journal of Power Electronics*, 11(2):179–187, 2011.
- [19] Kashif Ishaque and Zainal Salam. An improved modeling method to determine the model parameters of photovoltaic (pv) modules using differential evolution (de). *Solar energy*, 85(9):2349–2359, 2011.
- [20] Kashif Ishaque, Zainal Salam, et al. A comprehensive matlab simulink pv system simulator with partial shading capability based on two-diode model. *Solar energy*, 85(9):2217–2227, 2011.
- [21] Makbul AM Ramli, Ssennoga Twaha, Kashif Ishaque, and Yusuf A Al-Turki. A review on maximum power point tracking for photovoltaic systems with and without shading conditions. *Renewable and Sustainable Energy Reviews*, 67:144–159, 2017.
- [22] Yun Jack Chin, Zainal Salam, and Kashif Ishaque. An accurate and fast computational algorithm for the two-diode model of pv module based on a hybrid method. *IEEE transactions on Industrial Electronics*, 64(8):6212–6222, 2017.
- [23] Jieming Ma. *Optimization approaches for parameter estimation and maximum power point tracking (MPPT) of photovoltaic systems*. PhD thesis, University of Liverpool, 2014.
- [24] Robert M Corless, Gaston H Gonnet, David EG Hare, David J Jeffrey, and Donald E Knuth. On the lambertw function. *Advances in Computational mathematics*, 5(1):329–359, 1996.
- [25] Sever S Dragomir, Pietro Cerone, and Anthony Sofo. Some remarks on the trapezoid rule in numerical integration. *RGMIA research report collection*, 2(5), 1999.
- [26] MATLAB. Matlab: Integración numérica trapezoidal.
- [27] Andrés Tobón, Julián Peláez-Restrepo, Jhon Montano, Mariana Durango, Jorge Herrera, and Asier Ibeas. Mppt of a photovoltaic panels array with partial shading using the ipsm with implementation both in simulation as in hardware. *Energies*, 13(4):815, 2020.

2

ESTIMACIÓN DE PESOS Y DETERMINACIÓN DE LA FUNCIÓN OBJETIVO

Contenido

2.1	Introducción	15
2.2	Rango de búsqueda de los parámetros de un módulo PV	16
2.3	Formulación Matemática	18
2.3.1	Función Objetivo	18
2.3.2	Conclusiones	20
	Referencias	21

2.1. INTRODUCCIÓN

El comportamiento de un panel PV puede ser descrito mediante el perfil de V-I o V-P como se mencionó en el capítulo 1, dicho comportamiento energético puede ser obtenido mediante un circuito eléctrico equivalente que permite representar sus fenómenos eléctricos, los cuales ocurren dentro del material semiconductor del panel PV. Es por esto que el uso del circuito equivalente posibilita obtener medidas de V-I mediante su simulación, facilitando observar el comportamiento del panel bajo sus niveles eléctricos. También es posible obtener estos datos mediante la representación de su modelo matemático equivalente de un diodo de un panel PV, donde a partir del despeje y solución de sus ecuaciones matemáticas, se puede realizar la representación de dichos datos de V-I. Estos métodos se utilizan con la finalidad de adquirir los parámetros que mejor se ajusten a la representación del perfil PV, los cuales se realizan a partir de los datos obtenidos experimentalmente.

Los parámetros de un panel PV pueden ser obtenidos a partir de la Eq. (1.1). Como se menciona en el capítulo 1 estos pueden ser de cinco o siete parámetros, los cuales requieren de un punto de partida que permita obtener información a partir de los valores constantes de la ecuación del panel, y así mismo, usarlos como información para obtener los parámetros desconocidos. Los valores constantes que se pueden identificar normalmente en un panel PV son: el voltaje de circuito abierto del módulo V_{oc} , la corriente de corto circuito I_{sc} y los valores de máximo punto de voltaje V_{mp} y corriente I_{mp} . Estos datos pueden ser obtenidos a partir de la hoja del fabricante, el cual ofrece la información bajo STC, y en caso de no poder obtener los datos de este, es posible saber el comportamiento de un panel PV mediante la adquisición de los valores medidos de V-I o simulaciones de paneles PV [1–6, 6, 7].

Con lo anterior, se deduce que los métodos numéricos son importantes a la hora de resolver la ecuación de un panel PV, ya que mediante el uso de estos métodos, se pueden obtener los valores que mejor se ajusten a cada una de estas variables, que son necesarias para representar su comportamiento físico de V-I del panel [8–10].

Al realizar la estimación de parámetros de un panel PV, este nos permite conocer su comportamiento ante distintos entornos alejados de las condiciones estándar definidas por la hoja de datos del fabricante, ya que, si

un panel presenta variaciones ante la irradiación y la temperatura, pueden variar sus parámetros y su vez el perfil PV en sus niveles de potencia [11]. Es por esto, que se hace necesario el uso de métodos que permitan observar los cambios en los parámetros para determinar las variaciones en los perfiles PV. Con lo anterior y haciendo uso de la literatura especializada, se determinaron varios enfoques que permiten extraer los parámetros de un panel PV, los cuales dependen de los perfiles característicos de (V-I), adquiridos experimentalmente, por los niveles de MPPT [12–14] y por la implementación de algoritmos de optimización para la estimación de parámetros de un panel PV. Muchos de estos algoritmos están basados en métodos analíticos y técnicas estocásticas tales como heurísticas y metaheurísticas [15], el método analítico es usado a partir del despeje de las ecuaciones representativas del SDM o DDM que permiten obtener sus parámetros y recrear su perfil PV [16–18]. Aunque, los métodos analíticos permiten entregar los parámetros representativos de un panel PV, estos métodos son dependientes de las STC iniciales definidas en su modelo matemático equivalente, ya que, si no son definidos de forma precisa, estos no permitirán observar las variaciones en los perfiles PV y sus cambios en potencia, temperatura e irradiación ante condiciones no estándar. Aunque estos métodos no son robustos, no es posible generar variaciones y respuestas ante distintas condiciones reales de operación. En adición a esto, las técnicas de optimización más utilizadas en la extracción de parámetros son: la búsqueda de patrones (PSM) [19], algoritmo basados en forrajeo de bacteria (BFA) [20], optimización de enjambre de abejas artificiales (ABSO, por sus siglas en inglés) [21], algoritmo de polinización de flor híbrida (BFPA), optimización por enjambre de partículas (PSO) [4], entre otros. Aunque estos métodos de optimización son presentados con altas probabilidades de obtener soluciones globales, su solución factible se debe a que el espacio de búsqueda está restringido a un umbral muy cercano a los parámetros que representan los perfiles PV. Por consiguiente, el espacio de búsqueda no tiene un amplio rango, dando lugar a que las técnicas de optimización no tengan una forma libre de búsqueda, ya que al sesgar los rangos solo pueden trabajar con celdas PV y no con módulos o paneles PV, los cuales generan niveles de potencia mayores.

2.2. RANGO DE BÚSQUEDA DE LOS PARÁMETROS DE UN MÓDULO PV

Al implementar algoritmos de optimización en la Eq. (1.1) se necesita de un espacio de búsqueda y restricciones que permitan determinar los parámetros que mejor se ajusten al modelo matemático equivalente del panel bajo análisis y permita representar su perfil PV. El espacio de búsqueda es definido a partir de los límites máximos y mínimos y dependen principalmente de los niveles de corriente (I) y los parámetros de la Eq. (1.1), que son: $[\eta, R_s, R_h, I_{d1}, I_{ph}]$, los cuales fueron definidos en la sección 1.2.1. Distintos autores han adoptado supuestos para establecer dichos rangos de búsqueda, la información de estos rangos es obtenida mediante una revisión sistemática en la literatura especializada permitiendo así obtener un punto de referencia como lo son las celdas silicio de 57 mm [11, 22, 22–24], estos determinaron los rangos a una escala muy pequeña, debido a que las celdas manejan niveles muy bajos de potencia, dando así a cada parámetro de búsqueda un rango fijo de trabajo. Es por esto que, se definen dichos parámetros en la Tabla 2.1 para celdas de silicio monocristalino.

Parámetros	η	R_s [Ω]	R_h [Ω]	I_{d1} [A]	I_{ph} [A]
Límite máximo	2	0.5	100	1	1
Límite mínimo	1	0	0	0	0

Tabla 2.1: Rangos de búsqueda para celdas solares

Otros autores definen rangos de búsqueda a partir I_{ph} y R_h , ampliando los límites máximos y mínimos en los parámetros R_s , I_{d1} y η [25–28]. Dichos rangos se indican a continuación en la Tabla 2.2.

Parámetros	η	R_s [Ω]	R_h [Ω]	I_{d1} [A]	I_{ph} [A]
Límite máximo	2	1	100	1e-5	1
Límite mínimo	0.5	0	0	1e-9	0

Tabla 2.2: Rangos de búsqueda celdas de silicio monocristalino

Por otra parte, diferentes autores definen rangos de búsqueda que varían y son dependientes del tipo de panel PV. Es por esto que se establece como referencia los valores máximos y mínimos en la Tabla 2.3. Los cuales

hacen uso de la información suministrada por la hoja de datos del fabricante y el uso de las siguientes Eq. (2.1), (2.2) y (2.3).

$$I_{ph,STC} = (I_{SC} + \Delta T * K_i) * \frac{G}{G_{STC}} \quad (2.1)$$

$$I_{d,STC} = I_{d1} = \frac{(I_{SC} + \Delta T * K_i)}{e^{-\left[\frac{V_{OC} + \Delta T * k_V}{V_{th}}\right]}} \quad (2.2)$$

$$R_{h,STC} = \frac{V_{mp}}{I_{SC} - I_{mp}} - \frac{V_{OC} - V_{mp}}{I_{mp}} \quad (2.3)$$

Parámetros	η	R_s [Ω]	R_h [Ω]	I_{d1} [A]	I_{ph} [A]
Límite máximo	(2, 50)	2	3000	1e-5	8
Límite mínimo	0.5	0	0	1e-12	0

Tabla 2.3: Rangos de búsqueda a partir de la información suministrada por la hoja de datos del fabricante

Como se observa en la Tabla 2.3, los valores en los límites cambian de forma drástica en comparación a las tablas anteriores, debido a que los autores mencionados, propusieron una representación matemática de un panel PV y su comportamiento ante el material semiconductor, para establecer rangos de búsqueda y esto ocasionó que los rangos máximos establecidos tuvieran una variación en cada parámetro a partir de las ecuaciones y la hoja de datos del fabricante. Razón por la cual se concluye en este trabajo que es fundamental el uso de la hoja de datos del fabricante bajo STC para la obtención del punto inicial de los parámetros. I_{ph} e I_d [27, 29–31]. Los tres parámetros restantes son establecidos a partir de un rango de búsqueda definido por [32] para el límite máximo y mínimo de η mientras que para los otros parámetros se hace uso de el despeje de ecuaciones y la simulación de estos a partir de Matlab, la función lambertW y los métodos de Newton Raphson definidos por los autores [5, 6, 25, 26]. De los anteriores planteamientos se deduce que los rangos de búsqueda o restricciones son tomados como base, al igual que los valores entregados por la hoja de datos del fabricante. Estos datos son tomados como punto de partida dando paso al análisis de la corriente de corto circuito y el factor de idealidad. Para I_{ph} se determina el valor máximo dependiendo del tipo de panel bajo análisis teniendo en cuenta la corriente mencionada anteriormente, y para el valor de η se define a partir de la información suministrada en la literatura especializada, con los datos ya establecidos en [32]. En el caso de los valores de resistencias en serie y paralelo, se hace uso de la información suministrada por [5, 33] y la reproducción de los métodos aplicados por estos autores. Por lo tanto, los rangos de búsqueda para este trabajo son definidos a continuación en la Tabla 2.4 y 2.5

Límites	η	R_s	R_{sh}	I_o	I_{pv}
Max	2	2	400	$1e^{-5}$	5
Min	0.5	0	0	$1e^{-12}$	0

Tabla 2.4: Restricciones y rango de búsqueda para paneles PV MSX60 y SOLAR JS65

Como resultado de la búsqueda en la literatura y el trabajo realizado se consideran estos rangos como los más adecuados para los paneles PV. En la parte de simulación se opta por trabajar con los siguientes paneles solares: MXS60 y SOLAR JS65 en la Tabla 2.4. Se puede observar los distintos parámetros definidos.

Límites	η	R_s	R_{sh}	I_o	I_{pv}
Max	2	2	400	$1e^{-5}$	10
Min	0.5	0	0	$1e^{-12}$	0

Tabla 2.5: Restricciones y rango de búsqueda para paneles PV KC200GT y STP245S

Para los paneles KC200GT y STP2454S se definieron los rangos en la Tabla 2.5. En adición a estos niveles definidos, se adjunta la Tabla 3.12.

Panel	MSX60	JS65	KC200GT	STP245S
N. Celdas	60	36	54	60
P_{max} [W]	60	65	200	245
V_{mp} [V]	17.1	17.5	26.3	30.5
I_{mp} [A]	3.5	3.71	7.61	8.04
I_{sc} [A]	3.8	4.0	8.21	8.52

Tabla 2.6: Paneles fotovoltaicos y sus características definidas por hoja de datos del fabricante

Dicha Tabla presenta de izquierda a derecha, las características básicas. En la primera fila se observa el tipo de panel PV, en la segunda fila el número de celdas $N.Celdas$, la tercera fila contiene los valores de potencia máxima P_{max} , la cuarta fila el voltaje de máximo punto V_{max} , la quinta fila la corriente de máximo punto I_{max} y sexta fila la corriente de corto circuito I_{sc} .

2.3. FORMULACIÓN MATEMÁTICA

Como se mencionó anteriormente, el problema de SDM está ligado a un conjunto de restricciones asociadas a la estimación de parámetros, que permiten determinar los mejores valores que se ajustan al modelo matemático equivalente de un panel PV y a su vez, representan el perfil PV mediante el cálculo de la corriente. A continuación, se presenta toda la información necesaria para determinar la función objetivo en este trabajo. Cabe resaltar que existen distintos métodos de minimización de la función objetivo para la estimación de parámetros de un panel PV.

2.3.1. FUNCIÓN OBJETIVO

La función objetivo es introducida en el SDM para la evaluación y validación de los métodos de optimización [11, 34, 35]. En la búsqueda especializada de la literatura se encontraron diferentes funciones objetivos las cuales serán explicadas a continuación.

La función objetivo definida como la media del valor absoluto (MAE) definida en la Eq. (2.4) [36]. Donde, (N) corresponde a la cantidad de punto generados para el barrido de tensión, ($I_{calculada}$) es la corriente que se calcula a partir de los parámetros estimados por la técnica de optimización, ($I_{experimental}$) es la corriente entregada al adquirir los datos de V-I de un panel PV [36, 37].

$$MAE = \frac{\sum_{i=1}^N |I_{calculada} - I_{experimental}|}{N} \quad (2.4)$$

En [38], se toma al error absoluto relativo (RAE) en la Eq. 2.5, es representado de la siguiente manera .

$$RAE = \frac{\sum_{i=1}^4 |X_{Ci} - X_{Ti}|}{X_{Ti}} \quad (2.5)$$

Donde el i -ésimo índice objetivo y calculado se da como X_{Ti} y X_{Ci} respectivamente.

Otros autores han utilizado la función objetivo expresada en la Eq. 2.6. Donde (J) está en términos de la potencia máxima del panel PV con respecto al voltaje [39, 40].

$$J = \left| \frac{dI}{dV} \right| (V_{mp}, I_{mp}) + \frac{I_{mp}}{V_{mp}} \quad (2.6)$$

Donde V_{mp} representa el voltaje de máximo punto e I_{mp} la corriente de máximo punto. Finalmente, se pueden definir distintas funciones objetivos para la estimación de parámetros de un panel PV; la variación de estas dependerá del punto bajo análisis que se tenga en cuenta para validar los métodos, lo cual dependiendo del punto bajo análisis, estas funciones objetivo cambiarán [19, 41–50].

Con el estudio realizado en la literatura especializada se encontró que una de las funciones objetivo recomendadas es la raíz del error cuadrático medio (RMSE), la cual será aplicada a este trabajo de investigación. Para el problema de estimación de parámetros del SDM, se define como función objetivo (FO) a el RMSE, es decir, el valor a minimizar es el RMSE entre la corriente medida experimentalmente I_{Medida} y la corriente estimada por el método de solución $I_{Estimada}$ ($Error_{total}$); tal y como se presenta en la Eq. (2.7) y (2.8) [51, 52]. Donde, N corresponde a la cantidad de puntos generados para el barrido de tensión, V_{oc} es el voltaje de circuito abierto del panel bajo condiciones estándar y ΔV denota el paso de tensión asignado entre cada punto del barrido de tensión.

$$FO = Min \left(\sqrt{\frac{(Error_{total})^2}{N}} \right) \quad (2.7)$$

$$Error_{total} = \sum_{k=1}^{N=\frac{V_{oc}}{\Delta V}} I_{Medida_{(\Delta V * k)}} - I_{Estimada_{(\Delta V * k)}} \quad (2.8)$$

Cabe resaltar que la ($I_{Estimada}$), es calculada con la Eq. (2.9), mediante el uso del nivel de voltaje del punto bajo análisis, asignado por la sumatoria que representa el barrido de voltaje.

$$I_{pv} = I_{ph} - I_{d1} \left[\exp \left(\frac{V_{pv} + R_s \cdot I_{pv}}{\eta V_t} \right) - 1 \right] - \frac{(V_{pv} + R_s \cdot I_{pv})}{R_h} \quad (2.9)$$

$$V_t = \frac{N_s \cdot k \cdot T}{q} \quad (2.10)$$

En la Eq. (2.9), I_{pv} representa la corriente entregada por el panel PV, la cual es la variable a minimizar, ya que está en función de (η), que es el factor de idealidad del diodo. (I_{d1}) es la corriente de saturación del diodo, (R_s) la resistencia en serie, (R_h) la resistencia en paralelo, (I_{ph}), la corriente fotoinducida del módulo PV y V_{pv} el voltaje de salida del panel [53], [54]. La Eq. (2.9) puede ser representada como un circuito eléctrico equivalente de un módulo PV, que consiste en una fuente de corriente en paralelo con un diodo y dos resistencias conectadas, una en paralelo y otra en serie como se muestra en la Fig. 2.1 [55–57].




Figura 2.1: Diagrama del circuito equivalente de un PV con un diodo (SDM).

La Eq. (2.10), (V_t) representa el voltaje térmico de la junta PN del módulo PV, este depende del N_s ; que es el número de celdas conectadas en serie del panel, k es la constante de Boltzmann, T la temperatura y q la carga del electrón.

2.3.2. CONCLUSIONES

En este capítulo se presentó la estimación de los pesos y determinación de la función objetivo los cuales son de suma importancia para la realización de esta tesis en donde se dará uso de las técnicas de optimización y el diagnóstico de fallas en un panel PV a partir de la estimación de parámetros del SDM de un panel PV. Por lo tanto, se concluye en este capítulo:

- Con el estudio realizado en la literatura especializada se encontró que una de las funciones objetivo más recomendadas para la estimación de los parámetros del SDM de un panel PV es la raíz del error cuadrático medio (RMSE).
- Basados en la información recopilada en la literatura especializada, se logró definir que el espacio de búsqueda a utilizar en la estimación de parámetros es dependiente del tipo de elementos que se deseen trabajar, es decir, si se utiliza una celda, un módulo o un panel PV, los rangos de búsqueda cambiarán ya que esto hace que los parámetros a estimar sean diferentes en cada elemento que se desee trabajar.
- La información suministrada por la hoja de datos del fabricante es fundamental, ya que, esta puede ser crucial a la hora de seleccionar los parámetros que se desean estimar en la función objetivo y a su vez conocer los niveles de potencia generados por el panel PV, al igual que puede ser usada para celdas y módulos PV.

REFERENCIAS

- [1] B Chitti Babu and Suresh Gurjar. A novel simplified two-diode model of photovoltaic (pv) module. *IEEE journal of photovoltaics*, 4(4):1156–1161, 2014.
- [2] Vivek Tamrakar, SC Gupta, and Yashwant Sawle. Single-diode and two-diode pv cell modeling using matlab for studying characteristics of solar cell under varying conditions. *Electrical & Computer Engineering: An International Journal (ECIJ)*, 4(2):67–77, 2015.
- [3] Kashif Ishaque, Zainal Salam, et al. A comprehensive matlab simulink pv system simulator with partial shading capability based on two-diode model. *Solar energy*, 85(9):2217–2227, 2011.
- [4] JC Sánchez Barroso, JPM Correia, N Barth, S Ahzi, and MA Khaleel. A pso algorithm for the calculation of the series and shunt resistances of the pv panel one-diode model. In *2014 International Renewable and Sustainable Energy Conference (IRSEC)*, pages 1–6. IEEE, 2014.
- [5] Kashif Ishaque, Zainal Salam, Saad Mekhilef, and Amir Shamsudin. Parameter extraction of solar photovoltaic modules using penalty-based differential evolution. *Applied Energy*, 99:297–308, 2012.
- [6] Dhiaa Halboot Muhsen, Abu Bakar Ghazali, Tamer Khatib, and Issa Ahmed Abed. A comparative study of evolutionary algorithms and adapting control parameters for estimating the parameters of a single-diode photovoltaic module's model. *Renewable energy*, 96:377–389, 2016.
- [7] A Rezaee Jordehi. Parameter estimation of solar photovoltaic (pv) cells: A review. *Renewable and Sustainable Energy Reviews*, 61:354–371, 2016.
- [8] Rituraj Tamrakar and Archana Gupta. A review: extraction of solar cell modelling parameters. *Int. J. Innovative Res. Electr., Electron., Instrum. Control Eng*, 3(1):55–60, 2015.
- [9] I Nassar-Eddine, A Obbadi, Y Errami, M Agunaou, et al. Parameter estimation of photovoltaic modules using iterative method and the lambert w function: A comparative study. *Energy Conversion and Management*, 119:37–48, 2016.
- [10] L Sandrolini, M Artioli, and U Reggiani. Numerical method for the extraction of photovoltaic module double-diode model parameters through cluster analysis. *Applied Energy*, 87(2):442–451, 2010.
- [11] Jieming Ma, TO Ting, Ka Lok Man, Nan Zhang, Sheng-Uei Guan, and Prudence WH Wong. Parameter estimation of photovoltaic models via cuckoo search. *Journal of applied mathematics*, 2013, 2013.
- [12] Noureddine Maouhoub. Photovoltaic module parameter estimation using an analytical approach and least squares method. *Journal of Computational Electronics*, 17(2):784–790, 2018.
- [13] Giuseppina Ciulla, Valerio Lo Brano, Vincenzo Di Dio, and Giovanni Cipriani. A comparison of different one-diode models for the representation of i–v characteristic of a pv cell. *Renewable and Sustainable Energy Reviews*, 32:684–696, 2014.
- [14] Hugo Nunes, José Pombo, João Fermeiro, Sílvio Mariano, and Maria do Rosário Calado. Particle swarm optimization for photovoltaic model identification. In *2017 International Young Engineers Forum (YEF-ECE)*, pages 53–58. IEEE, 2017.
- [15] Rabah Benkercha, Samir Moulahoum, Ilhami Colak, and Bilal Taghezouit. Pv module parameters extraction with maximum power point estimation based on flower pollination algorithm. In *2016 IEEE International Power Electronics and Motion Control Conference (PEMC)*, pages 442–449. IEEE, 2016.
- [16] Giovanni Petrone, Carlos Andrés Ramos-Paja, and Giovanni Spagnuolo. *Photovoltaic sources modeling*. John Wiley & Sons, 2017.
- [17] Ahmed A El Tayyan. An approach to extract the parameters of solar cells from their illuminated iv curves using the lambert w function. *Turkish Journal of Physics*, 39(1):1–15, 2015.

- [18] Vun Jack Chin, Zainal Salam, and Kashif Ishaque. Cell modelling and model parameters estimation techniques for photovoltaic simulator application: A review. *Applied Energy*, 154:500–519, 2015.
- [19] MR AlRashidi, MF AlHajri, KM El-Naggar, and AK Al-Othman. A new estimation approach for determining the i–v characteristics of solar cells. *Solar Energy*, 85(7):1543–1550, 2011.
- [20] N Rajasekar, Neeraja Krishna Kumar, and Rini Venugopalan. Bacterial foraging algorithm based solar pv parameter estimation. *Solar Energy*, 97:255–265, 2013.
- [21] Alireza Askarzadeh and Alireza Rezazadeh. Artificial bee swarm optimization algorithm for parameters identification of solar cell models. *Applied Energy*, 102:943–949, 2013.
- [22] MF AlHajri, KM El-Naggar, MR AlRashidi, and AK Al-Othman. Optimal extraction of solar cell parameters using pattern search. *Renewable Energy*, 44:238–245, 2012.
- [23] Lian Lian Jiang, Douglas L Maskell, and Jagdish C Patra. Parameter estimation of solar cells and modules using an improved adaptive differential evolution algorithm. *Applied Energy*, 112:185–193, 2013.
- [24] Diego Oliva, Mohamed Abd El Aziz, and Aboul Ella Hassanien. Parameter estimation of photovoltaic cells using an improved chaotic whale optimization algorithm. *Applied Energy*, 200:141–154, 2017.
- [25] Jieming Ma. *Optimization approaches for parameter estimation and maximum power point tracking (MPPT) of photovoltaic systems*. PhD thesis, University of Liverpool, 2014.
- [26] Zhicong Chen, Lijun Wu, Peijie Lin, Yue Wu, and Shuying Cheng. Parameters identification of photovoltaic models using hybrid adaptive nelder-mead simplex algorithm based on eagle strategy. *Applied Energy*, 182:47–57, 2016.
- [27] Wenyin Gong and Zhihua Cai. Parameter extraction of solar cell models using repaired adaptive differential evolution. *Solar Energy*, 94:209–220, 2013.
- [28] O Hachana, KE Hemsas, GM Tina, and C Ventura. Comparison of different metaheuristic algorithms for parameter identification of photovoltaic cell/module. *Journal of renewable and sustainable energy*, 5(5):053122, 2013.
- [29] Yiqun Zhang, Peijie Lin, Zhicong Chen, and Shuying Cheng. A population classification evolution algorithm for the parameter extraction of solar cell models. *International Journal of Photoenergy*, 2016, 2016.
- [30] Rituraj Tamrakar and Archana Gupta. Extraction of solar cell modelling parameters using differential evolution algorithm. *Int. J. Innov. Res. Elec., Electron., Instrument. Contr. Engineering*, 3(11), 2015.
- [31] Yourim Yoon and Zong Woo Geem. Parameter optimization of single-diode model of photovoltaic cell using memetic algorithm. *International Journal of Photoenergy*, 2015, 2015.
- [32] Jeisson Vélez-Sánchez, Juan David Bastidas-Rodríguez, Carlos Andrés Ramos-Paja, Daniel González Montoya, and Luz Adriana Trejos-Grisales. A non-invasive procedure for estimating the exponential model parameters of bypass diodes in photovoltaic modules. *Energies*, 12(2):303, 2019.
- [33] J Accarino, G Petrone, CA Ramos-Paja, and G Spagnuolo. Symbolic algebra for the calculation of the series and parallel resistances in pv module model. In *2013 International Conference on Clean Electrical Power (ICCEP)*, pages 62–66. IEEE, 2013.
- [34] Omnia S Elazab, Hany M Hasanien, Ibrahim Alsaidan, Almoataz Y Abdelaziz, and SM Muyeen. Parameter estimation of three diode photovoltaic model using grasshopper optimization algorithm. *Energies*, 13(2):497, 2020.
- [35] Mohamed A Awadallah and Bala Venkatesh. Optimisation-based parameter estimation of photovoltaic modules. *International Journal of Industrial Electronics and Drives*, 4(1):33–43, 2018.

- [36] Vandana Khanna, BK Das, Dinesh Bisht, PK Singh, et al. A three diode model for industrial solar cells and estimation of solar cell parameters using pso algorithm. *Renewable Energy*, 78:105–113, 2015.
- [37] Humberto Barreto and Frank Howland. *Introductory econometrics: using Monte Carlo simulation with Microsoft excel*. Cambridge University Press, 2006.
- [38] Mohamed A Awadallah and Bala Venkatesh. Estimation of pv module parameters from datasheet information using optimization techniques. In *2015 IEEE International Conference on Industrial Technology (ICIT)*, pages 2777–2782. IEEE, 2015.
- [39] M Ulaganathan and D Devaraj. Real coded genetic algorithm for optimal parameter estimation of solar photovoltaic model. In *2016 International Conference on Emerging Trends in Engineering, Technology and Science (ICETETS)*, pages 1–6. IEEE, 2016.
- [40] Kashif Ishaque and Zainal Salam. An improved modeling method to determine the model parameters of photovoltaic (pv) modules using differential evolution (de). *Solar energy*, 85(9):2349–2359, 2011.
- [41] Huang Wei, Jiang Cong, Xue Lingyun, and Song Deyun. Extracting solar cell model parameters based on chaos particle swarm algorithm. In *2011 International conference on electric information and control engineering*, pages 398–402. IEEE, 2011.
- [42] Mahmoud S Ismail, Mahmoud Moghavvemi, and TMI Mahlia. Characterization of pv panel and global optimization of its model parameters using genetic algorithm. *Energy Conversion and Management*, 73:10–25, 2013.
- [43] Sanjaykumar J Patel, Ashish K Panchal, and Vipul Kheraj. Extraction of solar cell parameters from a single current–voltage characteristic using teaching learning based optimization algorithm. *Applied energy*, 119:384–393, 2014.
- [44] Khaled M El-Naggar, MR AlRashidi, MF AlHajri, and AK Al-Othman. Simulated annealing algorithm for photovoltaic parameters identification. *Solar Energy*, 86(1):266–274, 2012.
- [45] C Saha, N Agbu, and R Jinks. Review article of the solar pv parameters estimation using evolutionary algorithms. *MOJ Solar Photoen Sys*, 2(2):66–78, 2018.
- [46] Mohamed Louzazni, Aurelian Crăciunescu, Alexandru Dumitrache, et al. Identification of solar cell parameters with firefly algorithm. In *2015 Second International Conference on Mathematics and Computers in Sciences and in Industry (MCSI)*, pages 7–12. IEEE, 2015.
- [47] Fayrouz Dkhichi, Benyounes Oukarfi, Abderrahim Fakkar, and Nouredine Belbounaguia. Parameter identification of solar cell model using levenberg–marquardt algorithm combined with simulated annealing. *Solar energy*, 110:781–788, 2014.
- [48] Rongjie Wang, Yiju Zhan, and Haifeng Zhou. Application of artificial bee colony in model parameter identification of solar cells. *Energies*, 8(8):7563–7581, 2015.
- [49] Hany M Hasanien. Shuffled frog leaping algorithm for photovoltaic model identification. *IEEE Transactions on Sustainable Energy*, 6(2):509–515, 2015.
- [50] Arash M Dizqah, Alireza Maheri, and Krishna Busawon. An accurate method for the pv model identification based on a genetic algorithm and the interior-point method. *Renewable energy*, 72:212–222, 2014.
- [51] Nuri Gokmen, Engin Karatepe, Berk Celik, and Santiago Silvestre. Simple diagnostic approach for determining of faulted pv modules in string based pv arrays. *Solar Energy*, 86(11):3364–3377, 2012.
- [52] Shah Arifur Rahman, Rajiv K Varma, and Tim Vanderheide. Generalised model of a photovoltaic panel. *IET Renewable Power Generation*, 8(3):217–229, 2014.

- [53] Simon Lineykin, Moshe Averbukh, and Alon Kuperman. Five-parameter model of photovoltaic cell based on stc data and dimensionless. In *2012 IEEE 27th Convention of Electrical and Electronics Engineers in Israel*, pages 1–5. IEEE, 2012.
- [54] J Prasanth Ram, T Sudhakar Babu, and N Rajasekar. A comprehensive review on solar pv maximum power point tracking techniques. *Renewable and Sustainable Energy Reviews*, 67:826–847, 2017.
- [55] Sabir Messalti, Abdelghani Harrag, and Abdelhamid Loukriz. A new variable step size neural networks mppt controller: Review, simulation and hardware implementation. *Renewable and Sustainable Energy Reviews*, 68:221–233, 2017.
- [56] Marcelo Gradella Villalva, Jonas Rafael Gazoli, and Ernesto Ruppert Filho. Comprehensive approach to modeling and simulation of photovoltaic arrays. *IEEE Transactions on power electronics*, 24(5):1198–1208, 2009.
- [57] Dominique Bonkougou, Zacharie Koalaga, and Donatien Njomo. Modelling and simulation of photovoltaic module considering single-diode equivalent circuit model in matlab. *International Journal of Emerging Technology and Advanced Engineering*, 3(3):493–502, 2013.

3

ESTIMACIÓN DE PARÁMETROS DE UN PV MEDIANTE EL USO DE UN ALGORITMO DE OPTIMIZACIÓN

Contenido

3.1	Introducción	25
3.2	Técnicas de optimización utilizadas para la estimación de parámetros del modelo matemático equivalente de un diodo de un panel PV	26
3.2.1	Algoritmo de búsqueda de patrones mejorado – IPSM	26
3.2.2	Grasshopper Algorithm	33
3.2.3	Algoritmo de Optimización Genético Continuo	40
3.2.4	Conclusiones	44
	Referencias	46

3.1. INTRODUCCIÓN

Un panel PV puede ser representado mediante un circuito eléctrico equivalente, el cual representa los fenómenos eléctricos que ocurren en este [1–4]. Dentro de la literatura especializada es altamente empleado para representar los paneles PV el modelo de un diodo (SDM), el cual es formulado con cinco parámetros principales que permiten emular el comportamiento de un panel PV tal y como se mencionó en la sección 1.2.1. El rango y valor para seleccionar de cada uno de estos parámetros depende del tipo de panel bajo análisis y los niveles de potencia de este como se describió en el capítulo 2, el cual es parte fundamental para el problema de investigación de este trabajo.

Las condiciones climáticas y el desgaste natural del panel por operación modifican los parámetros que representan este dispositivo, como también la capacidad de potencia y su perfil fotovoltaico [5]. La estimación de los parámetros de un panel PV es necesaria para obtener la representación real del perfil PV del panel. Para obtener dichos parámetros, el SDM es usado para formular el modelo matemático del panel PV, el cual combinado con los datos V-I reales del panel; permite estimar los parámetros actuales del panel, mediante la implementación de algoritmos de optimización [6–8].

En este contexto, en la literatura especializada se encuentran diferentes métodos de solución, que permiten extraer los parámetros de un panel PV. Entre los métodos de solución más comunes se encuentran los métodos analíticos y las técnicas estocásticas; tales como heurísticas y metaheurísticas [9], comúnmente llamadas técnicas de optimización. Los métodos analíticos son usados a partir del despeje de las ecuaciones representativas del SDM que permiten obtener los parámetros que mejor se ajusten a la representación del perfil de un panel

solar. Aunque, los métodos analíticos permiten obtener los parámetros representativos de un panel, estos métodos son dependientes de las condiciones iniciales STC definidas en su modelo matemático equivalente. Si no son definidos de forma adecuada, estos, no permitirán observar las variaciones en los perfiles PV, al igual que los cambios en la potencia, temperatura e irradiación ante condiciones no estándar. Aunque estos métodos no son tan complejos, no es posible generar variaciones y respuestas ante distintas condiciones reales de operación [10–12].

El uso de las técnicas de optimización en la estimación de parámetros del modelo SDM, se puede obtener a partir de una celda, un módulo o un panel PV, lo cual depende de la necesidad que se vaya a trabajar. Para el caso de este trabajo de investigación, se hace uso de la estimación de parámetros en un panel PV, donde se describirán las técnicas de optimización aplicadas a este problema. En este proceso de evaluación se buscara en cada técnica de optimización, determinar cual es la técnica que ofrezca una mejor solución en tiempo de computo y minimización de la función objetivo.

3.2. TÉCNICAS DE OPTIMIZACIÓN UTILIZADAS PARA LA ESTIMACIÓN DE PARÁMETROS DEL MODELO MATEMÁTICO EQUIVALENTE DE UN DIODO DE UN PANEL PV

Los algoritmos de optimización se encargan de buscar la mejor alternativa para estimar los parámetros de un panel PV, donde los objetivos de optimización pueden ser minimizar el consumo energético y sus costos, maximizar el beneficio, la producción, el rendimiento o la eficiencia energética; en resumidas cuentas, la optimización puede intervenir en un gran número de áreas del conocimiento, siempre y cuando la expresión a intervenir pueda ser expresada como una función objetivo, es decir que se pueda llevar a un modelo matemático representativo que permita ser usado en un proceso iterativo. Las técnicas de optimización tienen un compromiso consigo mismas ya que al ser métodos estocásticos, dependiendo de su programación y la función objetivo estos deberán obtener un punto de estabilidad entre la precisión, tiempo y recurso computacional.

A continuación, se muestran distintos algoritmos de optimización utilizados para el SDM que permiten brindar solución a las problemáticas anteriormente descritas, este documento propone el uso de las técnicas de optimización que serán mencionadas a continuación: optimización por búsqueda de patrones mejorado (IPSM), optimización por saltamontes (GOA) y el algoritmo de optimización genético continuo (CGA), los cuales garantizan la estimación de parámetros de distintos tipos de paneles PV ante diferentes niveles de potencia. Cada técnica de optimización es validada y comparada. El IPSM es comparado con el PSO y el modelo Newton Raphson el cual entrega el perfil PV ideal, las demás técnicas son comparadas con dos técnicas de optimización, empleadas en la literatura para brindar solución al problema aquí abordado: el PSO y el GA tradicional. Adicionalmente, se emplean 4 tipos de paneles PV para validar la efectividad y robustez de la metodología de solución propuesta.

3.2.1. ALGORITMO DE BÚSQUEDA DE PATRONES MEJORADO – IPSM

El IPSM es un algoritmo que divide el campo de búsqueda en un número de mallas igual al número de variables a optimizar y las cuales están previamente acotadas como se observa en la Fig. 3.1(a). El rango de cada variable a optimizar se divide en n puntos equidistantes y este se encarga de generar todas las posibles combinaciones de búsqueda de las partículas generadas equidistantes. El algoritmo busca los valores de las variables que optimizan la función objetivo. Luego de determinar los valores de las variables, se establecen nuevas mallas cuyo rango estará entre los dos puntos adyacente a los valores hallados como se observa en la Fig. 3.1(b). A modo de ejemplo, si las mallas grandes, Mg , están conformada por n puntos equidistantes entonces cada i -ésima variable está representada en las Eq. (3.1) y Eq. (3.2).

$$Mg_i = [Q_1 \ Q_2 \ Q_3 \ Q_4 \ \dots \ Q_n] \quad (3.1)$$

donde:

$$Q_1 < Q_2 < Q_3 < Q_4 < \dots < Q_n \quad (3.2)$$

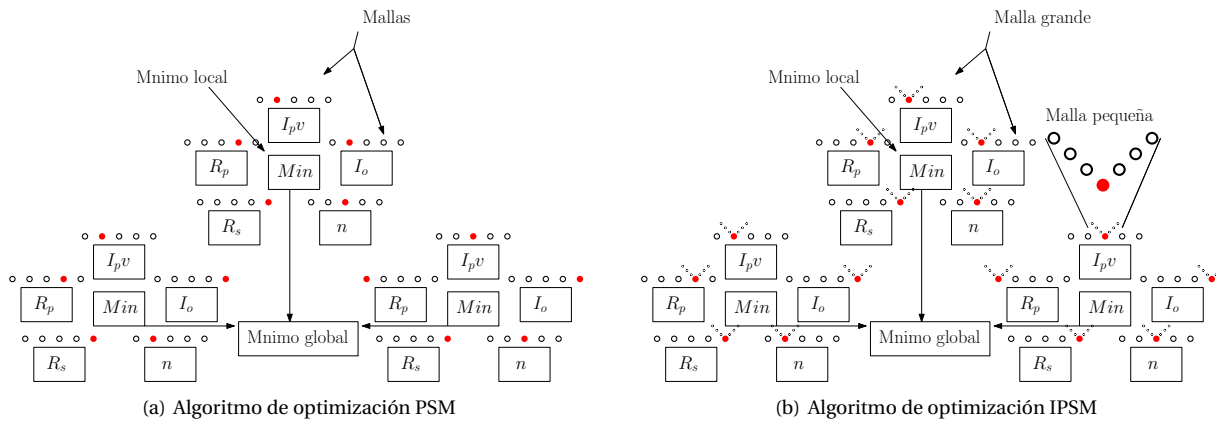


Figura 3.1: Procedimiento para la estimación de los parámetros del modelo matemático de un panel PV del algoritmo de optimización IPSM

Las mallas pequeñas, Mp , estarán conformadas por m puntos alrededor del punto de la malla grande en donde se encuentre el mínimo local hallado previamente a partir de la Eq. (3.3) y Eq. (3.4).

$$Mp_i = [q_1 \ q_2 \ q_3 \ q_4 \ \dots \ q_m] \tag{3.3}$$

donde:

$$q_1 < q_2 < q_3 < q_4 < \dots < q_m \tag{3.4}$$

Como ejemplo, si el mínimo local hallado en la malla grande fue Q_2 , entonces la malla pequeña debe cumplir lo establecido en la Eq. (3.5).

$$Mp_i \in [Q_1 \ Q_3] \tag{3.5}$$

Una vez definidas las mallas grandes, Mg , y pequeñas, Mp , se procede a encuestar cada una de las variables de las mallas grandes y así obtener los valores que más se acercan al punto óptimo de la función objetivo. Estos valores serán el centro de las mallas pequeñas, realizando de nuevo una encuesta, permitiendo así una búsqueda exhaustiva tal y como se observa en la Fig. 3.1(b).

Si se encuentra un nuevo valor que sea cercano al punto óptimo de la función objetivo, este reemplazará al previamente hallado para dicha malla. Por cada iteración se reducen el rango de las nuevas mallas pequeñas, y el algoritmo finaliza después de determinado número de iteraciones o que el error acumulado sea menor que la tolerancia. Para finalizar la búsqueda se puede definir una tolerancia que garantice la exactitud deseada, pero si esta exactitud no puede alcanzarse, el algoritmo quedará en un lazo infinito. Por lo tanto, se recomienda definir un número máximo de iteraciones que sacaría al algoritmo del posible bucle infinito, en caso de que no se alcance la exactitud esperada.

La Figura 3.2 muestra el diagrama de actividades del algoritmo implementado en Matlab®. El algoritmo tiene una actividad de inicialización en la cual se establecen los parámetros del sistema los cuales son los datos de tolerancia, número de partículas, modelo del panel, temperatura, radiación solar, entre otros que permiten que el algoritmo de optimización funcione en conjunto con la función objetivo; los parámetros del panel voltaje de circuito abierto, corriente de corto circuito y punto de operación de máxima potencia, al rango de los parámetros a optimizar resistencia serie y paralela, corriente fotovoltaica, corriente inversa y factor de idealidad del diodo, y finalmente se importan los datos de la curva experimental V-I del panel. En la actividad estructura del tipo "loop" se representan los ciclos anidados que recorren los rangos previamente definidos de los cinco parámetros del SDM que se quieren optimizar son: R_s , R_h , I_{ph} , η e I_s . Además, para cada valor de los cinco parámetros se recorre la curva experimental V-I completa del panel cuyo modelo se desea obtener. La actividad estructurada finaliza luego de recorrer el rango completo de los cinco parámetros del modelo, y la selección de los valores óptimos de dichos parámetros se da de acuerdo a una tolerancia definida establecida por (2.9). Debe tenerse

en cuenta que esta actividad estructurada sirve para modelar las consultas realizadas tanto a las mallas grandes como a las pequeñas.

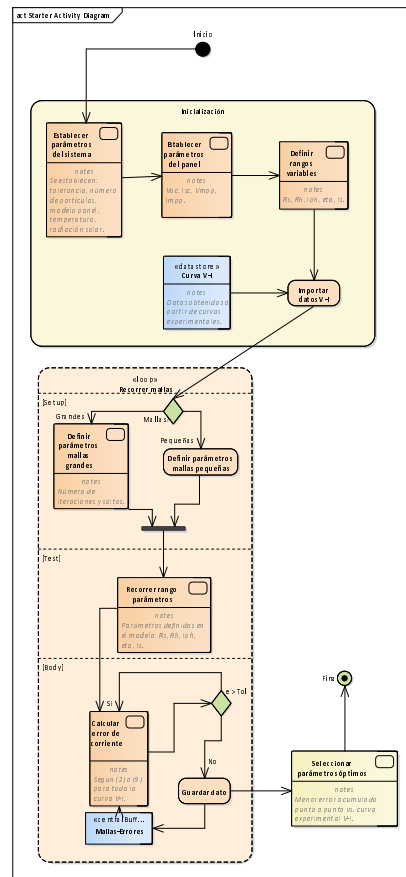


Figura 3.2: Diagrama de actividades de la optimización IPSM de los parámetros del modelo de la celda fotovoltaica.

Finalmente, luego de recorridas las mallas grandes y pequeñas, se obtienen los valores de los parámetros que optimizan el modelo de un diodo de un panel PV, teniendo en cuenta la curva experimental de V-I. El método de búsqueda de patrones mejorado, IPSM, se puede representar por el pseudocódigo del algoritmo 1.

PERFILES PV EXPERIMENTALES

Para poder validar los resultados del experimento realizado con el algoritmo IPSM se generan los datos de las curvas del panel utilizando el algoritmo propuesto por [13], en donde se encuentran los parámetros de un modelo matemático equivalente, generando finalmente las curvas características. Se obtuvieron las curvas V-P y V-I de paneles de uso corriente en la industria. En la Figura 3.3, se pueden observar dos perfiles PV a la izquierda se observa la curva V-P, necesaria para determinar el punto de máxima potencia. Mientras que la figura de la derecha representa el comportamiento del panel con respecto a la salida de corriente, curva V-I. Para las pruebas experimentales se generaron las curvas de cuatro paneles con características diferentes como puede verse en la Tabla 3.1. Las simulaciones del algoritmo que estima el modelo del panel fotovoltaicos usando IPSM a partir de datos V-I experimentales se realizó sobre un computador con procesador Core™ i5, 4 Gb de memoria RAM y un sistema operativo Linux.

Algorithm 1 Método propuesto basado en búsqueda de patrones

```

1:  $R_h \in (50,500)$ ,  $R_s \in (0,2)$ ,  $\eta \in (0,5,2,5)$ ,
2:  $I_s \in (1 \times 10^{-12}, 1 \times 10^{-5})$ ,  $I_{ph} \in (0,10)$ 
3:  $Mod = tmod$  "Tamaño del modelo"
4:  $It = nit$  "Número de iteraciones"
5: for  $Tr = 1 : It$  do
6:   for  $k = 1 : Mod$  "Variación para  $R_h$ " do
7:     for  $m = 1 : Mod$  "Variación para  $R_s$ " do
8:       for  $s = 1 : Mod$  "Variación para  $\eta$ " do
9:         for  $t = 1 : Mod$  "Variación para  $I_s$ " do
10:          for  $r = 1 : Mod$  "Variación para  $I_{ph}$ " do
11:            Evaluar ecuación (1.10) o (2.9)  $[\eta, I_s, R_s, R_h, I_{ph}]$  "Guardar mínimos"
12:          end for
13:        end for
14:      end for
15:    end for
16:  end for
17: end for

```

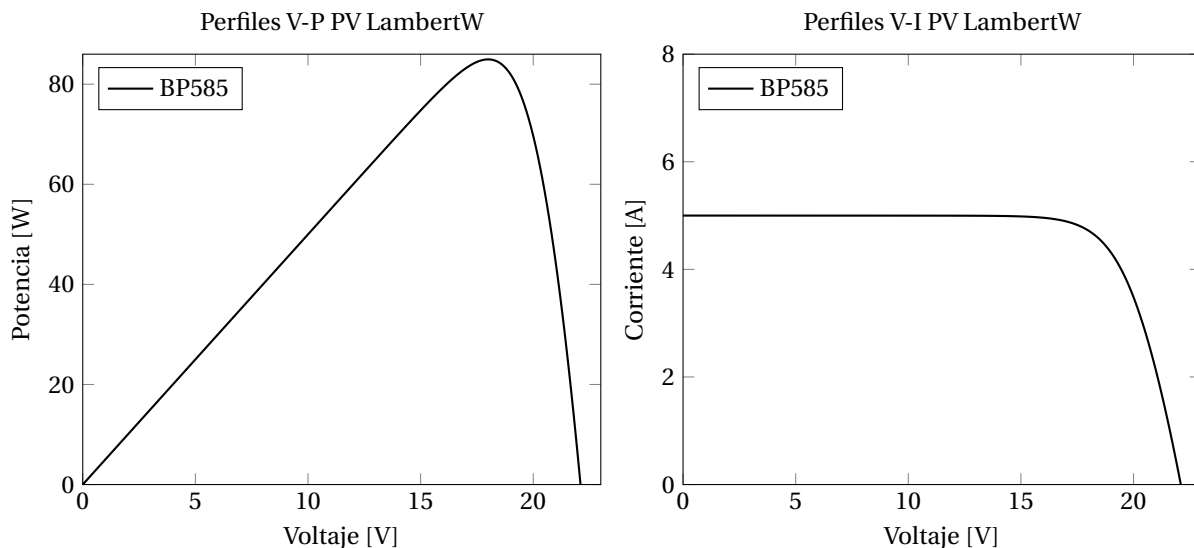


Figura 3.3: Perfiles fotovoltaicos a partir de la función LambertW

Panel	Celdas	$P_{max}(W)$	(V_{mp}, I_{mp})	I_{SC}
MSX60	60	60	(16.8 [V], 3.56 [A])	4.00
JS65 Series	36	65	(18.0 [V], 3.62 [A])	3.85
KC200GT	54	200	(26.3 [V], 7.61 [A])	8.21
STP245S	72	245	(30.5 [V], 8.04 [A])	8.52

Tabla 3.1: Paneles fotovoltaicos empleados para comparar la curva característica a partir de la hoja de datos del fabricante

En las Figuras 3.4(a), 3.5(a), 3.6(a) y 3.7(a) pueden verse la curva V-P estimada y la experimental de los paneles BP MSX-6, JS65 series, KC200GT y STP245S respectivamente. Las Figuras 3.4(b), 3.5(b), 3.6(b) y 3.7(b) muestran un acercamiento al punto de máxima potencia, el cual es el más importante debido a la exigencia de siempre extraer la máxima potencia del panel, y puede observarse que la pérdida de potencia más alta entre el modelo

estimado y el experimental se da para el panel JS65 series, donde la diferencia está por encima del 1.1 %. Para los demás paneles la pérdida en potencia está por debajo del 1%. En los demás sectores de la curva V-P el algoritmo permite una aproximación muy cercana a la ideal.




Figura 3.4: Curva experimental del panel BP MSX-60 vs. Modelo matemático estimado aplicando el IPSM.




Figura 3.5: Curva experimental del panel JS65 vs. Modelo matemático estimado aplicando el IPSM.




Figura 3.6: Curva experimental del panel KC200GT vs. Modelo matemático estimado aplicando el IPSM.




Figura 3.7: Curva experimental del panel STP245S vs. Modelo matemático estimado aplicando el IPSM.

COMPARACIÓN DEL ALGORITMO IPSM CON EL ALGORITMO PSO

La validación del algoritmo de optimización IPSM para la estimación de los parámetros del modelo de un diodo del panel fotovoltaico, se hizo bajo las mismas condiciones, misma cantidad de partículas e iteraciones, contra el algoritmo de optimización PSO (Particle Swarm Optimization) ([14]).

Para la prueba se tomaron 10 partículas con 50 iteraciones en ambos algoritmos de optimización, IPSM y PSO, aplicando los algoritmos a la estimación de los 5 parámetros R_h , R_s , η , I_s and I_{ph} sobre los paneles BP MSX-60, JS65 Series, KC200GT y STP245S, de acuerdo a los rangos que se describen en la Tabla 3.2.

Variable	Límite inferior	Límite superior
R_h (Ω)	5	10000
R_s (Ω)	0	5
η	0,5	2,5
I_s (A)	1×10^{-12}	1×10^{-5}
I_{ph} (A)	0	10

Tabla 3.2: Rangos para la estimación de las variables n , I_o , R_{ser} , R_{par} , I_{ph} ([15])

Los resultados se exponen en las Figuras 3.8, 3.9, 3.10 y 3.11, para los paneles BP MSX60, JS65 Series, KC200GT y STP245S respectivamente. Las Figuras muestran la curva experimental de cada uno de los paneles, línea azul continua, la optimización obtenida con IPSM, línea punteada roja, y tres aproximaciones obtenidas con PSO de 10 partículas.




Figura 3.8: Comparación entre los datos de referencia del panel BP MSX-60, la estimación según IPSM y tres estimaciones según PSO.




Figura 3.9: Comparación entre los datos de referencia del panel JS65 series, la estimación según IPSM y tres estimaciones según PSO.




Figura 3.10: Comparación entre los datos de referencia del panel KC200GT series, la estimación según IPISM y tres estimaciones según PSO.




Figura 3.11: Comparación entre los datos de referencia del panel STP245S series, la estimación según IPISM y tres estimaciones según PSO.

Como el algoritmo de optimización PSO depende de la aleatoriedad se ejecutó tres veces para cada uno de los paneles, mientras que el algoritmo de optimización IPISM solo se ejecutó una vez, ya que siempre arroja el mismo resultado. Los parámetros obtenidos usando IPISM y que hacen que el modelo de un solo diodo se asemeje más a la curva de referencia se pueden observar en Tabla 3.3.

Panel	R_h (Ω)	R_s ($m\Omega$)	η	I_s (μA)	I_{ph} (A)
MSX60	9502,56	48,23	0,9915	3,7693	3,8002
JS65	3591,17	42,44	1,6744	5,0849	4,0046
KC200GT	7836,73	48,23	1,0810	6,7323	8,2137
STP245S	3915,08	96,45	0,7608	2,4614	8,0941

Tabla 3.3: Mínimo global encontrado para: n , I_o , R_{ser} , R_{par} , I_{ph} de 4 paneles diferentes

La Tabla 3.4 muestra el error absoluto de corriente, de acuerdo con la función objetivo, para las estimaciones hechas para los cuatro paneles utilizando el algoritmo IPISM y el mejor caso del algoritmo PSO. Nótese que el error de la estimación realizada con el algoritmo IPISM siempre es menor que la obtenida en el mejor caso con el PSO. Por ejemplo, para el MSX60 el menor error obtenido con PSO es el 250,1 % más que el error obtenido con el algoritmo IPISM. El caso en el cual las dos estimaciones tuvieron el error de corriente más semejante, fue para la estimación PSO 1 (trazo verde en la Figura 3.9) del panel JS65, donde el error con el PSO fue el 77,1 % más que el error obtenido con el algoritmo IPISM.

Sin embargo, cabe anotar que no todas las estimaciones con el algoritmo PSO convergen, por ejemplo, la estimación PSO3 en los paneles JS65 series, KC200GT y STP245S muestran que el modelo no sigue a la referencia, y por eso este algoritmo, a diferencia del IPISM, no garantiza la convergencia en todos los casos.

Panel	$Error_{IPSM} (A)$	$Error_{PSO} (A)$	Relación
BP MSX60	1,0516	3,6813	250,1%
JS65 Series	3,0753	5,4471	77,1%
KC200GT	13,7053	46,5502	239,7%
STP245S	11,1318	42,8387	284,8%

Tabla 3.4: Error de corriente en las estimaciones.

Finalmente, para obtener el modelo matemático de un diodo para cada uno de los cuatro paneles comerciales considerados en este trabajo, se debe reemplazar en el SDM los parámetros mostrados en la Tabla 3.3.

3.2.2. GRASSHOPPER ALGORITHM

El algoritmo de optimización Grasshopper (GOA) se clasifica como bio-inspirado, imita la conducta de los saltamontes [16], insectos que dependiendo de su posición en el ciclo de vida (larva, ninfa, o adulto), tienden a vivir solos o en enjambres, los cuales tienen una relación directa con la manera en la que se mueven y buscan una fuente de comida; en la fase de larva, sus movimientos son lentos y tienen corto alcance, en contraste con los movimientos amplios y abruptos típicos de la fase adulta. En la fase ninfa, es prudente mencionar que los enjambres se mueven como cilindros rodantes.

Como parte del método de aprendizaje y avance de la técnica de optimización se tiene en cuenta la interacción social en la Eq.(3.6) define donde toman lugar la repulsión, atracción, y la zona media conocida como la zona de confort:

$$S_i = \sum_{j=1}^N s(d_{ij}) \hat{d}_{ij} \quad (3.6)$$

La distancia d_{ij} en la Eq.(3.6) entre el $i - th$ y el $j - th$ saltamontes se representa en la Eq. (3.7), además, la Eq.(3.8) define el vector unitario que señala la dirección desde el saltamontes $i - th$ hacia el saltamontes $j - th$.

$$d_{ij} = |x_j - x_i| \quad (3.7)$$

$$\hat{d}_{ij} = \frac{x_j - x_i}{d_{ij}} \quad (3.8)$$

La Eq.(3.9) muestra la función s que designa las fuerzas sociales:

$$s(r) = f e^{\frac{-r}{l}} - e^{-r} \quad (3.9)$$

Donde f indica la intensidad de atracción y l indica la escala de longitud de atracción.

Acercas de las variables previamente expuestas, la Eq. (3.10) especifica la función que representa el algoritmo como una estrategia de solución a un problema de optimización, no solo asegurando que los saltamontes no alcancen muy rápido la zona de confort sino también la convergencia a un punto específico y previniendo que el algoritmo caiga en óptimos locales; tal ecuación describe los cambios en la posición de los saltamontes. La actualización de la posición se basa en la posición actual, la posición de todos los demás saltamontes, la posición objetivo y el mejor global, involucrando todos los agentes de búsqueda en la definición de la siguiente posición de cada agente de búsqueda, difiriendo del PSO en donde las demás partículas no contribuyen con la actualización de la partícula.

En la Eq. (3.10), donde ub_d es el límite superior y lb_d es el límite inferior $D-th$ de $s(r)$, \hat{T}_d es el valor de la dimensión $D-th$ el objetivo, es decir, la mejor solución encontrada hasta el momento, simulando su movimiento hacia la fuente de comida, y por último, c es un coeficiente decreciente para encoger la zona de confort definida como la zona en el espacio de búsqueda en la cual los saltamontes no tienen la tendencia a atraer o repeler. Sin embargo, la gravedad que es un factor importante en las simulaciones de enjambres de espacio hiperdimensional, 2D y 3D, no está siendo considerado, además, la dirección del viento se asume siempre orientada al objetivo \hat{T}_d , asegurando que los saltamontes no lleguen a la zona de confort rápidamente; el modelo empleado en el espacio libre permite emular la interacción entre los saltamontes en un enjambre:

$$X_i^d = c \left(\sum_{j=1, j \neq i}^N c \frac{ub_d - lb_d}{2} s(|x_j - x_i|) \frac{x_j - x_i}{d_{ij}} \right) + \hat{T}_d \quad (3.10)$$

Es relevante el enfatizar la inserción de la variable C calculada con la Eq. (3.11):

$$c = cmax - l \frac{cmax - cmin}{L} \quad (3.11)$$

Donde $cmax$ es el valor máximo, $cmin$ es el valor mínimo, l representa la iteración actual, y L es el máximo número de iteraciones. De manera proporcional al número de iteraciones, esto permite al algoritmo:

- Balancear la exploración, en la cual los saltamontes se mueven abruptamente, y la explotación en la cual ellos usualmente tienen un movimiento local, estas son tendencias naturales del enjambre alrededor del objetivo.
- Manejar la atracción, repulsión, y zonas de confort.
- Simular la lentitud del movimiento de los saltamontes mientras se acercan a la fuente de comida.

En esta técnica de optimización, se asume que los saltamontes que obtuvieron el mejor valor objetivo en el proceso de optimización; es decir, el que posee el valor de aptitud es el objetivo; luego, en cada iteración, los demás saltamontes se moverán hacia su posición para encontrar en las siguientes iteraciones un objetivo más apropiado, así como una aproximación más precisa al real óptimo global en el espacio de búsqueda.

METODOLOGÍA PROPUESTA

Para evaluar el rendimiento del algoritmo de optimización GOA, se implementaron dos técnicas como método de comparación. El algoritmo genético GA y la optimización por enjambre de partículas PSO, serán utilizados en la estimación de parámetros del SDM de cuatro 4 tipos de paneles PV de uso común: KC200GT, STP245S, MSX60 and SOLARJS65 los cuales son usados como escenarios de pruebas. Los datos técnicos de cada uno de estos paneles PV son suministrados por el fabricante en la Tabla 3.5. Con base a la información suministrada en cada panel PV, se ejecutó cada una de las técnicas de optimización bajo las mismas condiciones de iteraciones, población, partículas y criterios de parada, lo cual permite validar el método de optimización y los resultados obtenidos por estos en un escenario de prueba bajo condiciones equitativas.

Panel	N. Celdas	P_{max} (W)	(V_{mp}, I_{mp})	I_{SC} (A)
KC200GT	54	200	(26,3 V, 7,61 A)	8,21
MSX60	60	60	(17,1 V, 3,50 A)	3,80
SOLARJS65	36	65	(17,5 V, 3,71 A)	4,00
STP245S	60	245	(30,5 V, 8,04 A)	8,52

Tabla 3.5: PV panels characteristic data

Las tres técnicas de optimización son programadas para adquirir los cinco parámetros del SDM de un panel PV n , R_s , R_h , I_s and I_{ph} los cuales se aproximan al modelo ideal de un panel PV y su perfil PV. Se minimizará el error de la función objetivo definida en el capítulo 2. Para cada uno de los parámetros se define un espacio de búsqueda, los cuales son considerados en los límites máximos y mínimos. Para este caso en específico, los rangos de búsqueda son descritos en la Tabla. 3.6 para los paneles PV MSX60 y JS65 respectivamente y en la Tabla. 3.7 para los paneles PV KC200GT y STP245S.

Límites	n	R_s	R_h	I_s	I_{ph}
Máximo.	2	2	400	$1 * 10^{-5}$	5
Mínimo.	0.5	0	0	$1 * 10^{-12}$	0

Tabla 3.6: Boundaries for parameters evaluation in MSX60 and JS65 solar panels

Límites	n	R_s	R_h	I_s	I_{ph}
Máximo.	2	2	400	$1 * 10^{-5}$	10
Mínimo.	0.5	0	0	$1 * 10^{-12}$	0

Tabla 3.7: Boundaries for parameters evaluation in KC200GT and STP245S solar panels

Las Tablas. 3.8, 3.9 y 3.10 resumen los parámetros de ajustes para cada técnica de optimización basados en las recomendaciones dadas por [17] aplicados al PSO, GA y el GOA respectivamente.

Parametros	Valor
Número de iteraciones	500
Partículas Swarm	50
Máximo numero de iteraciones	10000
Inercia final	0.7
Inercia inicial	0.01
Componente de control cognitiva	1.494
Componente de control social	1.494

Tabla 3.8: Parámetros de sintonización de PSO

Parametros	Valor
Número de iteraciones	500
Tamaño de la población	50
Máximo numero de iteraciones	10000
Número de individuos por torneo	2

Tabla 3.9: Parámetros de sintonización de GA

Parameter	Value
Número de iteraciones	500
Partículas Swarm	50
Máximo numero de iteraciones	10000
C max	0.7
C min	0.01
Intensidad de la atracción f	0.5
Escala de longitud de atracción l	1.5

Tabla 3.10: Parámetros de sintonización de GOA

Los resultados experimentales garantizan que las evaluaciones de las técnicas de optimización utilicen los mismos parámetros de ajuste, al igual que el mismo número de iteraciones, la misma cantidad de partículas e individuos, debido a que la validación de los resultados de los algoritmos de optimización requiere de la inclusión de los ajustes descritos anteriormente para un correcto funcionamiento respecto a la función objetivo.

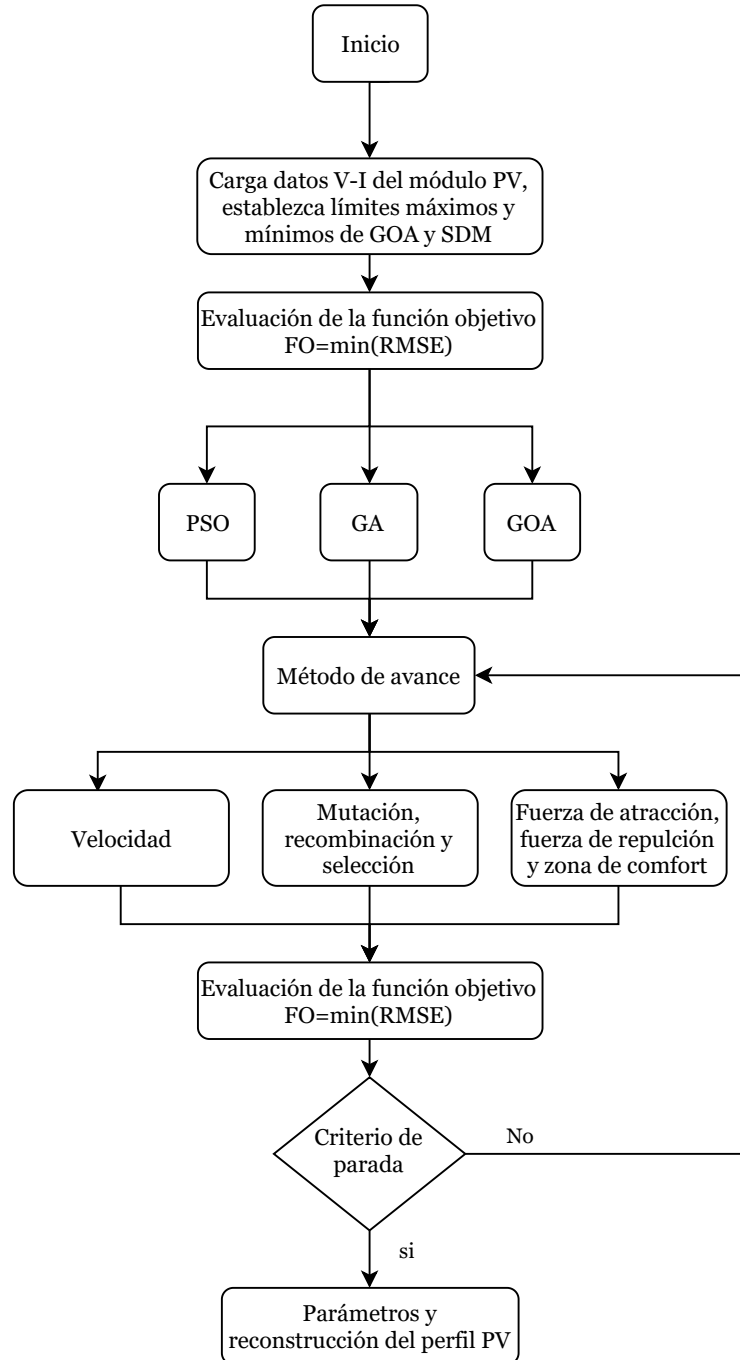


Figura 3.12: Diagrama de flujo de la aplicación propuesta

En el diagrama de flujo en la Fig.3.12 se puede observar una visión mas generalizada del proceso empleado en la evaluación de la función objetivo con cada una de las técnicas de optimización descritas anteriormente.

Adicionalmente, después de realizar cada uno de los ajustes necesarios en cada una de las técnicas de optimización, se ejecutaron 500 veces para cada tipo de panel PV. Los resultados obtenidos en cada una de las evaluaciones incluyen los errores mínimos y máximos, los cinco parámetros del SDM, las desviaciones estándar, los valores promedio y, por último, el tiempo promedio. Con estos datos estadísticos, se obtienen resultados de validación adecuados para las técnicas de optimización.

VALIDACIÓN DEL MODELO Y RESULTADOS EXPERIMENTALES

Las simulaciones se realizaron en *MATLAB* © 2018a en una computadora con las siguientes características: Intel (R) Xeon (R) CPU E5-1620 v3 de 3,5 Ghz procesador, memoria RAM de 16 GB DDR4, disco duro de estado sólido de 2,5" y 480 GB de almacenamiento y sistema operativo Windows 10 Pro.

Las Figuras 3.13(a), 3.13(b), 3.13(c) y 3.13(d), representan los errores distribuidos de los experimentos, se puede observar el rendimiento de los tres algoritmos mediante el uso de diagramas de cajas y bigotes.

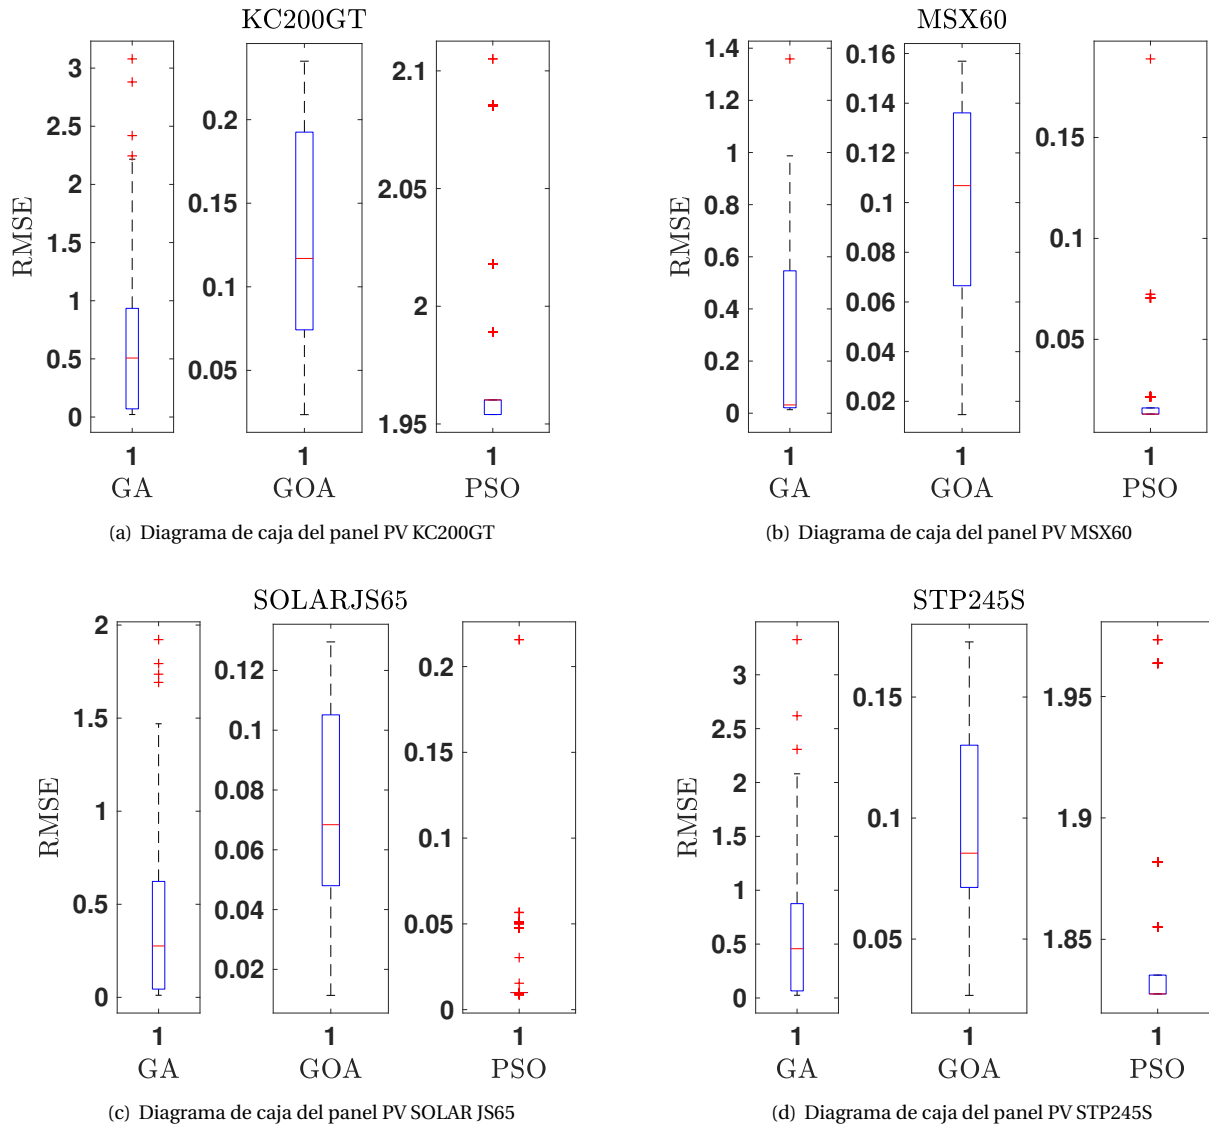


Figura 3.13: Diagrama de caja del panel PV (a) MSX60, (b) SOLARJS65, (c) KC200GT y (d) STP245S

La figura 3.13(a) muestra que para el panel KC200GT, el algoritmo con el mejor rendimiento fue GOA, que presenta un error inferior a 0.2349 para todo el conjunto de parámetros en el que el 50% de datos es inferior a 0.11 aunque para el resto de los algoritmos, los errores obtenidos fueron superiores a este valor durante más del 50% de los experimentos.

La figura. 3.13(b) ilustra los resultados para el panel PV MSX60, donde PSO demuestra para el 50% de los experimentos un error menor que 0.01297 que tiene un máximo de 0.18, seguido de GA que tiene un error menor que 0.0318 y típico valores de su último cuartil entre 0.4461 y 0.987 para el 50% de los experimentos. Finalmente,

los errores calculados con GOA están entre 0.014 y 0.1569.

El algoritmo PSO también presenta un mejor rendimiento para el panel SOLARJS65 PV, donde la mayoría de los datos muestran errores entre 0.0098 y 0.01, mientras que para GA y GOA, como se evidencia en la Figura. 3.13(c), sus errores más bajos son 0.0113 y sus valores máximos son 1.9217 y 0.1295, respectivamente.

Para el panel PV STP245S, PSO tiene el peor rendimiento con un error superior a 1.8275, como se muestra en la Figura 3.13(d), seguido de GOA con errores entre 0.026 y 0.1727 en los que el 50% de los experimentos, estos errores fueron inferiores a 0,0854.

Figura. 3.14 resume el rendimiento general de los tres algoritmos con los cuatro paneles fotovoltaicos, teniendo en total 2000 pruebas, se puede observar que el algoritmo con el mejor rendimiento para todas las pruebas fue el GOA, que para el 100% de los experimentos, los errores obtenidos fueron inferiores a 0.2345, en contraste con el PSO, aunque para dos paneles fotovoltaicos sus errores calculados fueron considerablemente bajos, para los otros dos fueron superiores a 1, del mismo modo, para GA en el que para el 50% de los errores calculados este se aproximó al 0.2717.

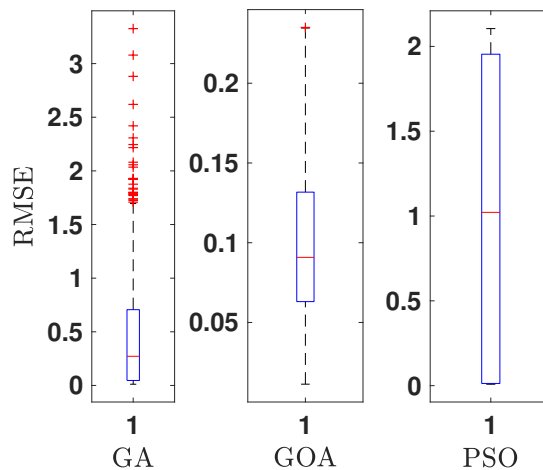


Figura 3.14: Diagrama de caja del rendimiento de los algoritmos de optimización

En la Tabla. 3.11 se presenta otra variable de medición crucial, el tiempo de ejecución de los algoritmos, donde GOA es el algoritmo con el tiempo de ejecución promedio más bajo para los cuatro paneles PV, seguido de GA y finalmente PSO, con tiempos de ejecución promedio en todos los experimentos de 0.6547, 2.2576 y 7.6138 respectivamente.

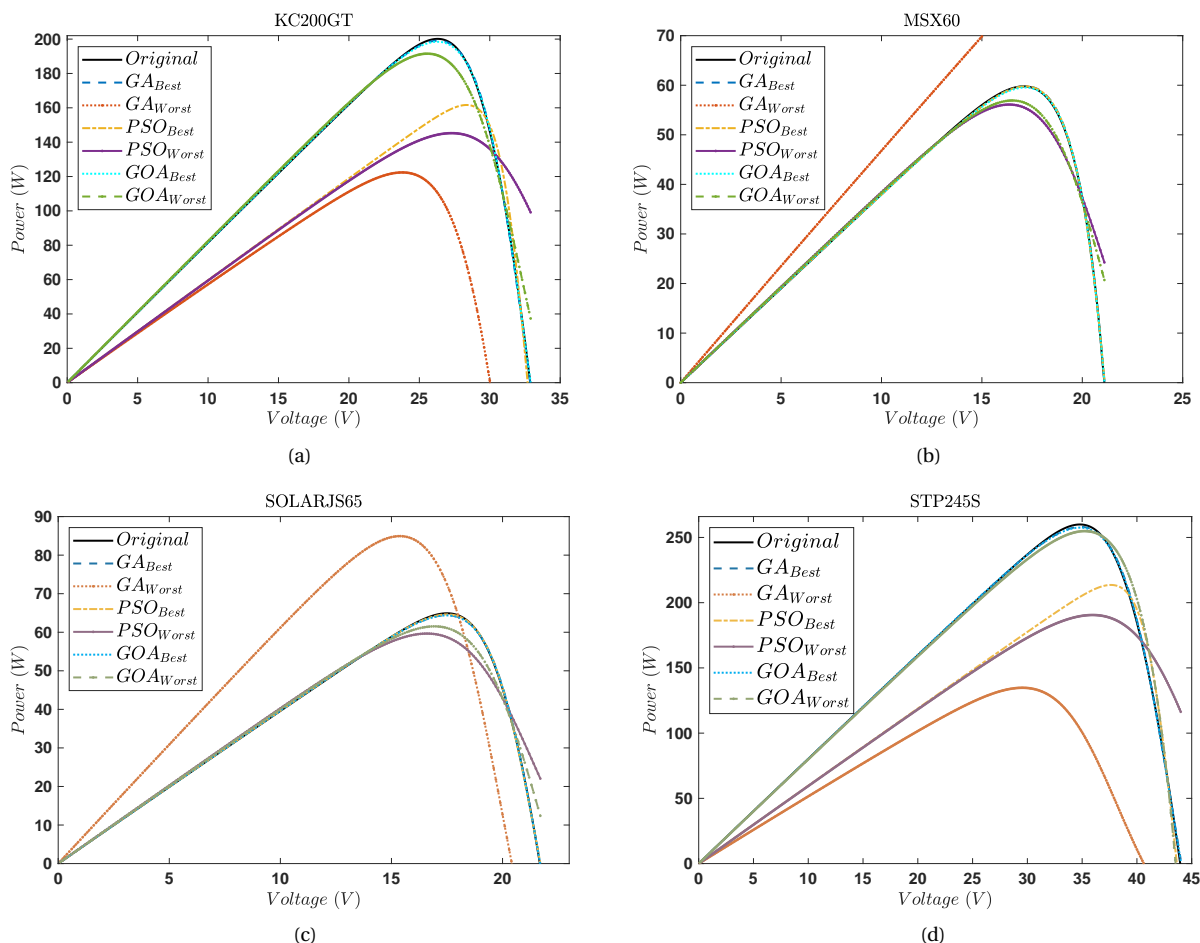


Figura 3.15: Simulación con los parámetros encontrados para los errores más bajos y más altos de los módulos PV (a) KC200GT, (b) MSX60, (c) SOLARJS65 y (d) STP245S.

Tiempo de ejecución [s]			
Panel	Algorithm		
	GOA	GA	PSO
KC200GT	0,719046	2,280907	8,355812
STP245S	0,888443	2,477229	8,387284
MSX60	0,496797	2,105302	7,450521
SOLARJS65	0,514890	2,166962	6,261715
Tiempo de ejecución total	0,654794	2,257600	7,613833

Tabla 3.11: Tiempos de ejecución promedio

La figura 3.15 representa la aproximación de los algoritmos al perfil PV original de los cuatro paneles 3.15(a) KC200GT, 3.15(b) MSX60, 3.15(c) SOLARJS65, y 3.15(d) STP245S. Las figuras ilustran las curvas resultantes de los errores más bajos y más altos obtenidos en cada una de las 500 iteraciones efectuadas con los tres algoritmos. De las figuras se puede concluir que GOA es una técnica precisa para estimar los parámetros para los cuatro tipos de módulos fotovoltaicos, mientras que los otros dos algoritmos, aunque presentan buenos enfoques, no son consistentes con los resultados para el resto de los casos, por lo tanto, el nivel de confiabilidad es más alto para GOA que para PSO y GA.

3.2.3. ALGORITMO DE OPTIMIZACIÓN GENÉTICO CONTINUO

El CGA es una adaptación poblacional que emplea variables continuas del GA [18, 19]. El cual emplea selección, recombinación y mutación para brindar solución a problemas de optimización continuos multivariable [20]. La metodología completa del CGA aquí empleado se describe a continuación.

GENERACIÓN DE LA POBLACIÓN INICIAL

La población inicial de individuos $Pob_{(n,d)}$, se propone una población con un tamaño de "n" filas que corresponde a la cantidad de individuos, como posibles soluciones problema, y "d" columnas que representan el número de variables del problema a solucionar ver la Eq. (3.12) que corresponde a las variables η , I_{ph} , I_{d1} , R_s , R_h . Donde P_n corresponde al n-esimo individuo dentro de $Pob_{(n,d)}$. Las variables de cada fila Pob representan los valores asignados a cada una de las variables para una solución en particular. Los valores de cada individuo Pob son calculados de forma aleatoria, representando los límites mínimos y máximos [21].

$$Pob_{(n,d)} = \begin{bmatrix} P_{1,1} & P_{1,2} & \cdots & \cdots & P_{1,d} \\ P_{2,1} & P_{2,2} & \cdots & \cdots & P_{2,d} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ P_{n,1} & P_{n,2} & \cdots & \cdots & P_{n,d} \end{bmatrix} \quad (3.12)$$

CÁLCULO DE LA FUNCIÓN OBJETIVO

Para evaluar el impacto de todas las posibles soluciones contenidas dentro de $Pob_{(n,d)}$, se realiza una primera evaluación en la función objetivo como primer ciclo iterativo, en este, se selecciona la incumbente del problema y se escogen los individuos que la generan. Almacenando los valores obtenidos por cada individuo dentro de la matriz de tamaño $n \times 1$ que corresponde al error de la población ($Error_{Pob}$). Para el caso de problema SDM se evalúa cada individuo creado a partir del espacio de búsqueda del SDM definidos en las Tablas 3.6 y 3.7, los cuales son asignados dentro de cada Pob obteniendo los valores de las variables asociados a cada posible solución.

$$Error_{Pob} = \begin{bmatrix} f([P_{1,1}, P_{1,2}, \cdots, P_{1,d}]) \\ f([P_{2,1}, P_{2,2}, \cdots, P_{2,d}]) \\ \vdots \\ f([P_{n,1}, P_{n,2}, \cdots, P_{n,d}]) \end{bmatrix} \quad (3.13)$$

GENERACIÓN DE LA POBLACIÓN DE DESCENDENTES

El CGA empleado, utiliza un proceso iterativo, en el cual en cada iteración se generan poblaciones de descendientes que permitan avanzar en el proceso de hallar la solución óptima del problema. Esta población de descendientes contiene la información de sus padres a partir del proceso de selección y recombinación, los cuales permiten heredar las mejores características de sus padres, empleando la mutación para generar aleatoriedad en su información y de esta manera evitar caer en óptimos locales. A continuación, se explican cada una de las etapas para el proceso de la generación de la población de descendientes:

- 1) **Selección:** Los descendientes seleccionan de forma aleatoria un subgrupo de individuos contenidos en la población actual. Durante este paso, se selecciona un número aleatorio r que va de 1 a a , es decir, $r = (a-1) * rand$. Si $r < a$, se genera una matriz adicional $(a-r) * s$, esta crea nuevos individuos mediante el uso de la misma estrategia de la población inicial, generando así la población de descendientes del mismo tamaño a la población actual ($a * s$).
- 2) **Recombinación:** modifica la descendencia que sigue a la población inicial y es aplicado a cada individuo de la población de descendientes. Si la probabilidad de recombinación (r_p) es mayor al 50%, se toma la población de padres e hijos y se realiza una sumatoria de estos, sacando un promedio, verificando que la población resultante este bajo los límites máximos y mínimos asignados a cada una de las variables.

- 3) **Mutación:** explora la probabilidad de mutación (m_p). si (m_p) es mayor al 50% (un valor seleccionado aleatoriamente), se selecciona un individuo de la población de forma aleatoria y se reasigna su información de la misma manera en que fue escogido. Si m_p es inferior al 50%, las soluciones potenciales no se modifican. Este proceso se aplica a todos los individuos en la descendencia. Una vez generadas las nuevas descendencias, se vuelve a evaluar la función objetivo.

GENERACIÓN DE LA NUEVA POBLACIÓN

Con la población actual y la de descendientes generada, el CGA continuo crea con estas una matriz de tamaño $2a$. esto con el fin de realizar una comparación entre ellas y eliminar las soluciones repetidas. La matriz es ordenada desde las mejores soluciones a las peores, así eliminando las peores hasta que la matriz vuelva a tener un tamaño de a . Esta pasará a ser la nueva población de padres para el siguiente ciclo iterativo [20].

CRITERIO DE PARADA

El CGA continuo propuesto en este trabajo finaliza cuando este satisface alguna de las siguientes condiciones: el número total de iteraciones es alcanzado o la solución no mejora después de m ciclos generacionales continuos.

Con el objetivo de brindar una ayuda visual para la interpretación de la metodología de la etapa maestra de la solución propuesta, se presenta el proceso iterativo en el Algoritmo 2, el cual representa la metodología del CGA propuesto para estimación de parámetros del SDM.

Algorithm 2 Método propuesto basado Algoritmo Genético continuo CGA

```

1: Inicialización de los parámetros
2: for  $t = 1 : t_{max}$  do
3:   if  $t == 1$  then
4:     Generar población inicial de padres;
5:     Resuelve el problema esclavo;
6:     Evaluar la función objetivo;
7:     Seleccionar la incumbente;
8:   else
9:     Evaluar la función objetivo
10:    Generar población de descendientes (hijos), utilizando método de selección, recombinación y mutación;
11:    Evaluar la función objetivo;
12:    Actualización la nueva población de padres;
13:    Actualizo la incumbente;
14:    if Se ha cumplido algún criterio de detención? then
15:      Finalizar el proceso de optimización;
16:      Solución óptima encontrada;
17:      Imprimir resultados;
18:      Break;
19:    else
20:      Continuar;
21:    end if
22:  end if
23: end for

```

ANÁLISIS COMPUTACIONAL

En la siguiente sección, se presentan los parámetros de simulación de permiten realizar el proceso de identificación de los perfiles PV para la validación del método propuesto, así como los métodos de comparación empleados para validar la efectividad de la metodología en términos de calidad de la solución y tiempos de procesamiento requeridos.

SISTEMA DE PRUEBA

Con el propósito de validar y comprobar la robustez de la metodología propuesta en este documento, se emplearon cuatro tipos de paneles con especificaciones diferentes, los cuales son mencionados en la Tabla 3.12. Dicha tabla presenta de izquierda a derecha, las características básicas como el número de celdas ($N.Celdas$), los valores de potencia máxima (P_{max}), voltaje de máximo punto (V_{mp}), corriente de máximo punto (I_{mp}) y la corriente de corto circuito (I_{sc}). Adicionalmente existen valores constantes necesarios para que el SDM pueda funcionar correctamente ante el proceso de estimación de parámetros. Como es el caso de la constante de Boltzmann $k = 1,3806503 \times 10^{-23}$ (J/K), la temperatura en grados Kelvin 273 (°K) y la carga eléctrica $q = 1,60217646 \times 10^{-19}$; los cuales aplican para cualquier tipo de panel PV.

Panel	MSX60	JS65	KC200GT	STP245S
N. Celdas	60	36	54	60
P_{max} [W]	60	65	200	245
V_{mp} [V]	17.1	17.5	26.3	30.5
I_{mp} [A]	3.5	3.71	7.61	8.04
I_{sc} [A]	3.8	4.0	8.21	8.52

Tabla 3.12: Paneles fotovoltaicos y sus características

MÉTODOS EMPLEADOS PARA LA COMPARACIÓN

En busca de comprobar la efectividad del método propuesto, se emplearon dos métodos de comparación: el método PSO uno de los más utilizados en la optimización [22] y el método de optimización GA [19], ya que se busca determinar la diferencia entre el algoritmo genético tradicional y el empleado en este trabajo que tiene un enfoque poblacional. Estos métodos de comparación son empleados bajo la misma metodología y las mismas restricciones para la estimación de parámetros del SDM ante los distintos paneles PV, empleados para el CGA. En este sentido, con el fin de realizar una comparación justa se determinó que las técnicas de optimización tendrán la misma cantidad de iteraciones, individuos o partículas iniciales, al igual que los mismos criterios de parada. De manera heurística, se seleccionó una población de 30 individuos, 10000 iteraciones máximas y un contador de no mejora de 80 iteraciones; basados en la premisa de no explorar más el espacio de solución, si la mejor solución no mejora. Finalmente, para obtener los tiempos promedios de procesamiento requeridos para los métodos de solución empleados, se ejecutó 1000 veces cada escenario de prueba.

SIMULACIONES Y RESULTADOS

El análisis computacional para la obtención de los resultados numéricos se realizó en un computador portátil con las siguientes especificaciones: un procesador Intel Core i5 – 8520U de 1,6 Ghz con turbo boost hasta 3,4 Ghz, memoria RAM DDR4 de 6 GB, disco duro de estado sólido M2 de 128 GB de almacenamiento y un sistema operativo Windows 10 PRO. Utilizando el entorno de programación *Matlab*® 2019a.

RESULTADOS DE LAS PRUEBAS AL SISTEMA SDM

En la Tabla 3.13 se pueden apreciar los resultados obtenidos por cada técnica de optimización empleada en este documento para resolver el problema del SDM mediante el uso de cuatro diferentes tipos de paneles PV descritos en la sección 3.2.3. La información es presentada de la siguiente manera: la primera fila contiene el método de solución utilizado, en la segunda y tercera fila se presentan la mejor solución encontrada y el peor resultado hallado por las técnicas de optimización, respectivamente. En la fila cuatro, se encuentra el valor medio del error hallado por cada técnica de optimización, en la quinta fila se presenta la desviación estándar del error; y por último, en la fila seis son presentados los tiempos promedios de ejecución. Todo esto, bajo la función objetivo (minimización de estimación de los parámetros que determinan los valores de la corriente I).

Basados en los resultados presentados en la Tabla 3.13, en esta se observa que el CGA logró estimar los parámetros con el menor tiempo de procesamiento y minimización error para cada uno de los escenarios de prueba propuestos. Para el caso de minimización de la función objetivo de estimación de parámetros del SDM de un panel PV (STP245S), se emplea el GA como caso base, ya que, este presenta la peor respuesta. Logrando identificar que el CGA minimiza la función objetivo en un 56,04 % más que el GA. Así mismo, el PSO logra una respuesta 3,01 % mejor que el GA. Destacando que el CGA presenta una solución 94,64 % mejor que el PSO.

STP245S			
Método	CGA	GA	PSO
Mejor Solución	0.03228	0.07342	0.07121
Peor Solución	0.14650	0.28554	0.84833
Valor Medio	0.08774	0.13069	0.30572
Desviación Estándar	0.01332	0.03033	0.16972
Tiempo Promedio	1.16926	5.26651	1.29790
KC200GT			
Método	CGA	GA	PSO
Mejor Solución	0.03338	0.05555	0.13823
Peor Solución	0.17441	0.33365	1.76640
Valor Medio	0.09050	0.14325	0.74059
Desviación Estándar	0.01682	0.03968	0.35056
Tiempo Promedio	0.98808	4.15797	1.69940
SOLAR JS65S			
Método	CGA	GA	PSO
Mejor Solución	0.00677	0.03755	0.06261
Peor Solución	0.08564	0.17708	1.16180
Valor Medio	0.04935	0.07587	0.38473
Desviación Estándar	0.00795	0.01854	0.21268
Tiempo Promedio	0.95107	2.97322	1.20250
MSX60			
Método	CGA	GA	PSO
Mejor Solución	0.01337	0.02362	0.07264
Peor Solución	0.08799	0.16012	0.74310
Valor Medio	0.04610	0.07304	0.35140
Desviación Estándar	0.00911	0.02124	0.14229
Tiempo Promedio	0.92316	2.56311	1.03090

Tabla 3.13: Resultados obtenidos para el SDM

Para el panel PV (KC200GT), la peor solución fue obtenida por el PSO, el CGA obtuvo una reducción del 75,85% con respecto al PSO, mientras que el GA tradicional obtuvo una reducción del 59,81%. Identificando al CGA con una minimización de la función objetivo del 21,151%.

Analizando el panel PV (SOLARJS65) se puede observar que los resultados se asemejan a la prueba anterior, donde el peor resultado ante la minimización de la función objetivo es presentado por el PSO, mientras que el CGA obtuvo la mejor respuesta con una reducción del error del 89,19% con respecto al PSO, seguido del GA con una reducción con respecto a la misma técnica del 40,02%. Lo que muestra al CGA con una minimización de la función objetivo del 55,13%.

Para el escenario de prueba final (MSX60), se comprobó la robustez del método CGA, presentado nuevamente la mejor respuesta en minimización de la función objetivo. Con una reducción del del 81,59% con respecto al PSO que presentó la peor respuesta, y una diferencia de 67,84% contra el GA que presentó la segunda mejor respuesta en este panel PV. Logrando identificar que el CGA minimiza la función objetivo en un 17,29% más que el GA.

En la Fig. 3.16, se presenta el tiempo de ejecución de cada técnica al minimizar la función objetivo, en los diferentes tipos de paneles empleados en este trabajo. Esto se hace con la finalidad de seleccionar la técnica de mayor eficiencia en términos computacionales. En esta gráfica se puede observar que el método que requiere menor tiempo de procesamiento en promedio es el CGA, seguido por el PSO y el GA con la peor respuesta, con tiempos promedio de 1,01s, 1,31s y 3,74s. En adición a esto, la Fig. 3.16, se puede observar cada uno de los tiempos que tarda en ejecutarse la técnica de optimización en cada uno de los escenarios de pruebas del SDM, permitiendo comprobar la metodología propuesta.

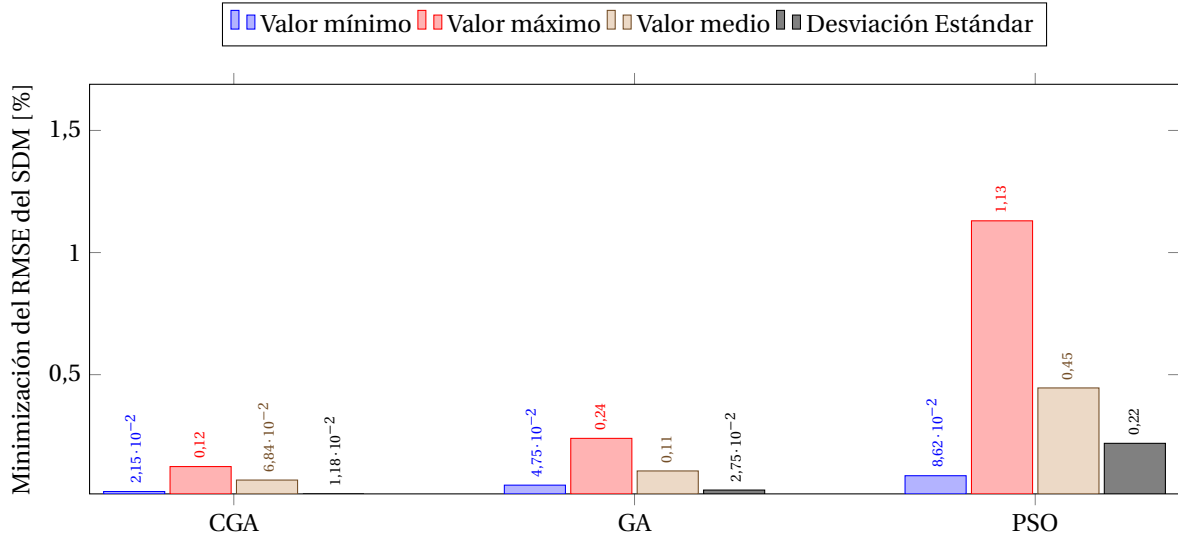


Figura 3.16: Minimización del RMSE del modelo de un diodo equivalente de un panel PV por las diferentes técnicas de optimización

Finalmente la Fig. 3.17, resume la minimización de la función objetivo ante los diferentes métodos de solución. En esta se puede observar que la solución del CGA propuesta proporciona mejores resultados respecto al valor mínimo, valor máximo, valor medio y la desviación estándar, con valores promedios de 0,038%, 0,104%, 0,075% y 0,014% respectivamente. Lo cual es una demostración de que el CGA como método de solución presenta una mayor efectividad con respecto a la minimización de la función objetivo y tiempos de procesamiento.

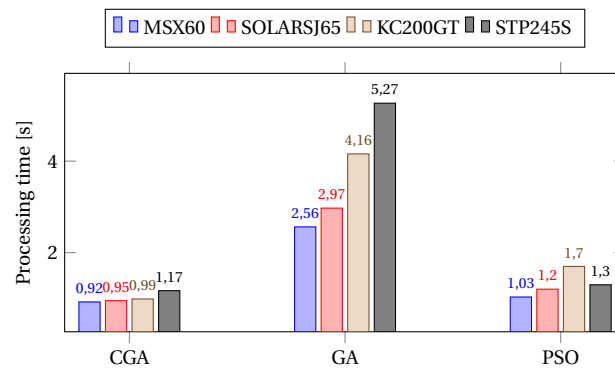


Figura 3.17: Tiempo de procesamiento requerido por cada método en cada tipo de panel PV empleado

3.2.4. CONCLUSIONES

Mediante el uso de las técnicas de optimización para la estimación de parámetros de un panel PV, la generación de su perfil PV ideal y los diferentes escenarios de pruebas que son tenidos en cuenta en este capítulo, se concluye que al aplicar y validar cada una de las diferentes técnicas de optimización, se puede observar que estas tienden a variar sus tiempos de cómputo, ya que dependiendo de su método de avance y su inspiración en la naturaleza serán más rápidas o lentas en la convergencia de la función objetivo. Sumado a esto, el GOA presenta tiempos bajo su desviación estándar y valores medios mejor dispersos que las demás técnicas de optimización como lo es el PSO y el GA, o incluso, la IPMS, técnica que tiende a obtener un mismo resultado en la minimización de la función objetivo, pero con tiempos de cómputo muy altos.

El algoritmo genético continuo presenta una gran estabilidad entre el costo computacional y la minimización de la función objeto, además, la técnica demuestra ante otras que sus valores medios y desviación estándar están por debajo del promedio de las anteriores, que se puede utilizar completamente en cualquier tipo de panel

PV en la estimación de parámetros, y como herramienta de diagnóstico de fallas, a partir de la estimación de los parámetros del SDM de un panel PV.

Cabe resaltar que cada una de estas técnicas de optimización explicadas en este capítulo fueron utilizadas para publicar y someter artículos de investigación, la primera (IPSM) fue aceptada en la revista de la universidad de Medellín, el GOA fue publicado en una revista Q2 International Journal of Energy and Environment Engineering y el CGA fue sometido en la revista Arabian Journal for Science and Engineering.

REFERENCIAS

- [1] B Chitti Babu and Suresh Gurjar. A novel simplified two-diode model of photovoltaic (pv) module. *IEEE journal of photovoltaics*, 4(4):1156–1161, 2014.
- [2] Vivek Tamrakar, SC Gupta, and Yashwant Sawle. Single-diode and two-diode pv cell modeling using matlab for studying characteristics of solar cell under varying conditions. *Electrical & Computer Engineering: An International Journal (ECIJ)*, 4(2):67–77, 2015.
- [3] Kashif Ishaque, Zainal Salam, et al. A comprehensive matlab simulink pv system simulator with partial shading capability based on two-diode model. *Solar energy*, 85(9):2217–2227, 2011.
- [4] JC Sánchez Barroso, JPM Correia, N Barth, S Ahzi, and MA Khaleel. A pso algorithm for the calculation of the series and shunt resistances of the pv panel one-diode model. In *2014 International Renewable and Sustainable Energy Conference (IRSEC)*, pages 1–6. IEEE, 2014.
- [5] Jieming Ma, TO Ting, Ka Lok Man, Nan Zhang, Sheng-Uei Guan, and Prudence WH Wong. Parameter estimation of photovoltaic models via cuckoo search. *Journal of applied mathematics*, 2013, 2013.
- [6] Noureddine Maouhoub. Photovoltaic module parameter estimation using an analytical approach and least squares method. *Journal of Computational Electronics*, 17(2):784–790, 2018.
- [7] Giuseppina Ciulla, Valerio Lo Brano, Vincenzo Di Dio, and Giovanni Cipriani. A comparison of different one-diode models for the representation of i–v characteristic of a pv cell. *Renewable and Sustainable Energy Reviews*, 32:684–696, 2014.
- [8] Hugo Nunes, José Pombo, João Fermeiro, Sílvio Mariano, and Maria do Rosário Calado. Particle swarm optimization for photovoltaic model identification. In *2017 International Young Engineers Forum (YEF-ECE)*, pages 53–58. IEEE, 2017.
- [9] Rabah Benkercha, Samir Moulahoum, Ilhami Colak, and Bilal Taghezouit. Pv module parameters extraction with maximum power point estimation based on flower pollination algorithm. In *2016 IEEE International Power Electronics and Motion Control Conference (PEMC)*, pages 442–449. IEEE, 2016.
- [10] Giovanni Petrone, Carlos Andrés Ramos-Paja, and Giovanni Spagnuolo. *Photovoltaic sources modeling*. John Wiley & Sons, 2017.
- [11] Ahmed A El Tayyan. An approach to extract the parameters of solar cells from their illuminated iv curves using the lambert w function. *Turkish Journal of Physics*, 39(1):1–15, 2015.
- [12] Vun Jack Chin, Zainal Salam, and Kashif Ishaque. Cell modelling and model parameters estimation techniques for photovoltaic simulator application: A review. *Applied Energy*, 154:500–519, 2015.
- [13] J Accarino, G Petrone, CA Ramos-Paja, and G Spagnuolo. Symbolic algebra for the calculation of the series and parallel resistances in pv module model. In *2013 International Conference on Clean Electrical Power (ICCEP)*, pages 62–66. IEEE, 2013.
- [14] Maurice Clerc. *Particle swarm optimization*, volume 93. John Wiley & Sons, 2010.
- [15] Simon Lineykin, Moshe Averbukh, and Alon Kuperman. Five-parameter model of photovoltaic cell based on stc data and dimensionless. In *2012 IEEE 27th Convention of Electrical and Electronics Engineers in Israel*, pages 1–5. IEEE, 2012.
- [16] Shahrzad Saremi, Seyedali Mirjalili, and Andrew Lewis. Grasshopper optimisation algorithm: theory and application. *Advances in Engineering Software*, 105:30–47, 2017.
- [17] Luis Fernando Grisales-Noreña, Daniel Gonzalez Montoya, and Carlos Andres Ramos-Paja. Optimal sizing and location of distributed generators based on pbil and pso techniques. *Energies*, 11(4):1018, 2018.
- [18] Miguel Galante. Un algoritmo genético simple para la optimización de estructuras planas articuladas. 1993.

-
- [19] PC Chu and JE Beasley. A genetic algorithm for the set partitioning problem. *Imperial College, London*, 1995.
- [20] OD Montoya, W Gil-González, and LF Grisales-Noreña. Optimal power dispatch of dgs in dc power grids: a hybrid gauss-seidel genetic-algorithm methodology for solving the opf problem. *WSEAS Transactions on Power Systems*, 13(33):335–346, 2018.
- [21] Simone SF Souza, Ruben Romero, Jorge Pereira, and João Tomé Saraiva. Specialized genetic algorithm of chu-beasley applied to the distribution system reconfiguration problem considering several demand scenarios. In *2015 IEEE Eindhoven PowerTech*, pages 1–5. Ieee, 2015.
- [22] Vandana Khanna, BK Das, Dinesh Bisht, PK Singh, et al. Estimation of photovoltaic cells model parameters using particle swarm optimization. In *Physics of Semiconductor Devices*, pages 391–394. Springer, 2014.

4

DIAGNÓSTICO DE FALLAS EN UN PANEL PV MEDIANTE EL USO DE UN ALGORITMO GENÉTICO CONTINUO

Contenido

4.1	Introducción	49
4.2	Tipos de Fallas que se pueden estimar en un panel PV a partir de los parámetros de su modelo matemático equivalente	52
4.3	Diagnóstico de fallas en un panel PV a partir de la estimación de parámetros del SDM de un panel PV	54
4.3.1	Conclusiones	57
	Referencias	58

4.1. INTRODUCCIÓN

La información ofrecida anteriormente permite dar un enfoque hacia el diagnóstico de fallas en un panel PV el cual es de suma importancia realizarlo, ya que este, puede proporcionar la información necesaria para evitar pérdidas de generación y transformación de energía en un arreglo PV, realizar correcciones preventivas y a su vez evitar que un panel defectuoso pueda dañar o influir en el daño de los otros paneles PV. Existen distintos métodos de monitoreo y diagnóstico de fallas en la literatura, que varían en tiempos de computo, complejidad y requisitos de sensores, entre otros dispositivos electrónicos [1–3]. En [4, 5] hacen lógica difusa y redes neuronales para realizar la detección de fallas a partir de imágenes termográficas y puntos calientes (hot-spot) en los paneles PV. Estas pruebas son realizadas en ambientes controlados en laboratorio y la adquisición de su base de datos de imágenes termográficas también es controlada, lo que hace que el proceso sea fiable; aunque sea fiable se vuelve costoso por cada componente utilizado en este proceso de adquisición de información de diagnóstico de fallas en arreglos PV. En [6–10] hacen extracción de información de los paneles PV mediante el uso de herramientas estadísticas mezcladas con redes neuronales y el procesamiento de datos de información como lo son las imágenes y las curvas de V-I, detectando fallas de corto circuito (SC), circuito abierto (OC), sombreado y polvo, arcos eléctricos o fallas de tierra en el sistema PV y mismatching. La detección de fallas que realizan en arreglos de paneles PV es mediante el uso de los niveles de potencia máximos generados por el arreglo; lo que lo hace poco fiable ya que un cambio en los niveles de potencia no garantizan que alguno de esos PV presente fallas físicas reales ya que se necesitan de más datos recopilados que simplemente los niveles de voltaje y corriente máximos generados. Mientras que [11, 12], se hace el monitoreo de los cambios en la resistencia en serie y de calidad de los diodos, los cuales se identifican mediante múltiples mediciones de la curva V-I del

panel PV. Aunque este análisis es acertado, limitan las variaciones a de corriente de los paneles bajo STC lo que no permite validar de forma real un sistema en entornos no STC. En [13–15] supervisan el funcionamiento de los sistemas PV para detectar fallas mediante cálculos en los incrementos en la resistencia en serie, los cambios de potencia y la degradación de estos a través del tiempo. Cabe resaltar que el trabajo de diagnóstico de fallas requiere de procesos en los que se deben analizar datos por distintos medios de información. Algunos prefieren realizarlo mediante bases de datos utilizados con inteligencia artificial o aprendizajes de máquina; por lo que este tipo de trabajos requiere de una gran base de datos y distintos escenarios de pruebas que permitan validar la información de diagnóstico de fallas. Otros obtienen resultados a partir del manejo de dispositivos y sensores eléctricos.

Debido a que los paneles PV pueden transformar su energía a partir de la irradiancia y la temperatura ambiente, estos son sensibles a cambios de potencia debido a las condiciones ambientales. Esto puede causar distintas fallas en un panel PV. A pesar de que un panel reciba mantenimiento constante y limpieza, nunca está exento de la influencia por el polvo, la lluvia y los altos niveles de temperatura que son originados de la región en donde sean instalados. Aunque los sistemas PV pueden seguir funcionando en un estado defectuoso, la eficiencia energética se ve afectada y las fallas a largo plazo causan daños irreversibles en el panel PV, hasta el punto de generar cortos e incendios. Para supervisar el estado de funcionamiento de los sistemas fotovoltaicos y detectar posibles fallos, se han propuesto en los últimos años diferentes métodos de diagnóstico de fallas en los sistemas PV tal y como fueron mencionados anteriormente, estos métodos permiten cuantificar los niveles de degradación ante los cambios de parámetros en los paneles PV.

Con los avances recientes en el desarrollo de dispositivos electrónicos que permiten obtener datos de V-I y V-P off-line y on-line en los paneles PV, se han convertido en una herramienta importante para el uso del diagnóstico de fallas en sistemas PV. Dichos dispositivos han sido usados en la implementación de algoritmos inteligentes como las redes neuronales y los algoritmos de optimización. Las redes neuronales se dividen en distintos métodos como lo muestran los autores en [16–23]. Mientras que el uso de las técnicas de optimización buscan el mismo objetivo, estas técnicas pueden ser utilizadas sin necesidad de bases de datos para ser entrenados como las redes neuronales y evitar a su vez los altos procesos de computo, las técnicas de optimización también pueden ser utilizadas como herramientas para determinar el MPPT o en la estimación de los parámetros que mejor se ajusten al SDM de un panel PV tal y como se hizo en el capítulo 3, capítulo en el cual se realizó la implementación ante diferentes técnicas de optimización y el uso de cuatro escenarios de pruebas diferentes que permitieron validar la efectividad de las técnicas y la estimación de los parámetros de los cuatro distintos paneles PV. Permitiendo así, definir las restricciones o rangos de búsqueda de los parámetros del modelo matemático del SDM de un panel PV. Dichos parámetros son los que permitirán realizar el diagnóstico de fallas en un panel PV que presente algún desgaste físico en su comportamiento PV. El diagnóstico, se realizó mediante la adquisición de datos de V-I con el dispositivo llamado Sweep Device (SWD) el cual se observa en la Fig. 4.1. Este dispositivo se encarga de realizar los barridos de V-I de cualquier tipo de panel PV ante cualquier nivel de irradiación y temperatura. El SWD fue fabricado en el laboratorio de electrónica y energías renovables del ITM. Su diseño físico y esquemático se puede observar en la Fig 4.1(a) y 4.1(b).

El dispositivo que se observa en la Fig 4.1 presenta la elaboración del dispositivo eléctrico y su esquemático de conexiones, en conjunto con su alimentación y modos de cambios de estado, que permiten realizar el barrido de un panel PV en sus niveles de V-I. Dicho dispositivo después de ser utilizado se implementa la adquisición de datos mediante la herramienta de Matlab para procesar los datos, filtrarlos y utilizar la técnica de optimización para la estimación de parámetros tal y como se ve en la siguiente Fig. 4.2.

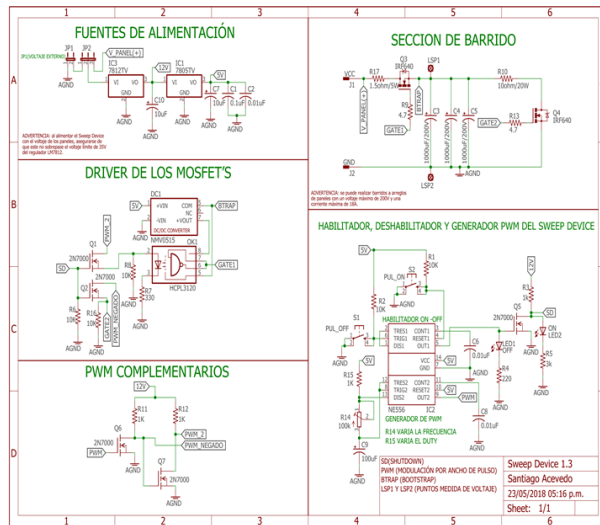
En la figura se observan los distintos elementos que permitieron realizar la adquisición de datos de V-P de un panel PV. Este dispositivo tiene conectado a su salida un Arduino Due el cual se encarga de adquirir los datos V-I mediante la implementación de dos divisores de tensión, estos divisores son los que regulan el voltaje salida del SWD para que cuando sean transmitidos por el Arduino este no se dañe ya que el dispositivo solo soporta un voltaje de 3.3 [V] máximo. Después de la regulación de tensión se envían los datos directamente a Matlab mediante puerto serial. Al momento de recibir los datos, se procede a implementar la técnica de optimización que se desee utilizar.

Cabe resaltar que los datos que generan el perfil PV son una cantidad mínima definida por el primero objetivo de este trabajo, esto se puede observar en la Fig 4.3.

El primer paso para obtener la información requerida de un panel PV es el barrido de V-I, por lo que los métodos de extracción de parámetros se correlacionan con el análisis eléctrico de los paneles PV, estas son técnicas



(a) Montaje físico Sweep Device



(b) Diseño esquemático del Sweep Device

Figura 4.1: Sweep Device Dispositivo eléctrico encargado de realizar los barridos de V-I




Figura 4.2: Implementación para la adquisición de datos V-I o V-P de un panel PV




Figura 4.3: Perfil V-P real obtenido con Sweep Device y la menor cantidad de datos representativos

computacionalmente convenientes, presenta una baja carga computacional y tiempos de computo apropiados para la revisión efectiva de los sistemas PV. Al emplear esta técnica debe tenerse en cuenta que la simulación, emulación o representación de las características V-I de un panel PV, dependerá en la precisión de la estimación de parámetros del panel PV, por ende, se requiere una técnica que converja con el menor error posible. En la literatura se reportan métodos numéricos o analíticos, que, a pesar que pueden ofrecer simplicidad, la reducción del error en la estimación de parámetros puede ser una tarea expensiva, sin mencionar el hecho de que pueden necesitar parámetros que no se encuentran en la hoja de datos del fabricante (datasheet). Luego, como alternativa, están las técnicas metaheurística que usualmente estiman los parámetros relevantes, minimizando el RMSE como función objetivo; los algoritmos más utilizados son aquellos bio-inspirados tales como el PSO, Ga, Differential Evolution (DE), Artificial Bee Colony Algorithm (ABC), Bacterial Foraging (BF) y PSM. Recientemente se ha considerado el algoritmo Genético continuo para esta aplicación, aunque es un algoritmo modificado relativamente nuevo aplicado al campo de la fotovoltaica, este ha demostrado una buena relación entre la precisión y su tiempo de ejecución tal y como se observó en el capítulo 3 en los resultados presentados por esta técnica de optimización, es por esto que, en este capítulo se mostrarán los resultados obtenidos por la técnica de optimización y la estimación de parámetros de un panel PV BP585 para la detección de fallas, fallas las cuales se mencionaran a continuación.

4.2. TIPOS DE FALLAS QUE SE PUEDEN ESTIMAR EN UN PANEL PV A PARTIR DE LOS PARÁMETROS DE SU MODELO MATEMÁTICO EQUIVALENTE

En un sistema fotovoltaico real, la temperatura y la irradiancia son elementos que no se pueden controlar. En general se requiere un control preciso de las condiciones ambientales para analizar y adquirir los datos característicos de V-I. Además de esto se necesita de altos niveles de irradiancia para obtener un diagnóstico de

fallas bajo cualquier factor ambiental [24]. En este trabajo se presentan el tipo de fallas que se pueden analizar y diagnosticar a partir de la estimación de parámetros a partir del modelo matemático equivalente de un diodo de un panel PV se ve detallado en la Tabla 4.1.

Diagnóstico de fallas	
Diagnóstico	Posibles fallas
Incremento de R_s	Envejecimiento, desgaste y humedad
Disminución de corriente del panel I_{pv}	Sombreado parcial o total
Incremento de R_s y disminución de R_{sh}	Oxido

Tabla 4.1: Fallas que se pueden representar a partir de los parámetros del modelo matemático de un panel PV

Para realizar el diagnóstico de fallas de un panel PV se debe garantizar que la irradiancia mínima con la que se adquieran los datos V-I debe ser de $G = 500 [W/m^2]$, por lo que bajo estos niveles de irradiancia se pueden realizar pruebas de diagnóstico de fallas. Además de eso la Tabla 4.1, en su segunda fila primera columna presenta el diagnóstico de la falla que se genera a partir del cambio de alguno de los parámetros del SDM de un panel PV; mientras en la segunda columna de la misma fila se presenta el tipo de fallas que se pueden ocasionar por ese cambio en los parámetros del SDM de un panel PV.

- **Incremento de la resistencia R_s :** Este cambio se debe al desgaste que puede tener un panel PV ante su exposición en ambientes en los cuales existe recurrencia de trabajos agrícolas, lugares que generen grandes cantidades de polvo y suciedad o simplemente que estén ubicados en áreas metropolitanas. Este puede causar deformaciones en la dinámica del perfil PV causando que esta se vuelva más cóncava la curva de potencia [25].
- **Disminución de la corriente I_{pv} del panel PV:** La disminución de corriente se puede determinar como una falla por sombreado parcial o total; también puede realizarse mediante el seguimiento del MPPT ya que al bajar el nivel de potencia de un panel PV bajo altos niveles de irradiación este se puede definir como una falla [25].
- **Incremento de R_s y disminución de la resistencia en paralelo R_{sh} :** Los cambios de ambas resistencias en los parámetros del panel PV a partir de la curva de V-I, pueden catalogarse como una falla por oxido en los paneles PV ya que esta genera cambios en los niveles de potencia y la corriente [25].




Figura 4.4: Diagrama representativo de funcionamiento total para el diagnóstico de fallas

Como se observa en la Fig. 4.4, esta muestra el proceso completo realizado para el diagnóstico de fallas en un panel PV. Este proceso inicia con el panel PV el cual se le adquieren los datos de V-I mediante el SWD, dispositivo encargado de hacer los barridos, los cuales deben ser regulados mediante divisores de tensión los cuales son necesarios para poder llevarlos al Arduino Due. Luego de la adquisición por parte del dispositivo embebido los datos son enviados via puerto serial a Matlab para que estos sean representados bajo perfiles de V-P por facilidad visual. Cuando los datos están en Matlab se procede a implementar la técnica de optimización en la estimación de los parámetros del modelo matemático del panel PV bajo análisis esto bajo los datos de V-I y se finaliza con el diagnóstico de fallas del panel comparando los perfiles PV ideal, adquirido por el SWD versus el estimado por la técnica de optimización.

El paso a seguir es incorporar el tipo de fallas a simular con los cambios en los parámetros del panel PV bajo análisis. Bajo el supuesto de esta información, se determina realizar el diagnóstico de fallas en un panel PV de referencia BP585 del laboratorio de electrónica y energías renovables del ITM. Sus características principales serán definidas en la siguiente Tabla 4.2.

Panel BP585	
N. Celdas	36
P_{max} [W]	85
V_{mp} [V]	18
I_{mp} [A]	4.72
I_{sc} [A]	5

Tabla 4.2: Paneles fotovoltaicos y sus características principales de la hoja de datos del fabricante

En esta se presenta de izquierda a derecha, las características básicas como el número de celdas ($N.Celdas$), los valores de potencia máxima (P_{max}), voltaje de máximo punto (V_{max}), corriente de máximo punto (I_{max}) y la corriente de corto circuito (I_{sc}).

4.3. DIAGNÓSTICO DE FALLAS EN UN PANEL PV A PARTIR DE LA ESTIMACIÓN DE PARÁMETROS DEL SDM DE UN PANEL PV

Con toda la información presentada anteriormente se propone un método de diagnóstico de fallas a partir de los datos V-I y la implementación de la técnica de optimización CGA, en la cual se presentarán los resultados, los cuales se tomaron dos escenarios de pruebas (dos paneles fotovoltaicos de la misma referencia), ya que son los existentes en el laboratorio y por ende son paneles con desgaste y vida útil diferente dichos paneles. A estos se les adquirieron los valores de V-I, bajo niveles de irradiancia $G = 1000 [W/m^2]$, luego se aplicó la técnica de optimización CGA para realizar la estimación de parámetros, seguido del diagnóstico de fallas que presente cada uno de estos paneles que se tienen para trabajar.

En busca de comprobar la efectividad del método propuesto, como se ha mencionado, se emplea el CGA. La técnica de optimización tendrá el mismo método de validación usado en el capítulo 3 ya que estos resultados se obtuvieron de datos de V-I bajo STC y no ante datos bajo no STC los cuales serán adquiridos por el SWD. Por lo que, se opta en tener una población de 50 individuos, 10000 iteraciones máximas y un contador de no mejora de 100 iteraciones; basados en la premisa de no explorar más el espacio de solución, si la mejor solución no mejora. Finalmente, para obtener los tiempos promedios de procesamiento requeridos para los métodos de solución empleados, se ejecutó 1000 veces en cada escenario de prueba.

Los resultados obtenidos para el diagnóstico de fallas son presentados en las Tablas 4.3 y 4.4, se harán los análisis de los resultados por la técnica de optimización ante datos reales adquiridos por el SWD al realizar el diagnóstico de fallas teniendo en cuenta la representación del perfil PV bajo condiciones STC el cual presenta un estado óptimo de funcionamiento de un panel PV y se compararon con los medidos por dichos paneles desgastados y el estimado por la técnica de optimización, para finalizar con el diagnóstico del panel PV.

BP585 (1)	
Mejor Solución	0,02882867
Peor Solución	0,85245668
Valor Medio	0,19763632
Desviación Estándar	0,17676947
Tiempo Promedio	1,98997182
BP585 (2)	
Mejor Solución	0,01633958
Peor Solución	0,83859714
Valor Medio	0,18707659
Desviación Estándar	0,18260825
Tiempo Promedio	4,1049624

Tabla 4.3: Resultados obtenidos por la técnica de optimización CGA en la estimación de parámetros del SDM

La información es presentada de la siguiente manera en la Tabla 4.3: la primera fila contiene el panel PV *BP585(1)*, en la segunda y tercera fila se presentan la mejor solución encontrada y el peor resultado hallado por la técnica de optimización. En la fila cuatro, se encuentra el valor medio del error hallado por la técnica de optimización, en la quinta fila se presenta la desviación estándar del error; en la fila seis se presenta el tiempo promedio de ejecución. En la fila siete aparecen los datos del panel PV *BP585(2)* y el resto de datos son los mismos mencionados anteriormente. Todos estos resultados, bajo la función objetivo (minimización de estimación de los parámetros que determinan los valores de la corriente I).

Parámetros	η	R_s [Ω]	R_h [Ω]	I_{d1} [A]	I_{ph} [A]
Parámetros ideales	1,0664	0,26488	8308,033	9,19E-07	5
Mejores individuos BP585(1)	1,5098676	1,52304739	30,0602684	9,2871E-06	5,12569004
Mejores individuos BP585(2)	1,60014171	1,51055798	982,445952	9,8245E-06	4,45750296

Tabla 4.4: Resultados de los pesos obtenidos a partir de datos reales de un panel PV

En la Tabla 4.4, se presentan los mejores individuos que permitieron obtener la mejor representación de los perfiles PV. la fila uno representa los parámetros estimados, la fila dos los parametros ideales del panel BP585, la tercera fila los resultados de la estimación de parámetros del *BP585(1)* y la cuarta fila presenta los mejores resultados obtenidos para el *BP585(2)*.

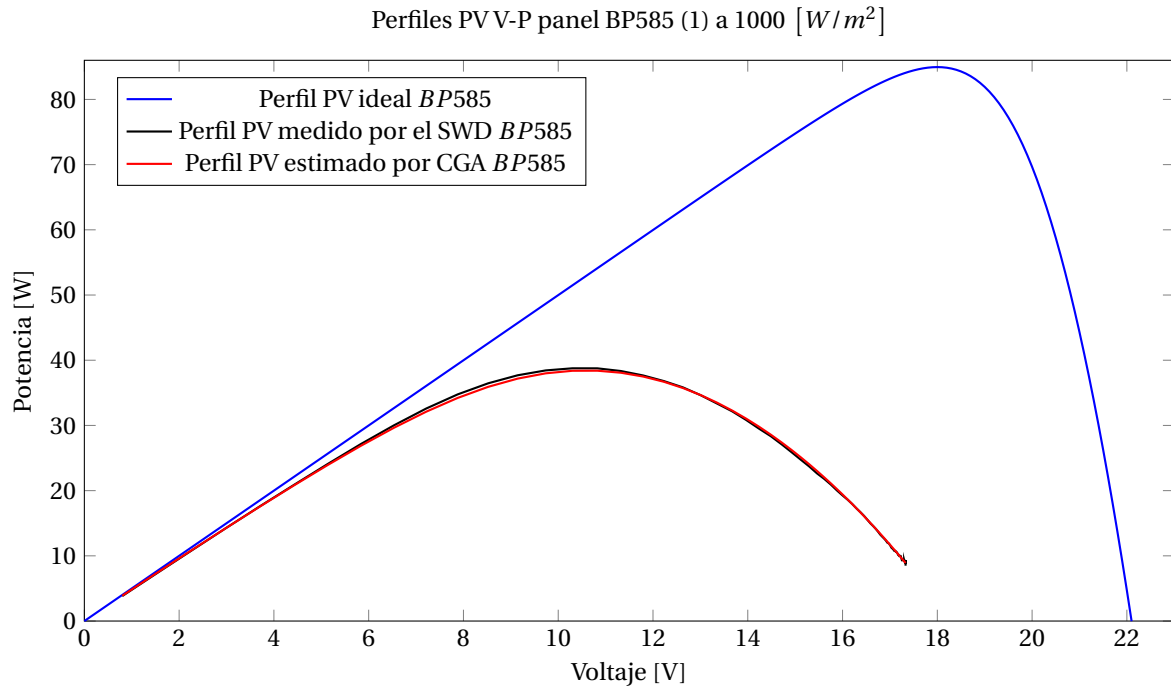


Figura 4.5: Perfiles PV para el diagnóstico de fallas del panel BP585 (1)

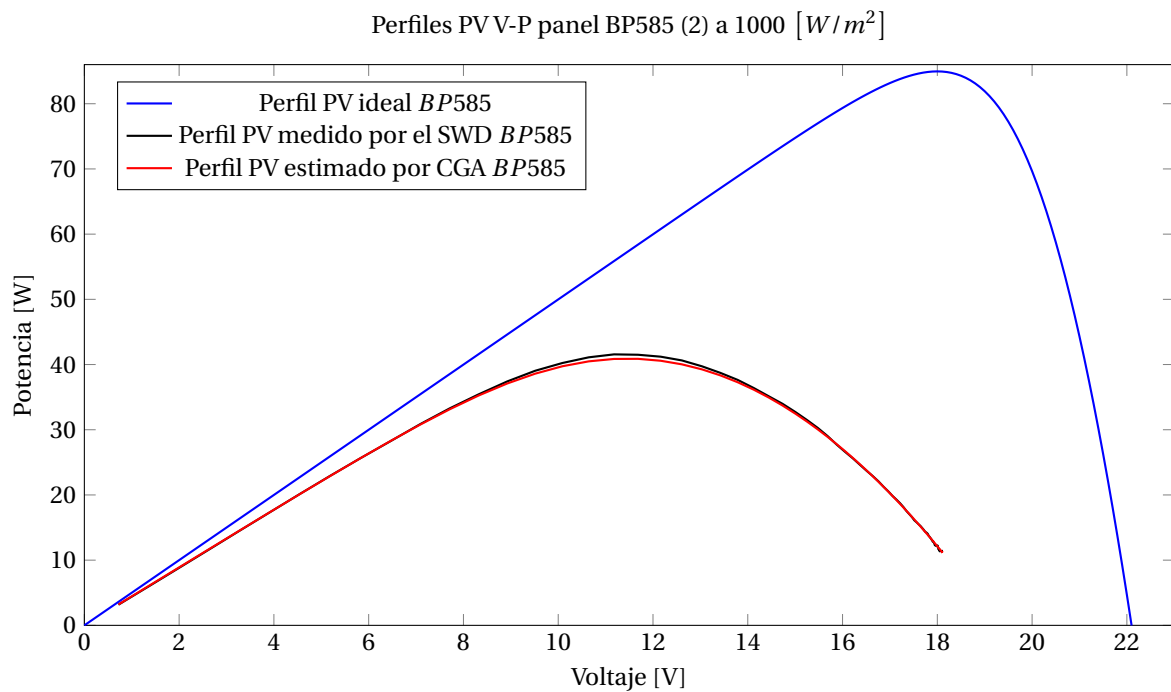


Figura 4.6: Perfiles PV para el diagnóstico de fallas del panel BP585 (2)

Como se puede observar en la Figura 4.5 y 4.6. Estas muestran a los perfiles ideales comparados con los medidos y estimados respectivamente, se observan las pérdidas en los niveles de potencia. Al tomar estas medidas sobre un panel PV, se puede observar que este presenta desgastes considerables bajo un mismo nivel de

irradiancia de $G = 1000 [W/m^2]$ en contraste con un panel PV bajo condiciones STC. Estos fuertes cambios se deben a los tiempos de exposición que han tenidos a distintos ambientes, a la poca supervisión y el poco mantenimiento, demuestran los niveles de deterioro que tienen en la generación de potencia. Además de esto, se puede observar cómo los perfiles PV de los paneles no alcanzan sus niveles máximos de voltaje de circuito abierto. Cabe resaltar que estos paneles PV presentan cambios en la mayoría de los parámetros del SDM, tiene incremento en los parámetros (η_1) y la resistencia R_s , reducciones sustanciales en la resistencia R_{sh} mientras que los otros dos parámetros se mantienen de forma próxima a los parámetros (I_{d1}) e (I_{ph}). Este análisis nos permite determinar que el panel PV presenta fallas por envejecimiento y desgaste. Humedad no presenta debido a que cuando se realizaron las pruebas dicho panel no presentaba ningún tipo de humedad o gotas de lluvias en él. Por otra parte, el panel PV no presenta disminución en la corriente I_{ph} ya que las pruebas cuando fueron obtenidas no existían sombreados parciales o totales. Por último el panel sí presenta disminución también en la resistencia R_{sh} ya que este en algunas partes de las celdas pequeños rastros de oxido.

4.3.1. CONCLUSIONES

Para el diagnóstico de fallas en un panel PV mediante el uso de un algoritmo genético se concluye que se pueden determinar algunas fallas a partir de la estimación de parámetros de un panel PV. Para este caso los paneles PV presentaron dos tipos de fallas juntas en los paneles PV. Por esto, se debe tener en cuenta que los parámetros ideales tienden a variar cuando este se desgasta. Por esto es necesario conocer los datos ofrecidos por la hoja de datos del fabricante, también es necesario realizar mantenimientos a los paneles PV, ya que, si estos no son cuidados de forma apropiada, su vida útil se reducirá sustancialmente. También es necesario realizar la adquisición de los datos de V-I o V-P para examinar los perfiles PV ya que, si estos tienden a generar cambios constantes en las medidas de voltaje o pérdidas en los niveles de potencia, estos podrían generar daños permanentes e irreparables cuando estén conectados en arreglos PV.

Por otra parte, las técnicas de optimización permiten estimar los parámetros de un panel PV y aproximarse a sus representaciones PV. Estas técnicas pueden ser de utilidad si se tiene clara la función objetivo y las restricciones o el espacio de búsqueda. teniendo clara esta información como se observaron en los resultados, las técnicas de optimización pueden presentar tiempos de computo favorables para el diagnóstico de fallas en un panel PV.

Como parte final de este trabajo se incorpora en la Tabla 4.5. Cada uno de los productos derivados de esta tesis de maestría. Para mayor información ver los Anexos en el capítulo 5.

Nombre de la revista	Categoría	Título del artículo	Estado del artículo
Energies MDPI	Q1	MPPT of a Photovoltaic Panels Array with Partial Shading Using the IPSM with Implementation Both in Simulation as in Hardware	Publicado
International Journal of Energy and Environmental Engineering	Q2	Grasshopper optimization algorithm for parameter estimation of photovoltaic modules based on the single diode model	Publicado
Statistics, Optimization And Information Computing	Q3	Optimal Power Flow in Direct Current Networks Using the Antlion Optimizer	Aceptado
Ingenierías universidad de Medellín	B	Estimación de los parámetros del modelo de un solo diodo del módulo fotovoltaico aplicando el método de optimización basado en búsqueda de patrones mejorado.	Aceptado
Arabian Journal for Science and Engineering	Q2	Estimating the parameters of a single-diode equivalent mathematical model of a photovoltaic module using the continuous genetic algorithm	Sometido

Tabla 4.5: Productos derivados de la tesis de maestría

REFERENCIAS

- [1] Joel Krueger and Duncan Smith. A practical approach to fire hazard analysis for offshore structures. *Journal of hazardous materials*, 104(1-3):107–122, 2003.
- [2] Hiba Al-Sheikh and Nazih Moubayed. Fault detection and diagnosis of renewable energy systems: An overview. In *2012 International Conference on Renewable Energies for Developing Countries (REDEC)*, pages 1–7. IEEE, 2012.
- [3] Gary D Hasenfus. Smart sensors for solar panels, October 23 2012. US Patent 8,294,451.
- [4] Moath Alsafasfeh, Ikhlas Abdel-Qader, Bradley Bazuin, Qais Alsafasfeh, and Wencong Su. Unsupervised fault detection and analysis for large photovoltaic systems using drones and machine vision. *Energies*, 11(9):2252, 2018.
- [5] Mahmoud Dhimish and Ghadeer Badran. Photovoltaic hot-spots fault detection algorithm using fuzzy systems. *IEEE Transactions on Device and Materials Reliability*, 19(4):671–679, 2019.
- [6] Elyes Garoudja, Fouzi Harrou, Ying Sun, Kamel Kara, Aissa Chouder, and Santiago Silvestre. Statistical fault detection in photovoltaic systems. *Solar Energy*, 150:485–499, 2017.
- [7] Emma Pedersen, Sunil Rao, Sameeksha Katoch, Kristen Jaskie, Andreas Spanias, Cihan Tepedelenlioglu, and Elias Kyriakides. Pv array fault detection using radial basis networks. In *2019 10th International Conference on Information, Intelligence, Systems and Applications (IISA)*, pages 1–4. IEEE, 2019.
- [8] C Birk Jones, Joshua S Stein, Sigifredo Gonzalez, and Bruce H King. Photovoltaic system fault detection and diagnostics using laterally primed adaptive resonance theory neural network. In *2015 IEEE 42nd Photovoltaic Specialist Conference (PVSC)*, pages 1–6. IEEE, 2015.
- [9] AH Mohamed and AM Nassar. New algorithm for fault diagnosis of photovoltaic energy systems. *International Journal of Computer Applications*, 114(9), 2015.
- [10] Zahi M Omer, Abbas A Fardoun, and Ala Hussain. Large scale photovoltaic array fault diagnosis for optimized solar cell parameters extracted by heuristic evolutionary algorithm. In *2016 IEEE Power And Energy Society General Meeting (PESGM)*, pages 1–5. IEEE, 2016.
- [11] Dezso Sera. Series resistance monitoring for photovoltaic modules in the vicinity of mpp. In *25th European photovoltaic solar energy conference and exhibition*, pages 4506–4510, 2010.
- [12] Mohamed Hassan Ali, Abdelhamid Rabhi, Ahmed El Hajjaji, and Giuseppe M Tina. Real time fault detection in photovoltaic systems. *Energy Procedia*, 111:914–923, 2017.
- [13] Juan David Bastidas-Rodríguez, Edinson Franco, Giovanni Petrone, Carlos Andrés Ramos-Paja, and Giovanni Spagnuolo. Model-based degradation analysis of photovoltaic modules through series resistance estimation. *IEEE Transactions on Industrial Electronics*, 62(11):7256–7265, 2015.
- [14] Michael G Deceglie, Matthew Muller, Dirk C Jordan, and Chris Deline. Numerical validation of an algorithm for combined soiling and degradation analysis of photovoltaic systems. In *2019 IEEE 46th Photovoltaic Specialists Conference (PVSC)*, pages 3111–3114. IEEE, 2019.
- [15] YH Chen, R Liang, Y Tian, and F Wang. A novel fault diagnosis method of pv based-on power loss and iv characteristics. In *IOP Conference Series: Earth and Environmental Science*, volume 40, page 012022. IOP Publishing, 2016.
- [16] Zhicong Chen, Fuchang Han, Lijun Wu, Jinling Yu, Shuying Cheng, Peijie Lin, and Huihuang Chen. Random forest based intelligent fault diagnosis for pv arrays using array voltage and string currents. *Energy conversion and management*, 178:250–264, 2018.
- [17] W Chine, A Mellit, Vanni Lughi, A Malek, Giorgio Sulligoi, and A Massi Pavan. A novel fault diagnosis technique for photovoltaic systems based on artificial neural networks. *Renewable Energy*, 90:501–512, 2016.

- [18] Zhicong Chen, Lijun Wu, Shuying Cheng, Peijie Lin, Yue Wu, and Wencheng Lin. Intelligent fault diagnosis of photovoltaic arrays based on optimized kernel extreme learning machine and iv characteristics. *Applied Energy*, 204:912–931, 2017.
- [19] Peijie Lin, Yaohai Lin, Zhicong Chen, Lijun Wu, Lingchen Chen, and Shuying Cheng. A density peak-based clustering approach for fault diagnosis of photovoltaic arrays. *International Journal of Photoenergy*, 2017, 2017.
- [20] Honglu Zhu, Lingxing Lu, Jianxi Yao, Songyuan Dai, and Yang Hu. Fault diagnosis approach for photovoltaic arrays based on unsupervised sample clustering and probabilistic neural network model. *Solar Energy*, 176:395–405, 2018.
- [21] Shengyang Liu, Lei Dong, Xiaozhong Liao, Ying Hao, Xiaodong Cao, and Xiaoxiao Wang. A dilation and erosion-based clustering approach for fault diagnosis of photovoltaic arrays. *IEEE Sensors Journal*, 19(11):4123–4137, 2019.
- [22] Ye Zhao, Roy Ball, Jerry Mosesian, Jean-François de Palma, and Brad Lehman. Graph-based semi-supervised learning for fault detection and classification in solar photovoltaic arrays. *IEEE Transactions on Power Electronics*, 30(5):2848–2858, 2014.
- [23] Hosna Momeni, Nasser Sadoogi, Meisam Farrokhifar, and Hamed Farhadi Gharibeh. Fault diagnosis in photovoltaic arrays using gbssl method and proposing a fault correction system. *IEEE Transactions on Industrial Informatics*, 2019.
- [24] Peng Xu, Jin Ming Hou, and Deng Kuo Yuan. Fault diagnosis for building grid-connected photovoltaic system based on analysis of energy loss. In *Advanced Materials Research*, volume 805, pages 93–98. Trans Tech Publ, 2013.
- [25] Jun-Ming Huang, Rong-Jong Wai, and Geng-Jie Yang. Design of hybrid artificial bee colony algorithm and semi-supervised extreme learning machine for pv fault diagnoses by considering dust impact. *IEEE Transactions on Power Electronics*, 2019.

5

ANEXOS

Contenido

5.1 Función objetivo del modelo matemático equivalente de un diodo de un panel PV	61
5.2 Código del Algoritmo Genético Continuo	62
5.3 Artículos publicados en el marco de la investigación de la tesis	65
5.4 Artículos aceptados en el marco de la investigación de la tesis	68
5.5 Artículos sometidos en el marco de la investigación de la tesis	71

5.1. FUNCIÓN OBJETIVO DEL MODELO MATEMÁTICO EQUIVALENTE DE UN DIODO DE UN PANEL PV

```
function error= Fast_calculo_error_one(parametros, Dat_MSX60,Ns)
```

```
LengthD=length(Dat_MSX60(:,1));  
Ant=length(parametros);  
Ns1 = ones(LengthD,Ant)*Ns; %Numero de celdas en serie del PV  
k = 1.3806503e-23; %Constante de Boltzman (J/K)  
q = 1.60217646e-19; %Carga del electron (C)  
a1 = ones(LengthD,Ant)*1; %Factor de idealidad del diodo  
Tn = 25+273; %Temperatura de operacion nominal (K)  
Vtn = k*Tn/q; %Voltaje de union termica (nominal)  
error=[];
```

```
%Valores aleatorios de cada una de las variables
```

```
n1=ones(LengthD,1)*parametros(:,1)';  
Rser=ones(LengthD,1)*parametros(:,2)';  
Rpar=ones(LengthD,1)*parametros(:,3)';  
Io1=ones(LengthD,1)*parametros(:,4)';  
Iph=ones(LengthD,1)*parametros(:,5)';  
Vtn1=ones(LengthD,Ant)*Vtn;  
Vt1=n1.*Vtn1;  
V = Dat_MSX60(:,1);  
Ipvm = (zeros(Ant,length(V)))';  
I_pvm=[];
```

```

% Solves  $g = I - f(I, V) = 0$  with Newton-Raphson
Ip= Iph-Io1.*(exp((V+Ipvm.*Rser)./Vt1./Ns./a1)-ones(LengthD, Ant)*1)-(V+Ipvm.*Rser)./Rpar-Ipvm;
while (abs(Ip)>0.000001)
    Id1=Io1.*(exp((V+Ipvm.*Rser)./Vt1./Ns./a1)-ones(LengthD, Ant)*1);
    Ip = Iph-Id1-(V+Ipvm.*Rser)./Rpar-Ipvm;
    Ilin = -Io1.*Rser./Vt1./Ns./a1.*exp((V+Ipvm.*Rser)./Vt1./Ns./a1)-Rser./Rpar-ones(LengthD, Ant)*1;
    I = Ipvm - Ip./Ilin;
    Ipvm=I;
end

[minio]=abs(Dat_MSX60(:,2)-Ipvm);%calculo del error absoluto en cada punto de analisis
[error]=[minio];%almacena el error dato por dato
error_global=sqrt((sum(error.^2))/length(error));
error=error_global;%muestreo el error

```

5.2. CÓDIGO DEL ALGORITMO GENÉTICO CONTINUO

```

clear all;
clc;
cla;
format longG

warning off
PP=10;
Sol_fo=zeros(PP,1);
Sol_Elite=zeros(PP,5);
Time_prom=zeros(PP,1);
for z=1:PP

dmax=[2.0; 5; 10000; 1e-5; 6];
dmin=[0.5; 0; 0; 0; 0];
Ns=36;
E=0.001;
Dim = 5;
tmax = 10000;
N =50;
NoMejora = tmax;
Contar=1;
sumapos=1;
err=[];
Pob=rand(N,Dim).*repmat(dmax',N,1);
Tor = 4; %%Numero de individuos por torneo
PobAux = [Pob,zeros(N,1)];
error=Fast_calculo_error_one(PobAux, Dat_MSX60,Ns);%evaluacion fo
PobAux(:,end) = error;
PobAux = sortrows(PobAux,Dim+1);
Incumbente = PobAux(1,end);
tic;
while Contar<tmax
    if Contar>tmax
        break
    end

```

```

Pob1 = zeros(Tor,Dim);
Pob1=rand(Tor,Dim).*repmat(dmax',Tor,1);
Pob2 = zeros(Tor,Dim);
while (true)
    p = randi([1,N],1,Tor);
    if size(unique(p),2)==Tor
        break;
    end
end
Pob2= PobAux(p,1:end-1);
%%%Recombinacion
Pob3 = zeros(2*Tor,Dim);
p = [];
while (true)
    p = randi([2,Dim],1,Tor);
    if size(unique(p),2)==Tor
        break;
    end
end
for i = 1:Tor
    par = 2*i; impar = 2*i-1;
    Pob3(impar,:) = [Pob1(i,1:p(i)),Pob2(i,1+p(i):end)];
    Pob3(par,:) = [Pob2(i,1:p(i)),Pob1(i,1+p(i):end)];
end
%%%Mutacion
for i =1:2*Tor
    if rand > 0.5
        a = randi([1 Dim],2,1);
        Pob3(i,a) = dmin(a) + (dmax(a)-dmin(a))*rand;
    end
end
Pob2= [Pob3,zeros(2*Tor,1)];
error=Fast_calculo_error_one(Pob2, Dat_MSX60,Ns); %evaluacion fO
Pob2(:,end) = error;
Pob2 = sortrows(Pob2,Dim+1);
%%%Reemplazo del Ganador en la poblacion
Ganador = Pob2(1,:);
if Ganador(:,end) < PobAux(:,1:end-1)
    PobAux(:, :) = Ganador;
end
if (Ganador(:,end) < PobAux(end,end))
    PobAux(end, :) = Ganador;
end
PobAux = sortrows(PobAux,Dim+1);
Incumbente = Ganador(1,end);
Contar = Contar + 1;
if (Contar/N)>=80 %veces que no mejora
    break;
end
end
time=toc;
Sol_fo(z,1)=PobAux(1,6);
Sol_Elite(z,:)=PobAux(1,1:5);

```

```

Time_prom(z,1)=time;
end
Time_prom=sum(Time_prom)/PP;
%%
[~,fil]=min(Sol_fo);
Mejor_fo=Sol_fo(fil,:);
Mejor_Elite=Sol_Elite(fil,:);
%%
[~,fil]=max(Sol_fo);
Peor_fo=Sol_fo(fil,:);
Peor_Elite=Sol_Elite(fil,:);
%%
disp(['Mejor_fo:_', num2str(Mejor_fo)])
disp(['Mejor_Elite:_', num2str(Mejor_Elite)])
disp(['Time_prom:_', num2str(Time_prom)])
disp(['Peor_fo:_', num2str(Peor_fo)])
disp(['Peor_Elite:_', num2str(Peor_Elite)])
%%
%%Constantes
k = 1.3806503e-23;      %Constante de Boltzman (J/K)
q = 1.60217646e-19;   %Carga del electron (C)
a1 = 1;                %Factor de idealidad del diodo
Tn = 25+273;          %Temperatura de operacion nominal (K)
Vtn = k*Tn/q;         %Voltaje de union termica (nominal)

fprintf(['\nAlgoritmo_Genetico ', '\n']);

n1=PobAux(1,1);
Rser=PobAux(1,2);
Rpar=PobAux(1,3);
Io1=PobAux(1,4);
Iph=PobAux(1,5);
disp(['n1:_', num2str(n1)])
disp(['Rser:_', num2str(Rser)])
disp(['Rpar:_', num2str(Rpar)])
disp(['Io1:_', num2str(Io1)])
disp(['Iph:_', num2str(Iph)])
fprintf(['Error_Min_ALO:_', num2str(PobAux(1,6)*100), '\n']);
disp(['tiempo:_', num2str(time)])

error=[];
V = Dat_MSX60(:,1);
Ipvm = (zeros(1,length(V)))';
Vt1=n1*Vtn;
I_pvm=[];
for j=1:length(Dat_MSX60(:,1))
    % Solves  $g = I - f(I,V) = 0$  with Newntonn-Raphson
    Ip(j) = Iph-Io1*(exp((V(j)+Ipvm(j)*Rser)/Vt1/Ns/a1)-1)-(V(j)+Ipvm(j)*Rser)/Rpar-Ipvm(j);
    while (abs(Ip(j)) > 0.001)
        Id1=Io1*(exp((V(j)+Ipvm(j)*Rser)/Vt1/Ns/a1)-1);
        Ip(j) = Iph-Id1-(V(j)+Ipvm(j)*Rser)/Rpar-Ipvm(j);
        Ilin(j) = -Io1*Rser/Vt1/Ns/a1*exp((V(j)+Ipvm(j)*Rser)/Vt1/Ns/a1)-Rser/Rpar-1;
        I(j) = Ipvm(j) - Ip(j)/Ilin(j);
    end
end

```





```
    Ipvm(j)=I(j);
end
[ minio]=abs((Dat_MSX60(j,2)-(Ipvm(j))));
[ error]=[ error; minio];
end
error_global=sqrt((sum(error(:,1).^2))/length(error));
error=error_global; %muestro el error

plot(Dat_MSX60(:,1),Dat_MSX60(:,1).*Dat_MSX60(:,2), 'r', 'LineWidth',1)
hold on
plot(V,V.*Ipvm, 'b', 'LineWidth',1)
xlabel('$Voltaje~(V)$', 'Interpreter', 'latex', 'FontSize',16)
ylabel('$Potencia~(W)$', 'Interpreter', 'latex', 'FontSize',16)
set(gca, 'FontName', 'Arial', 'FontWeight', 'Bold', 'FontSize',16)
```

5.3. ARTÍCULOS PUBLICADOS EN EL MARCO DE LA INVESTIGACIÓN DE LA TESIS

Article

MPPT of a Photovoltaic Panels Array with Partial Shading Using the IPSM with Implementation Both in Simulation as in Hardware

Andrés Tobón ^{1,*}, Julián Peláez-Restrepo ¹ , Jhon Montano ¹, Mariana Durango ¹ ,
Jorge Herrera ² and Asier Ibeas ^{2,3}

¹ Departamento de Electrónica y Telecomunicaciones, Facultad de Ingenierías, Instituto Tecnológico Metropolitano, 050035 Medellín, Antioquia, Colombia; julianpelaez@itm.edu.co (J.P.-R.); jhonjairo_09@live.com (J.M.); marianadurango134392@correo.itm.edu.co (M.D.)

² Departamento de Ingeniería, Facultad de Ciencias Naturales e Ingeniería, Universidad de Bogotá Jorge Tadeo Lozano, 110311 Bogotá, Distrito Capital, Colombia; jaureher@hotmail.com (J.H.); asier.ibeas@uab.cat (A.I.)

³ Department of Telecommunications and Systems Engineering, Universitat Autònoma de Barcelona (UAB), 08193 Bellaterra, Cerdanyola del Vallés, 08193 Barcelona, Spain

* Correspondence: andrestobon@itm.edu.co; Tel.: +57-4-460-0727 (ext. 5560)

Received: 22 November 2019; Accepted: 17 December 2019; Published: 13 February 2020



Abstract: This article presents a method for the Maximum Power Point Tracking (MPPT) of a Photovoltaic (PV) panels array with partial shading, applying an Improved Pattern Search Method (IPSM). The method is simulated in PSIM[®] and then implemented in hardware in the loop system, emulating the PV array on an industrial computer (Speedgoat) that allows real-time emulations and the IPSM is applied in an Arduino DUE. The experiments were carried out with TP245S-20/WD, KYOCERA KC200GT, YINGLY SOLAR JS65, and MSX60 photovoltaic panels. The results are the proper MPPT with changes in partial shading over time, inducing the increase and decrease of the maximum power point. The results obtained are the search for the global maximum power point in a matrix of panels in which, due to partial shading, it might have several local maximum power points, and thanks to the IPSM algorithm, it always manages to find the global maximum power point. Finally, the results are compared with other methods where it was found that IPSM had faster answers.

Keywords: solar power system; maximum power point tracking; pattern search method; partial shading

1. Introduction

Electricity is mostly generated through systems that deteriorate the environment, such as the burning of fossil fuels. This method of conventional generation has caused strong criticism from the scientific community and society in general due to its direct impact on global warming. The need for electric power has grown exponentially in recent decades and issues related to current power supply systems are fundamental to this [1], making the development of sustainable, renewable energy generation processes a highly interesting topic for the academic community.

As a solution to all these problems, smart grid systems are being worked on. This consists of migrating from a centralized energy generation system to a distributed energy generation system. Among the energy conversion systems most used for these systems are renewable generation systems [2].

Among the renewable generation systems, the most commonly used are wind turbines and photovoltaic (PV) panels. Wind-powered systems, whose fuel is abundant and free, present



Grasshopper optimization algorithm for parameter estimation of photovoltaic modules based on the single diode model

J. Montano¹ · A. F. Tobón¹ · J. P. Villegas² · M. Durango¹

Received: 13 August 2019 / Accepted: 7 February 2020
© Islamic Azad University 2020

Abstract

This paper presents an accurate application of the Grasshopper Optimization Algorithm (GOA) for estimating the optimal parameters of the single diode model (SDM) of a photovoltaic (PV) module from experimental data, which as is well known, and its non-linear current vs voltage (I–V) profile make its modeling challenging. The accuracy and execution time obtained with GOA were compared with metaheuristic techniques such as genetic algorithm (GA) and particle swarm optimization algorithm (PSO). The analysis and validation were effectuated on four different types of PV modules for each optimization algorithm, confirming a good relation between computational time and reliability of GOA in estimating the parameters of the PV module.

Keywords Single diode model · Grasshopper optimizer · Parameter identification · Photovoltaic modules

Introduction

Over the years, there has been a progressive increase in energy demand, and today, the most common sources are those based on fossil fuels and nuclear energy, which threatens the climate stability of the planet and human health [15]. As possible solutions, it has been worked hard on renewable energies such as wind, solar, and biomass, appearing as a promising option due to their sustainability and security [12]. Solar energy is one of the most common renewable energies, based on photovoltaic modules that transform the light from the sun into electrical energy; as they only depend on the sun, solar energy has become a trend at the level of sales and research, because it is a sustainable solution, low pollution, low maintenance, and easy installation, and its

energy source is unlimited, so they have had a growing and continuous development [6].

PV modules efficiency depends on the temperature and the incident irradiation (e.g., fully irradiated or in partial shading conditions), as described in [23]. For this reason, a mathematical model based on a non-linear equation is expressed to describe the physical behavior of the PV modules under different operating ranges. These models are a research focus, since the model depends on several variables that will change depending on the PV module manufacturer's data and the climate conditions described, additionally, depending on the material type of the PV module, either is monocrystalline or polycrystalline, the mathematical model will have five (i.e., SDM, Single Diode Model) or seven (i.e., DDM, Double Diode Model) unknown variables, respectively, to be identified [1].

In the literature, there are proposed different techniques for estimating the parameters of the mathematical model of a PV module, the most commonly adopted are analytical methods or optimization techniques, the analytical method structures itself in the numerical solution of the equations representative of the behavior of the module [30, 35], the reduced form [24], Lambert W [10, 22], Pade's approach [19], and the minimum squares [9, 36]. However, the analytical methods depend on the initial conditions of the PV module and, it is necessary to know the irradiation profile and the ambient temperature; besides, it does not take into account

✉ A. F. Tobón
andrestobon@itm.edu.co

J. Montano
jhonrojas129959@correo.itm.edu.co

J. P. Villegas
juan.villegas@pascualbravo.edu.co

M. Durango
marianadurango134392@correo.itm.edu.co

¹ Cr31 N No. 54-10, Medellín, Colombia

² Cll 73 No. 73A - 226, Medellín, Colombia



5.4. ARTÍCULOS ACEPTADOS EN EL MARCO DE LA INVESTIGACIÓN DE LA TESIS

OPTIMAL POWER FLOW IN DIRECT CURRENT NETWORKS USING THE ANTLION OPTIMIZER

Oscar Daniel GARZON¹, Luis Fernando GRISALES¹, Oscar Danilo MONTROYA², Jhon Jairo ROJAS³, Jauder Alexander OCAMPO¹

¹Department of Electromechanical and Mechatronic Engineering, Instituto Tecnológico Metropolitano, Medellín, Colombia

²Program of Electrical and Electronic Engineering, Faculty of Engineering, Universidad Tecnológica de Bolívar, Cartagena, Colombia

³Department of Electronic Engineering, Instituto Tecnológico Metropolitano, Medellín, Colombia

oscargarzon220554@correo.itm.edu.co, luisgrisales@itm.edu.co, omontroya@utb.edu.co, jhonrojas129959@correo.itm.edu.co, jauderocampo64905@correo.itm.edu.co

DOI: [10.15598/aece.v13ix.xxxx](https://doi.org/10.15598/aece.v13ix.xxxx)

Abstract. This document presents a solution method for optimal power flow (OPF) problem in direct current (DC) networks by implementing a master-slave optimization methodology that combines an antlion optimizer (ALO) and a power flow approach based on successive approximation (SA). In the master stage, the ALO determines the optimal amount of power to be delivered by all the distributed generators (DGs) in order to minimize the total power losses in the distribution lines of the DC network. In slave stage, the power flow problem is solved considering constant power loads and power outputs of DGs as constants. To validate the effectiveness and robustness of the proposed model, two additional comparative methods were implemented: particle swarm optimization (PSO) and black hole optimization (BHO). Two distribution test feeders (21 and 69 nodes) were simulated under different scenarios of distributed power generation. The simulations, conducted in MATLAB 2018b, show that the proposed method presents a better balance between power loss minimization and computational time required to find the optimal solution regardless of the size of the DC network.

Keywords

Antlion optimization, direct current micro-grids, metaheuristic optimization methods, optimal power flow analysis, power flow method, successive approximation.

1. Introduction

Micro Grids (MGs) are defined as small-scale electrical systems that can operate with Alternating Current (AC) or Direct Current (DC) and in isolation or connected to the electrical grid [1]. MGs can integrate different distributed energy resources, such as energy storage (batteries, supercondensers, or fuel cells) and distributed generation systems based on renewable energy sources (sun, wind, and thermal energy, among others) or their non-renewable counterparts (coal, gas, and oil, among others).

Since most devices used in the industry and households work with DC, implementing a DC Micro Grid (DC MG) offers a reduction in implementation costs and energy losses because AC/DC converters are not necessary [2]. Thus, the energy they used to operate is better exploited [3]. Additionally, integrating and operating devices in DC MGs is simpler than in AC MGs. Likewise, the mathematical models that represent DC networks are less complex because important variables (such as frequency and reactive power) are inherent to AC networks and nonexistent in DC networks [4]. For those reasons, this document focuses on direct current networks.

Despite of the advantages of DC MGs, they also present different problems to integrate and operate the different devices that compose them [5]; the most noticeable are high network power losses, voltage profiles outside allowable limits, overloaded lines, high investment and operation costs associated with bad design strategies, and energy management. As a result, researchers in this field have been interested in taking the

**Estimación de los parámetros del modelo de un solo diodo del módulo
fotovoltaico aplicando el método de optimización basado en búsqueda de
patrones mejorado.**

Parameters estimation of the single diode model of a photovoltaic module based on the
improved patterns search method.

RESUMEN:

En este artículo se propone el uso del algoritmo de optimización búsqueda de patrones mejorado (IPSM), aplicándolo a la estimación de los parámetros del modelo de un solo diodo de una célula fotovoltaica. Los parámetros por estimar son: la corriente fotovoltaica, la corriente de saturación del diodo, la resistencia serie, la resistencia en paralelo y el factor de idealidad del diodo. La estimación se hace a partir de los datos obtenidos de una curva conocida, es decir que se podría caracterizar una celda fotovoltaica y a partir de los datos de la curva se extraen los parámetros. Los resultados son la identificación de los parámetros y la exactitud del modelo con respecto a la referencia en el punto de máxima potencia (MPP). Adicionalmente se realiza una comparación con el modelo obtenido con tres estimaciones realizadas con el algoritmo de optimización enjambre de partículas (PSO), bajo las mismas condiciones en cantidad de partículas y de iteraciones. El error encontrado, muestra la similitud del modelo con la referencia obtenido de acuerdo con el algoritmo IPSM.

Palabras clave: Electrónica de potencia, sistema fotovoltaico, punto de máxima potencia, búsqueda de patrones, modelo de un solo diodo.

5.5. ARTÍCULOS SOMETIDOS EN EL MARCO DE LA INVESTIGACIÓN DE LA TESIS

Arabian Journal for Science and Engineering

Estimating the parameters of a single-diode equivalent mathematical model of a photovoltaic module using the continuous genetic algorithm

--Manuscript Draft--

Manuscript Number:	
Full Title:	Estimating the parameters of a single-diode equivalent mathematical model of a photovoltaic module using the continuous genetic algorithm
Article Type:	SCI / ENG - Research Article
Section/Category:	ENG-Computer Engineering and Computer Science
Keywords:	Renewable energy, photovoltaic panel, parameter identification, modeling, photovoltaic systems, optimization methods, mathematical model, genetic algorithms
Corresponding Author:	Jhon Jairo Rojas Montano Instituto Tecnológico Metropolitano Medellin, COLOMBIA
Corresponding Author Secondary Information:	
Corresponding Author's Institution:	Instituto Tecnológico Metropolitano
Corresponding Author's Secondary Institution:	
First Author:	Jhon Jairo Rojas Montano
First Author Secondary Information:	
Order of Authors:	Jhon Jairo Rojas Montano Luis Fernando Grisales Noreña Andres Felipe Tobón Mejía Julian Peláez Restrepo Daniel Gonzalez Montoya Mariana Durango Florez
Order of Authors Secondary Information:	
Funding Information:	
Abstract:	<p>Estimating the parameters of a single-diode equivalent model of a PhotoVoltaic (PV) module serves to obtain the real values that represent the power profile of such module and, thus, analyze its physical condition. To solve the parameter estimation problem, we propose implementing the Continuous Genetic Algorithm (CGA) using experimental current-voltage (I-V) data. Five parameters are estimated in this study by means of the CGA: photoinduced current, saturation current and ideality factor of the diode, series resistance, and shunt resistance. We consider, as the objective function, the minimization of the root mean square error between the PV current estimated by the solution method based on the selected parameters and the actual curve of the PV module used as the test scenario. All this is subject to the set of constraints that limits the problem under analysis. To validate the effectiveness and robustness of the proposed method, we compared it to two other methods: the Particle Swarm Optimization (PSO) method and the traditional Genetic Algorithm (GA); in addition, we employed four different types of PV modules (MSX60, SOLAR SJ65, KYOCERA KC200GT, and STP245S) to create the test scenarios using MATLAB 2019b. The results show that the proposed method presents the best relationship between parameter estimation and processing time required to solve the Single-Diode Model (SDM) parameter estimation problem.</p>
Suggested Reviewers:	Moez Feki, PhD Full professor, Universite de Sousse Ecole Superieure des Sciences et de la

REFERENCIAS

CAPÍTULO 0

- [1] M Azab, F Salem, and MI Mosaad. Pv parameters estimation using different evolutionary algorithms. *Journal of Electrical Engineering*, 13(4), 2013.
- [2] Francesco Bonanno, Giacomo Capizzi, G Graditi, C Napoli, and Giuseppe Marco Tina. A radial basis function neural network based approach for the electrical characteristics estimation of a photovoltaic module. *Applied Energy*, 97:956–961, 2012.
- [3] H Wang, Y Liu, M Li, H Huang, HM Xu, RJ Hong, and H Shen. Multifunctional tio2 nanowires-modified nanoparticles bilayer film for 3d dye-sensitized solar cells. *Optoelectron. Adv. Mater. Rapid Commun*, 4(8):1166–1169, 2010.
- [4] Mohammed Q Taha, Qusay H Eesse, and Salih Mohammed Salih. Mathematical modeling of different photovoltaic modules. *Journal of telecommunications*, 11(2):59–64, 2011.
- [5] B Chitti Babu and Suresh Gurjar. A novel simplified two-diode model of photovoltaic (pv) module. *IEEE journal of photovoltaics*, 4(4):1156–1161, 2014.
- [6] Vivek Tamrakar, SC Gupta, and Yashwant Sawle. Single-diode and two-diode pv cell modeling using matlab for studying characteristics of solar cell under varying conditions. *Electrical & Computer Engineering: An International Journal (ECIJ)*, 4(2):67–77, 2015.
- [7] Kashif Ishaque, Zainal Salam, et al. A comprehensive matlab simulink pv system simulator with partial shading capability based on two-diode model. *Solar energy*, 85(9):2217–2227, 2011.
- [8] JC Sánchez Barroso, JPM Correia, N Barth, S Ahzi, and MA Khaleel. A pso algorithm for the calculation of the series and shunt resistances of the pv panel one-diode model. In *2014 International Renewable and Sustainable Energy Conference (IRSEC)*, pages 1–6. IEEE, 2014.
- [9] Jieming Ma, TO Ting, Ka Lok Man, Nan Zhang, Sheng-Uei Guan, and Prudence WH Wong. Parameter estimation of photovoltaic models via cuckoo search. *Journal of Applied Mathematics*, 2013, 2013.
- [10] Nouredine Maouhoub. Photovoltaic module parameter estimation using an analytical approach and least squares method. *Journal of Computational Electronics*, 17(2):784–790, 2018.
- [11] Giuseppina Ciulla, Valerio Lo Brano, Vincenzo Di Dio, and Giovanni Cipriani. A comparison of different one-diode models for the representation of i–v characteristic of a pv cell. *Renewable and Sustainable Energy Reviews*, 32:684–696, 2014.
- [12] Hugo Nunes, José Pombo, João Fermeiro, Sílvio Mariano, and Maria do Rosário Calado. Particle swarm optimization for photovoltaic model identification. In *2017 International Young Engineers Forum (YEF-ECE)*, pages 53–58. IEEE, 2017.
- [13] Rabah Benkercha, Samir Moulahoum, Ilhami Colak, and Bilal Taghezouit. Pv module parameters extraction with maximum power point estimation based on flower pollination algorithm. In *2016 IEEE International Power Electronics and Motion Control Conference (PEMC)*, pages 442–449. IEEE, 2016.
- [14] MR AlRashidi, MF AlHajri, KM El-Naggar, and AK Al-Othman. A new estimation approach for determining the i–v characteristics of solar cells. *Solar Energy*, 85(7):1543–1550, 2011.

- [15] N Rajasekar, Neeraja Krishna Kumar, and Rini Venugopalan. Bacterial foraging algorithm based solar pv parameter estimation. *Solar Energy*, 97:255–265, 2013.
- [16] Alireza Askarzadeh and Alireza Rezaadeh. Artificial bee swarm optimization algorithm for parameters identification of solar cell models. *Applied Energy*, 102:943–949, 2013.

CAPÍTULO 1

- [1] Ali Q Al-Shetwi, Muhamad Zahim Sujod, and Frede Blaabjerg. Low voltage ride-through capability control for single-stage inverter-based grid-connected photovoltaic power plant. *Solar energy*, 159:665–681, 2018.
- [2] Albert Polman, Mark Knight, Erik C Garnett, Bruno Ehrler, and Wim C Sinke. Photovoltaic materials: Present efficiencies and future challenges. *Science*, 352(6283):aad4424, 2016.
- [3] Nikola L Georgijevic, Marko V Jankovic, Srdjan Srdic, and Zoran Radakovic. The detection of series arc fault in photovoltaic systems based on the arc current entropy. *IEEE Transactions on Power Electronics*, 31(8):5917–5930, 2016.
- [4] Juan David Bastidas-Rodriguez, Giovanni Petrone, Carlos Andrés Ramos-Paja, and Giovanni Spagnuolo. A genetic algorithm for identifying the single diode model parameters of a photovoltaic panel. *Mathematics and Computers in Simulation*, 131:38–54, 2017.
- [5] Nuri Gokmen, Engin Karatepe, Santiago Silvestre, Berk Celik, and Pablo Ortega. An efficient fault diagnosis method for pv systems based on operating voltage-window. *Energy conversion and management*, 73:350–360, 2013.
- [6] Nuri Gokmen, Engin Karatepe, Berk Celik, and Santiago Silvestre. Simple diagnostic approach for determining of faulted pv modules in string based pv arrays. *Solar Energy*, 86(11):3364–3377, 2012.
- [7] Martin A Green, Ewan D Dunlop, Dean H Levi, Jochen Hohl-Ebinger, Masahiro Yoshita, and Anita WY Ho-Baillie. Solar cell efficiency tables (version 54). *Progress in Photovoltaics: Research and Applications*, 27(7):565–575, 2019.
- [8] Shah Arifur Rahman, Rajiv K Varma, and Tim Vanderheide. Generalised model of a photovoltaic panel. *IET Renewable Power Generation*, 8(3):217–229, 2014.
- [9] Kashif Ishaque, Zainal Salam, Saad Mekhilef, and Amir Shamsudin. Parameter extraction of solar photovoltaic modules using penalty-based differential evolution. *Applied Energy*, 99:297–308, 2012.
- [10] Sabir Messalti, Abdelghani Harrag, and Abdelhamid Loukriz. A new variable step size neural networks mppt controller: Review, simulation and hardware implementation. *Renewable and Sustainable Energy Reviews*, 68:221–233, 2017.
- [11] Marcelo Gradella Villalva, Jonas Rafael Gazoli, and Ernesto Ruppert Filho. Comprehensive approach to modeling and simulation of photovoltaic arrays. *IEEE Transactions on power electronics*, 24(5):1198–1208, 2009.
- [12] Dominique Bonkoungou, Zacharie Koalaga, and Donatien Njomo. Modelling and simulation of photovoltaic module considering single-diode equivalent circuit model in matlab. *International Journal of Emerging Technology and Advanced Engineering*, 3(3):493–502, 2013.
- [13] Simon Lineykin, Moshe Averbukh, and Alon Kuperman. Five-parameter model of photovoltaic cell based on stc data and dimensionless. In *2012 IEEE 27th Convention of Electrical and Electronics Engineers in Israel*, pages 1–5. IEEE, 2012.
- [14] J Prasanth Ram, T Sudhakar Babu, and N Rajasekar. A comprehensive review on solar pv maximum power point tracking techniques. *Renewable and Sustainable Energy Reviews*, 67:826–847, 2017.

- [15] Sourov Roy, Mohammed Khorshed Alam, Faisal Khan, Jay Johnson, and Jack Flicker. An irradiance-independent, robust ground-fault detection scheme for pv arrays based on spread spectrum time-domain reflectometry (ssdr). *IEEE Transactions on Power Electronics*, 33(8):7046–7057, 2018.
- [16] Charles R Sullivan, Jonathan J Awerbuch, and Alexander M Latham. Decrease in photovoltaic power output from ripple: Simple general calculation and the effect of partial shading. *IEEE Transactions on Power Electronics*, 28(2):740–747, 2013.
- [17] J Accarino, G Petrone, CA Ramos-Paja, and G Spagnuolo. Symbolic algebra for the calculation of the series and parallel resistances in pv module model. In *2013 International Conference on Clean Electrical Power (ICCEP)*, pages 62–66. IEEE, 2013.
- [18] Kashif Ishaque, Zainal Salam, and Hamed Taheri. Accurate matlab simulink pv system simulator based on a two-diode model. *Journal of Power Electronics*, 11(2):179–187, 2011.
- [19] Kashif Ishaque and Zainal Salam. An improved modeling method to determine the model parameters of photovoltaic (pv) modules using differential evolution (de). *Solar energy*, 85(9):2349–2359, 2011.
- [20] Kashif Ishaque, Zainal Salam, et al. A comprehensive matlab simulink pv system simulator with partial shading capability based on two-diode model. *Solar energy*, 85(9):2217–2227, 2011.
- [21] Makbul AM Ramli, Ssennoga Twaha, Kashif Ishaque, and Yusuf A Al-Turki. A review on maximum power point tracking for photovoltaic systems with and without shading conditions. *Renewable and Sustainable Energy Reviews*, 67:144–159, 2017.
- [22] Vun Jack Chin, Zainal Salam, and Kashif Ishaque. An accurate and fast computational algorithm for the two-diode model of pv module based on a hybrid method. *IEEE transactions on Industrial Electronics*, 64(8):6212–6222, 2017.
- [23] Jieming Ma. *Optimization approaches for parameter estimation and maximum power point tracking (MPPT) of photovoltaic systems*. PhD thesis, University of Liverpool, 2014.
- [24] Robert M Corless, Gaston H Gonnet, David EG Hare, David J Jeffrey, and Donald E Knuth. On the lambertw function. *Advances in Computational mathematics*, 5(1):329–359, 1996.
- [25] Sever S Dragomir, Pietro Cerone, and Anthony Sofo. Some remarks on the trapezoid rule in numerical integration. *RGMA research report collection*, 2(5), 1999.
- [26] MATLAB. Matlab: Integración numérica trapezoidal.
- [27] Andrés Tobón, Julián Peláez-Restrepo, Jhon Montano, Mariana Durango, Jorge Herrera, and Asier Ibeas. Mpppt of a photovoltaic panels array with partial shading using the ipsm with implementation both in simulation as in hardware. *Energies*, 13(4):815, 2020.

CAPÍTULO 2

- [1] B Chitti Babu and Suresh Gurjar. A novel simplified two-diode model of photovoltaic (pv) module. *IEEE journal of photovoltaics*, 4(4):1156–1161, 2014.
- [2] Vivek Tamrakar, SC Gupta, and Yashwant Sawle. Single-diode and two-diode pv cell modeling using matlab for studying characteristics of solar cell under varying conditions. *Electrical & Computer Engineering: An International Journal (ECIJ)*, 4(2):67–77, 2015.
- [3] Kashif Ishaque, Zainal Salam, et al. A comprehensive matlab simulink pv system simulator with partial shading capability based on two-diode model. *Solar energy*, 85(9):2217–2227, 2011.
- [4] JC Sánchez Barroso, JPM Correia, N Barth, S Ahzi, and MA Khaleel. A pso algorithm for the calculation of the series and shunt resistances of the pv panel one-diode model. In *2014 International Renewable and Sustainable Energy Conference (IRSEC)*, pages 1–6. IEEE, 2014.

- [5] Kashif Ishaque, Zainal Salam, Saad Mekhilef, and Amir Shamsudin. Parameter extraction of solar photovoltaic modules using penalty-based differential evolution. *Applied Energy*, 99:297–308, 2012.
- [6] Dhiaa Halboot Muhsen, Abu Bakar Ghazali, Tamer Khatib, and Issa Ahmed Abed. A comparative study of evolutionary algorithms and adapting control parameters for estimating the parameters of a single-diode photovoltaic module's model. *Renewable energy*, 96:377–389, 2016.
- [7] A Rezaee Jordehi. Parameter estimation of solar photovoltaic (pv) cells: A review. *Renewable and Sustainable Energy Reviews*, 61:354–371, 2016.
- [8] Rituraj Tamrakar and Archana Gupta. A review: extraction of solar cell modelling parameters. *Int. J. Innovative Res. Electr., Electron., Instrum. Control Eng*, 3(1):55–60, 2015.
- [9] I Nassar-Eddine, A Obbadi, Y Errami, M Agunaou, et al. Parameter estimation of photovoltaic modules using iterative method and the lambert w function: A comparative study. *Energy Conversion and Management*, 119:37–48, 2016.
- [10] L Sandrolini, M Artioli, and U Reggiani. Numerical method for the extraction of photovoltaic module double-diode model parameters through cluster analysis. *Applied Energy*, 87(2):442–451, 2010.
- [11] Jieming Ma, TO Ting, Ka Lok Man, Nan Zhang, Sheng-Uei Guan, and Prudence WH Wong. Parameter estimation of photovoltaic models via cuckoo search. *Journal of applied mathematics*, 2013, 2013.
- [12] Noureddine Maouhoub. Photovoltaic module parameter estimation using an analytical approach and least squares method. *Journal of Computational Electronics*, 17(2):784–790, 2018.
- [13] Giuseppina Ciulla, Valerio Lo Brano, Vincenzo Di Dio, and Giovanni Cipriani. A comparison of different one-diode models for the representation of i–v characteristic of a pv cell. *Renewable and Sustainable Energy Reviews*, 32:684–696, 2014.
- [14] Hugo Nunes, José Pombo, João Fermeiro, Sílvio Mariano, and Maria do Rosário Calado. Particle swarm optimization for photovoltaic model identification. In *2017 International Young Engineers Forum (YEF-ECE)*, pages 53–58. IEEE, 2017.
- [15] Rabah Benkercha, Samir Moulahoum, Ilhami Colak, and Bilal Taghezouit. Pv module parameters extraction with maximum power point estimation based on flower pollination algorithm. In *2016 IEEE International Power Electronics and Motion Control Conference (PEMC)*, pages 442–449. IEEE, 2016.
- [16] Giovanni Petrone, Carlos Andrés Ramos-Paja, and Giovanni Spagnuolo. *Photovoltaic sources modeling*. John Wiley & Sons, 2017.
- [17] Ahmed A El Tayyan. An approach to extract the parameters of solar cells from their illuminated iv curves using the lambert w function. *Turkish Journal of Physics*, 39(1):1–15, 2015.
- [18] Vun Jack Chin, Zainal Salam, and Kashif Ishaque. Cell modelling and model parameters estimation techniques for photovoltaic simulator application: A review. *Applied Energy*, 154:500–519, 2015.
- [19] MR AlRashidi, MF AlHajri, KM El-Naggar, and AK Al-Othman. A new estimation approach for determining the i–v characteristics of solar cells. *Solar Energy*, 85(7):1543–1550, 2011.
- [20] N Rajasekar, Neeraja Krishna Kumar, and Rini Venugopalan. Bacterial foraging algorithm based solar pv parameter estimation. *Solar Energy*, 97:255–265, 2013.
- [21] Alireza Askarzadeh and Alireza Rezazadeh. Artificial bee swarm optimization algorithm for parameters identification of solar cell models. *Applied Energy*, 102:943–949, 2013.
- [22] MF AlHajri, KM El-Naggar, MR AlRashidi, and AK Al-Othman. Optimal extraction of solar cell parameters using pattern search. *Renewable Energy*, 44:238–245, 2012.

- [23] Lian Lian Jiang, Douglas L Maskell, and Jagdish C Patra. Parameter estimation of solar cells and modules using an improved adaptive differential evolution algorithm. *Applied Energy*, 112:185–193, 2013.
- [24] Diego Oliva, Mohamed Abd El Aziz, and Aboul Ella Hassanien. Parameter estimation of photovoltaic cells using an improved chaotic whale optimization algorithm. *Applied Energy*, 200:141–154, 2017.
- [25] Jieming Ma. *Optimization approaches for parameter estimation and maximum power point tracking (MPPT) of photovoltaic systems*. PhD thesis, University of Liverpool, 2014.
- [26] Zhicong Chen, Lijun Wu, Peijie Lin, Yue Wu, and Shuying Cheng. Parameters identification of photovoltaic models using hybrid adaptive nelder-mead simplex algorithm based on eagle strategy. *Applied Energy*, 182:47–57, 2016.
- [27] Wenyin Gong and Zhihua Cai. Parameter extraction of solar cell models using repaired adaptive differential evolution. *Solar Energy*, 94:209–220, 2013.
- [28] O Hachana, KE Hemsas, GM Tina, and C Ventura. Comparison of different metaheuristic algorithms for parameter identification of photovoltaic cell/module. *Journal of renewable and sustainable energy*, 5(5):053122, 2013.
- [29] Yiqun Zhang, Peijie Lin, Zhicong Chen, and Shuying Cheng. A population classification evolution algorithm for the parameter extraction of solar cell models. *International Journal of Photoenergy*, 2016, 2016.
- [30] Rituraj Tamrakar and Archana Gupta. Extraction of solar cell modelling parameters using differential evolution algorithm. *Int. J. Innov. Res. Elec., Electron., Instrument. Contr. Engineering*, 3(11), 2015.
- [31] Yourim Yoon and Zong Woo Geem. Parameter optimization of single-diode model of photovoltaic cell using memetic algorithm. *International Journal of Photoenergy*, 2015, 2015.
- [32] Jeisson Vélez-Sánchez, Juan David Bastidas-Rodríguez, Carlos Andrés Ramos-Paja, Daniel González Montoya, and Luz Adriana Trejos-Grisales. A non-invasive procedure for estimating the exponential model parameters of bypass diodes in photovoltaic modules. *Energies*, 12(2):303, 2019.
- [33] J Accarino, G Petrone, CA Ramos-Paja, and G Spagnuolo. Symbolic algebra for the calculation of the series and parallel resistances in pv module model. In *2013 International Conference on Clean Electrical Power (ICCEP)*, pages 62–66. IEEE, 2013.
- [34] Omnia S Elazab, Hany M Hasanien, Ibrahim Alsaïdan, Almoataz Y Abdelaziz, and SM Muyeen. Parameter estimation of three diode photovoltaic model using grasshopper optimization algorithm. *Energies*, 13(2):497, 2020.
- [35] Mohamed A Awadallah and Bala Venkatesh. Optimisation-based parameter estimation of photovoltaic modules. *International Journal of Industrial Electronics and Drives*, 4(1):33–43, 2018.
- [36] Vandana Khanna, BK Das, Dinesh Bisht, PK Singh, et al. A three diode model for industrial solar cells and estimation of solar cell parameters using pso algorithm. *Renewable Energy*, 78:105–113, 2015.
- [37] Humberto Barreto and Frank Howland. *Introductory econometrics: using Monte Carlo simulation with Microsoft excel*. Cambridge University Press, 2006.
- [38] Mohamed A Awadallah and Bala Venkatesh. Estimation of pv module parameters from datasheet information using optimization techniques. In *2015 IEEE International Conference on Industrial Technology (ICIT)*, pages 2777–2782. IEEE, 2015.
- [39] M Ulaganathan and D Devaraj. Real coded genetic algorithm for optimal parameter estimation of solar photovoltaic model. In *2016 International Conference on Emerging Trends in Engineering, Technology and Science (ICETETS)*, pages 1–6. IEEE, 2016.

- [40] Kashif Ishaque and Zainal Salam. An improved modeling method to determine the model parameters of photovoltaic (pv) modules using differential evolution (de). *Solar energy*, 85(9):2349–2359, 2011.
- [41] Huang Wei, Jiang Cong, Xue Lingyun, and Song Deyun. Extracting solar cell model parameters based on chaos particle swarm algorithm. In *2011 International conference on electric information and control engineering*, pages 398–402. IEEE, 2011.
- [42] Mahmoud S Ismail, Mahmoud Moghavvemi, and TMI Mahlia. Characterization of pv panel and global optimization of its model parameters using genetic algorithm. *Energy Conversion and Management*, 73:10–25, 2013.
- [43] Sanjaykumar J Patel, Ashish K Panchal, and Vipul Kheraj. Extraction of solar cell parameters from a single current–voltage characteristic using teaching learning based optimization algorithm. *Applied energy*, 119:384–393, 2014.
- [44] Khaled M El-Naggar, MR AlRashidi, MF AlHajri, and AK Al-Othman. Simulated annealing algorithm for photovoltaic parameters identification. *Solar Energy*, 86(1):266–274, 2012.
- [45] C Saha, N Agbu, and R Jinks. Review article of the solar pv parameters estimation using evolutionary algorithms. *MOJ Solar Photoen Sys*, 2(2):66–78, 2018.
- [46] Mohamed Louzazni, Aurelian Crăciunescu, Alexandru Dumitrache, et al. Identification of solar cell parameters with firefly algorithm. In *2015 Second International Conference on Mathematics and Computers in Sciences and in Industry (MCSI)*, pages 7–12. IEEE, 2015.
- [47] Fayrouz Dkhichi, Benyounes Oukarfi, Abderrahim Fakkar, and Noureddine Belbounaguia. Parameter identification of solar cell model using levenberg–marquardt algorithm combined with simulated annealing. *Solar energy*, 110:781–788, 2014.
- [48] Rongjie Wang, Yiju Zhan, and Haifeng Zhou. Application of artificial bee colony in model parameter identification of solar cells. *Energies*, 8(8):7563–7581, 2015.
- [49] Hany M Hasanien. Shuffled frog leaping algorithm for photovoltaic model identification. *IEEE Transactions on Sustainable Energy*, 6(2):509–515, 2015.
- [50] Arash M Dizqah, Alireza Maheri, and Krishna Busawon. An accurate method for the pv model identification based on a genetic algorithm and the interior-point method. *Renewable energy*, 72:212–222, 2014.
- [51] Nuri Gokmen, Engin Karatepe, Berk Celik, and Santiago Silvestre. Simple diagnostic approach for determining of faulted pv modules in string based pv arrays. *Solar Energy*, 86(11):3364–3377, 2012.
- [52] Shah Arifur Rahman, Rajiv K Varma, and Tim Vanderheide. Generalised model of a photovoltaic panel. *IET Renewable Power Generation*, 8(3):217–229, 2014.
- [53] Simon Lineykin, Moshe Averbukh, and Alon Kuperman. Five-parameter model of photovoltaic cell based on stc data and dimensionless. In *2012 IEEE 27th Convention of Electrical and Electronics Engineers in Israel*, pages 1–5. IEEE, 2012.
- [54] J Prasanth Ram, T Sudhakar Babu, and N Rajasekar. A comprehensive review on solar pv maximum power point tracking techniques. *Renewable and Sustainable Energy Reviews*, 67:826–847, 2017.
- [55] Sabir Messalti, Abdelghani Harrag, and Abdelhamid Loukriz. A new variable step size neural networks mppt controller: Review, simulation and hardware implementation. *Renewable and Sustainable Energy Reviews*, 68:221–233, 2017.
- [56] Marcelo Gradella Villalva, Jonas Rafael Gazoli, and Ernesto Ruppert Filho. Comprehensive approach to modeling and simulation of photovoltaic arrays. *IEEE Transactions on power electronics*, 24(5):1198–1208, 2009.

- [57] Dominique Bonkougou, Zacharie Koalaga, and Donatien Njomo. Modelling and simulation of photovoltaic module considering single-diode equivalent circuit model in matlab. *International Journal of Emerging Technology and Advanced Engineering*, 3(3):493–502, 2013.

CAPÍTULO 3

- [1] B Chitti Babu and Suresh Gurjar. A novel simplified two-diode model of photovoltaic (pv) module. *IEEE journal of photovoltaics*, 4(4):1156–1161, 2014.
- [2] Vivek Tamrakar, SC Gupta, and Yashwant Sawle. Single-diode and two-diode pv cell modeling using matlab for studying characteristics of solar cell under varying conditions. *Electrical & Computer Engineering: An International Journal (ECIJ)*, 4(2):67–77, 2015.
- [3] Kashif Ishaque, Zainal Salam, et al. A comprehensive matlab simulink pv system simulator with partial shading capability based on two-diode model. *Solar energy*, 85(9):2217–2227, 2011.
- [4] JC Sánchez Barroso, JPM Correia, N Barth, S Ahzi, and MA Khaleel. A pso algorithm for the calculation of the series and shunt resistances of the pv panel one-diode model. In *2014 International Renewable and Sustainable Energy Conference (IRSEC)*, pages 1–6. IEEE, 2014.
- [5] Jieming Ma, TO Ting, Ka Lok Man, Nan Zhang, Sheng-Uei Guan, and Prudence WH Wong. Parameter estimation of photovoltaic models via cuckoo search. *Journal of applied mathematics*, 2013, 2013.
- [6] Noureddine Maouhoub. Photovoltaic module parameter estimation using an analytical approach and least squares method. *Journal of Computational Electronics*, 17(2):784–790, 2018.
- [7] Giuseppina Ciulla, Valerio Lo Brano, Vincenzo Di Dio, and Giovanni Cipriani. A comparison of different one-diode models for the representation of i–v characteristic of a pv cell. *Renewable and Sustainable Energy Reviews*, 32:684–696, 2014.
- [8] Hugo Nunes, José Pombo, João Fermeiro, Sílvio Mariano, and Maria do Rosário Calado. Particle swarm optimization for photovoltaic model identification. In *2017 International Young Engineers Forum (YEF-ECE)*, pages 53–58. IEEE, 2017.
- [9] Rabah Benkercha, Samir Moulahoum, Ilhami Colak, and Bilal Taghezouit. Pv module parameters extraction with maximum power point estimation based on flower pollination algorithm. In *2016 IEEE International Power Electronics and Motion Control Conference (PEMC)*, pages 442–449. IEEE, 2016.
- [10] Giovanni Petrone, Carlos Andrés Ramos-Paja, and Giovanni Spagnuolo. *Photovoltaic sources modeling*. John Wiley & Sons, 2017.
- [11] Ahmed A El Tayyan. An approach to extract the parameters of solar cells from their illuminated iv curves using the lambert w function. *Turkish Journal of Physics*, 39(1):1–15, 2015.
- [12] Vun Jack Chin, Zainal Salam, and Kashif Ishaque. Cell modelling and model parameters estimation techniques for photovoltaic simulator application: A review. *Applied Energy*, 154:500–519, 2015.
- [13] J Accarino, G Petrone, CA Ramos-Paja, and G Spagnuolo. Symbolic algebra for the calculation of the series and parallel resistances in pv module model. In *2013 International Conference on Clean Electrical Power (ICCEP)*, pages 62–66. IEEE, 2013.
- [14] Maurice Clerc. *Particle swarm optimization*, volume 93. John Wiley & Sons, 2010.
- [15] Simon Lineykin, Moshe Averbukh, and Alon Kuperman. Five-parameter model of photovoltaic cell based on stc data and dimensionless. In *2012 IEEE 27th Convention of Electrical and Electronics Engineers in Israel*, pages 1–5. IEEE, 2012.

- [16] Shahrzad Saremi, Seyedali Mirjalili, and Andrew Lewis. Grasshopper optimisation algorithm: theory and application. *Advances in Engineering Software*, 105:30–47, 2017.
- [17] Luis Fernando Grisales-Noreña, Daniel Gonzalez Montoya, and Carlos Andres Ramos-Paja. Optimal sizing and location of distributed generators based on pbil and pso techniques. *Energies*, 11(4):1018, 2018.
- [18] Miguel Galante. Un algoritmo genético simple para la optimización de estructuras planas articuladas. 1993.
- [19] PC Chu and JE Beasley. A genetic algorithm for the set partitioning problem. *Imperial College, London*, 1995.
- [20] OD Montoya, W Gil-González, and LF Grisales-Noreña. Optimal power dispatch of dgs in dc power grids: a hybrid gauss-seidel genetic-algorithm methodology for solving the opf problem. *WSEAS Transactions on Power Systems*, 13(33):335–346, 2018.
- [21] Simone SF Souza, Ruben Romero, Jorge Pereira, and João Tomé Saraiva. Specialized genetic algorithm of chu-beasley applied to the distribution system reconfiguration problem considering several demand scenarios. In *2015 IEEE Eindhoven PowerTech*, pages 1–5. Ieee, 2015.
- [22] Vandana Khanna, BK Das, Dinesh Bisht, PK Singh, et al. Estimation of photovoltaic cells model parameters using particle swarm optimization. In *Physics of Semiconductor Devices*, pages 391–394. Springer, 2014.

CAPÍTULO 4

- [1] Joel Krueger and Duncan Smith. A practical approach to fire hazard analysis for offshore structures. *Journal of hazardous materials*, 104(1-3):107–122, 2003.
- [2] Hiba Al-Sheikh and Nazih Moubayed. Fault detection and diagnosis of renewable energy systems: An overview. In *2012 International Conference on Renewable Energies for Developing Countries (REDEC)*, pages 1–7. IEEE, 2012.
- [3] Gary D Hasenfus. Smart sensors for solar panels, October 23 2012. US Patent 8,294,451.
- [4] Moath Alsafasfeh, Ikhlas Abdel-Qader, Bradley Bazuin, Qais Alsafasfeh, and Wencong Su. Unsupervised fault detection and analysis for large photovoltaic systems using drones and machine vision. *Energies*, 11(9):2252, 2018.
- [5] Mahmoud Dhimish and Ghadeer Badran. Photovoltaic hot-spots fault detection algorithm using fuzzy systems. *IEEE Transactions on Device and Materials Reliability*, 19(4):671–679, 2019.
- [6] Elyes Garoudja, Fouzi Harrou, Ying Sun, Kamel Kara, Aissa Chouder, and Santiago Silvestre. Statistical fault detection in photovoltaic systems. *Solar Energy*, 150:485–499, 2017.
- [7] Emma Pedersen, Sunil Rao, Sameeksha Katoch, Kristen Jaskie, Andreas Spanias, Cihan Tepedelenlioglu, and Elias Kyriakides. Pv array fault detection using radial basis networks. In *2019 10th International Conference on Information, Intelligence, Systems and Applications (IISA)*, pages 1–4. IEEE, 2019.
- [8] C Birk Jones, Joshua S Stein, Sigifredo Gonzalez, and Bruce H King. Photovoltaic system fault detection and diagnostics using laterally primed adaptive resonance theory neural network. In *2015 IEEE 42nd Photovoltaic Specialist Conference (PVSC)*, pages 1–6. IEEE, 2015.
- [9] AH Mohamed and AM Nassar. New algorithm for fault diagnosis of photovoltaic energy systems. *International Journal of Computer Applications*, 114(9), 2015.
- [10] Zahi M Omer, Abbas A Fardoun, and Ala Hussain. Large scale photovoltaic array fault diagnosis for optimized solar cell parameters extracted by heuristic evolutionary algorithm. In *2016 Ieee Power And Energy Society General Meeting (pesgm)*, pages 1–5. IEEE, 2016.

- [11] Dezso Sera. Series resistance monitoring for photovoltaic modules in the vicinity of mpp. In *25th European photovoltaic solar energy conference and exhibition*, pages 4506–4510, 2010.
- [12] Mohamed Hassan Ali, Abdelhamid Rabhi, Ahmed El Hajjaji, and Giuseppe M Tina. Real time fault detection in photovoltaic systems. *Energy Procedia*, 111:914–923, 2017.
- [13] Juan David Bastidas-Rodríguez, Edinson Franco, Giovanni Petrone, Carlos Andrés Ramos-Paja, and Giovanni Spagnuolo. Model-based degradation analysis of photovoltaic modules through series resistance estimation. *IEEE Transactions on Industrial Electronics*, 62(11):7256–7265, 2015.
- [14] Michael G Deceglie, Matthew Muller, Dirk C Jordan, and Chris Deline. Numerical validation of an algorithm for combined soiling and degradation analysis of photovoltaic systems. In *2019 IEEE 46th Photovoltaic Specialists Conference (PVSC)*, pages 3111–3114. IEEE, 2019.
- [15] YH Chen, R Liang, Y Tian, and F Wang. A novel fault diagnosis method of pv based-on power loss and iv characteristics. In *IOP Conference Series: Earth and Environmental Science*, volume 40, page 012022. IOP Publishing, 2016.
- [16] Zhicong Chen, Fuchang Han, Lijun Wu, Jinling Yu, Shuying Cheng, Peijie Lin, and Huihuang Chen. Random forest based intelligent fault diagnosis for pv arrays using array voltage and string currents. *Energy conversion and management*, 178:250–264, 2018.
- [17] W Chine, A Mellit, Vanni Lughi, A Malek, Giorgio Sulligoi, and A Massi Pavan. A novel fault diagnosis technique for photovoltaic systems based on artificial neural networks. *Renewable Energy*, 90:501–512, 2016.
- [18] Zhicong Chen, Lijun Wu, Shuying Cheng, Peijie Lin, Yue Wu, and Wencheng Lin. Intelligent fault diagnosis of photovoltaic arrays based on optimized kernel extreme learning machine and iv characteristics. *Applied Energy*, 204:912–931, 2017.
- [19] Peijie Lin, Yaohai Lin, Zhicong Chen, Lijun Wu, Lingchen Chen, and Shuying Cheng. A density peak-based clustering approach for fault diagnosis of photovoltaic arrays. *International Journal of Photoenergy*, 2017, 2017.
- [20] Honglu Zhu, Lingxing Lu, Jianxi Yao, Songyuan Dai, and Yang Hu. Fault diagnosis approach for photovoltaic arrays based on unsupervised sample clustering and probabilistic neural network model. *Solar Energy*, 176:395–405, 2018.
- [21] Shengyang Liu, Lei Dong, Xiaozhong Liao, Ying Hao, Xiaodong Cao, and Xiaoxiao Wang. A dilation and erosion-based clustering approach for fault diagnosis of photovoltaic arrays. *IEEE Sensors Journal*, 19(11):4123–4137, 2019.
- [22] Ye Zhao, Roy Ball, Jerry Mosesian, Jean-François de Palma, and Brad Lehman. Graph-based semi-supervised learning for fault detection and classification in solar photovoltaic arrays. *IEEE Transactions on Power Electronics*, 30(5):2848–2858, 2014.
- [23] Hosna Momeni, Nasser Sadoogi, Meisam Farrokhifar, and Hamed Farhadi Gharibeh. Fault diagnosis in photovoltaic arrays using gbssl method and proposing a fault correction system. *IEEE Transactions on Industrial Informatics*, 2019.
- [24] Peng Xu, Jin Ming Hou, and Deng Kuo Yuan. Fault diagnosis for building grid-connected photovoltaic system based on analysis of energy loss. In *Advanced Materials Research*, volume 805, pages 93–98. Trans Tech Publ, 2013.
- [25] Jun-Ming Huang, Rong-Jong Wai, and Geng-Jie Yang. Design of hybrid artificial bee colony algorithm and semi-supervised extreme learning machine for pv fault diagnoses by considering dust impact. *IEEE Transactions on Power Electronics*, 2019.