



ESPE

UNIVERSIDAD DE LAS FUERZAS ARMADAS

INNOVACIÓN PARA LA EXCELENCIA

**DEPARTAMENTO DE ELÉCTRICA,
ELECTRÓNICA Y TELECOMUNICACIONES**

**CARRERA DE INGENIERÍA EN ELECTRÓNICA,
AUTOMATIZACIÓN Y CONTROL**

**TRABAJO DE TITULACIÓN, PREVIO A LA OBTENCIÓN DEL TÍTULO
DE INGENIERO EN ELECTRÓNICA, AUTOMATIZACIÓN Y CONTROL**

**TEMA: SINTONIZACIÓN DE LOS PARÁMETROS DE UN
CONTROLADOR FUZZY LOGIC, BASADA EN EL ALGORITMO DE
OPTIMIZACIÓN POR ENJAMBRE DE PARTÍCULAS UTILIZADO EN EL
SISTEMA DE GESTIÓN ENERGÉTICA DE UNA MICRORRED
ELECTROTÉRMICA.**

AUTOR: PACHECO GUEVARA, DIEGO RICARDO

DIRECTOR: ING. ARCOS AVILÉS, DIEGO GUSTAVO, Ph.D.

SANGOLQUÍ

2019



**DEPARTAMENTO DE ELÉCTRICA, ELÉCTRONICA Y
TELECOMUNICACIONES**

**CARRERA DE INGENIERÍA EN ELECTRÓNICA,
AUTOMATIZACIÓN Y CONTROL**

CERTIFICACIÓN

Certifico que el trabajo de titulación, **“SINTONIZACIÓN DE LOS PARÁMETROS DE UN CONTROLADOR FUZZY LOGIC, BASADA EN EL ALGORITMO DE OPTIMIZACIÓN POR ENJAMBRE DE PARTÍCULAS UTILIZADO EN EL SISTEMA DE GESTIÓN ENERGÉTICA DE UNA MICRORRED ELECTROTÉRMICA”** fue realizado por el señor Pacheco Guevara, Diego Ricardo el mismo que ha sido revisado en su totalidad, analizado por la herramienta de verificación de similitud de contenido; por lo tanto cumple con los requisitos teóricos, científicos, técnicos, metodológicos y legales establecidos por la Universidad de Fuerzas Armadas ESPE, razón por la cual me permito acreditar y autorizar para que lo sustente públicamente.

Sangolquí, 29 de noviembre del 2019

Firma:

Diego Gustavo Arcos Avilés, Ph.D.

C.C.: 171087944-4



**DEPARTAMENTO DE ELÉCTRICA, ELÉCTRONICA Y
TELECOMUNICACIONES**

**CARRERA DE INGENIERÍA EN ELECTRÓNICA,
AUTOMATIZACIÓN Y CONTROL**

AUTORÍA DE RESPONSABILIDAD

Yo, **Pacheco Guevara, Diego Ricardo**, declaro que el contenido, ideas y criterios del trabajo de titulación: **"SINTONIZACIÓN DE LOS PARÁMETROS DE UN CONTROLADOR FUZZY LOGIC, BASADA EN EL ALGORITMO DE OPTIMIZACIÓN POR ENJAMBRE DE PARTÍCULAS UTILIZADO EN EL SISTEMA DE GESTIÓN ENERGÉTICA DE UNA MICRORRED ELECTROTÉRMICA"** es de mi autoría y responsabilidad, cumpliendo con los requisitos teóricos, científicos, técnicos, metodológicos y legales establecidos por la Universidad de Fuerzas Armadas ESPE, respetando los derechos intelectuales de terceros y referenciando las citas bibliográficas.

Consecuentemente el contenido de la investigación mencionada es veraz.

Sangolquí, 29 de noviembre del 2019

Firma:



Pacheco Guevara, Diego Ricardo

C.C.: 172700718-7



**DEPARTAMENTO DE ELÉCTRICA, ELÉCTRONICA Y
TELECOMUNICACIONES**

**CARRERA DE INGENIERÍA EN ELECTRÓNICA,
AUTOMATIZACIÓN Y CONTROL**

AUTORIZACIÓN

Yo, Pacheco Guevara, Diego Ricardo, autorizo a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de titulación: **“SINTONIZACIÓN DE LOS PARÁMETROS DE UN CONTROLADOR FUZZY LOGIC, BASADA EN EL ALGORITMO DE OPTIMIZACIÓN POR ENJAMBRE DE PARTÍCULAS UTILIZADO EN EL SISTEMA DE GESTIÓN ENERGÉTICA DE UNA MICRORRED ELECTROTÉRMICA”** en el Repositorio Institucional, cuyo contenido, ideas y criterios son de mi responsabilidad.

Sangolquí, 29 de noviembre del 2019

Firma:

Pacheco Guevara, Diego Ricardo

C.C.: 172700718-7

DEDICATORIA

A la memoria de mi padre Rubén (QEPD), quien siempre me apoyo y ha sido la fuente de inspiración en mi vida. A mi madre Susana quien ha sabido superar todos los obstáculos de la vida, manteniendo su incansable lucha para sacar adelante a nuestra familia.

A mis hermanos Adriana y Andrés por su confianza, cariño y amistad a través de los años, a pesar de las peleas siempre estaremos juntos.

Diego Ricardo Pacheco Guevara

AGRADECIMIENTO

A mi familia por su aporte constante de amor, confianza, apoyo, valores y sabiduría brindados a lo largo de toda mi vida.

A Verónica, por todo el amor y confianza ofrecido en los buenos y malos momentos de los últimos años.

A mis amigos, profesores y compañeros de universidad, quienes han aportado para que esta experiencia sea sumamente grata.

A mi tutor Diego Arcos Avilés, Ph.D. por su aporte de inspiración, y confianza para la elaboración del presente trabajo.

A todos ustedes, muchas gracias

Diego Ricardo Pacheco Guevara

ÍNDICE DE CONTENIDOS

CERTIFICACIÓN	i
AUTORÍA DE RESPONSABILIDAD	ii
AUTORIZACIÓN	iii
DEDICATORIA	iv
AGRADECIMIENTO	v
ÍNDICE DE CONTENIDOS	vi
ÍNDICE DE TABLAS	ix
ÍNDICE DE FIGURAS	x
RESUMEN	x
ABSTRACT	xiii
CAPITULO I:	1
1.1 Antecedentes	1
1.2 Justificación e Importancia	4
1.3 Alcance del proyecto	8
1.4 Objetivos	9
1.4.1 Objetivo General	9
1.4.2 Objetivos Específicos	9
CAPÍTULO II	10
2.1 Lógica difusa	10
2.1.1 Conjunto difuso	10
2.1.2 Predicado difuso	10
2.2 Controladores fuzzy logic	11
2.2.1 Componentes del controlador fuzzy logic	11
2.3 Ajuste de Parámetros del Controlador Fuzzy Logic	12
2.3.1 Universo de Discurso	13
2.3.2 Funciones de Pertenencia	13
2.3.3 Base de reglas	14
2.4 Optimización multiobjetivo	15

2.5 Método de la suma ponderada	16
2.5.1 Inicialización de la población	16
2.5.2 Algoritmos heurísticos y metaheurísticos	17
2.5.3 Algoritmos inspirados en la naturaleza.....	18
2.6 Optimización por enjambre de partículas	18
2.6.1 Aplicaciones de la optimización por enjambre de partículas.....	19
2.6.2 Parámetros del PSO	20
2.6.2.1 Espacio de búsqueda	20
2.6.2.2 Velocidad de las partículas.....	20
2.6.2.3 Posición de las partículas	21
2.6.2.4 Memoria individual y colectiva.....	21
2.6.2.5 Parámetros de aceleración estocásticos	21
2.6.2.6 Constantes de aceleración	21
2.6.2.7 Búsqueda multi-dimensional.....	22
2.6.2.8 Peso de inercia.....	22
2.6.2.9 Factor de constricción	23
2.6.2.10 Dimensiones de vectores del PSO.....	24
2.6.2.11 Pseudocódigo y diagrama de flujo del PSO	24
2.7 Sistemas de Gestión Energética.....	26
CAPITULO III:	27
4.1 Descripción del caso de estudio.....	27
4.2 Sistema de Gestión Energética del caso de estudio	28
4.3 Controlador Fuzzy Logic del EMS.....	29
4.4 Criterios de Calidad	29
4.5 Función de costo del problema de optimización	30
4.6 Diseño del algoritmo de optimización por enjambre de partículas	31
4.6.1 Población Inicial	32
4.6.1.1 Población del error de predicción.....	32
4.6.1.2 Población del estado de carga de la batería.....	33
4.6.1.3 Población de la potencia del controlador	34

4.6.1.4 Población de la Base de Reglas	35
4.6.2 Parámetros de Ajuste del PSO	36
4.6.3 Limitaciones de Velocidad	36
4.6.4 Pseudocódigo y diagrama de flujo del PSO implementado.....	37
CAPITULO IV:	39
5.1 Simulaciones numéricas.	39
5.2 Variación de parámetros PSO.....	39
5.2.1 Tiempo de procesamiento.	41
5.2.2 Tiempo de convergencia.	41
5.3 Comparativa de funciones de pertenencia de las entradas del FLC	42
5.3.1 Comparativa del error de predicción.....	42
5.3.2 Comparativa del estado de carga de la batería.....	45
5.4 Comparación de las funciones de pertenencia de la salida del FLC.	46
5.5 Comparación de la Base de Reglas.....	49
5.6 Evaluación de los parámetros de Calidad.....	50
CAPITULO V:	58
7.1 Conclusiones.....	58
7.2 Recomendaciones	59
7.3 Reconocimientos	60
BIBLIOGRAFÍA	61

ÍNDICE DE TABLAS

Tabla 1 <i>Resumen de la configuración de las constantes de aceleración del PSO</i>	22
Tabla 2 <i>Dimensiones de los vectores del PSO</i>	24
Tabla 3 <i>Coordenadas de parámetros a optimizar</i>	32
Tabla 4 <i>Posiciones iniciales de funciones de pertenencia del P_E</i>	33
Tabla 5 <i>Posiciones iniciales de funciones de pertenencia del SOC</i>	34
Tabla 6 <i>Posiciones y rango iniciales de funciones de pertenencia de P_{FLC}</i>	35
Tabla 7 <i>Base de Reglas Inicial</i>	36
Tabla 8 <i>Parámetros del PSO</i>	36
Tabla 9 <i>Resumen de la información de ejecución del algoritmo PSO</i>	42
Tabla 10 <i>Comparación de funciones de pertenencia del error de predicción</i>	44
Tabla 11 <i>Comparación de funciones de pertenencia de estado de carga de la batería</i>	46
Tabla 12 <i>Parámetros de MF y rango de la salida del FLC obtenido por métodos heurísticos</i> ...	47
Tabla 13 <i>Parámetros de MF y rango de la salida del FLC obtenido por CSA</i>	48
Tabla 14 <i>Parámetros de MF y rango de la salida del FLC obtenido por PSO</i>	48
Tabla 15 <i>Base de reglas de EMS-FC optimizada por PSO</i>	49
Tabla 16 <i>Base de reglas de EMS-FC optimizada por CSA</i>	49
Tabla 17 <i>Base de reglas de EMS-FC optimizada por algoritmos heurísticos</i>	50
Tabla 18 <i>Comparación de los criterios de calidad de EMS</i>	56
Tabla 19 <i>Variación porcentual de los criterios de calidad de EMS</i>	56
Tabla 20 <i>Tiempo de convergencia del PSO y CSA</i>	57

ÍNDICE DE FIGURAS

Figura 1. Red residencial conectada a una microrred electrotérmica	6
Figura 2. Diagrama de bloques de la estrategia de gestión energética difusa.....	7
Figura 3. Arquitectura del controlador de lógica difuso	12
Figura 4. Tipos de funciones de pertenencia.....	14
Figura 5. Pseudocódigo del algoritmo PSO	24
Figura 6. Diagrama de flujo de algoritmo PSO.....	25
Figura 7. Diagrama de bloques Fuzzy EMS-FC	28
Figura 8. Población inicial de del error de predicción.	33
Figura 9. Población inicial del estado de carga de la batería.	34
Figura 10. Población inicial de la potencia del controlador.....	35
Figura 11. Desplazamiento de nuevas soluciones.....	37
Figura 12. Pseudocódigo del algoritmo PSO implementado población	37
Figura 13. Diagrama de flujo del algoritmo PSO implementado.....	38
Figura 14. Zonas no definidas de funciones de pertenencia	41
Figura 15. Funciones de pertenencia P_E PSO finales vs iniciales.....	43
Figura 16. Funciones de pertenencia P_E PSO vs métodos heurísticos.....	43
Figura 17. Funciones de pertenencia P_E PSO vs CSA	44
Figura 18. Funciones de pertenencia del SOC, PSO final vs inicial.....	45
Figura 19. Funciones de pertenencia del SOC, PSO vs métodos heurísticos	45
Figura 20. Funciones de pertenencia del SOC, PSO vs CSA	46
Figura 21. Funciones de pertenencia de P_{FLC} obtenida por métodos heurísticos.....	47

Figura 22. Funciones de pertenencia de P_{FLC} obtenida por CSA.....	47
Figura 23. Funciones de pertenencia de P_{FLC} obtenida por PSO	48
Figura 24. Comparación SOC de batería PSO vs métodos heurísticos.....	51
Figura 25. Comparación SOC de Batería PSO vs CSA.....	51
Figura 26. Comparación de Rangos de SOC, PSO vs métodos heurísticos.....	52
Figura 27. Comparación de Rangos de SOC, PSO vs CSA.....	52
Figura 28. Comparación de perfiles de potencia intercambiada, PSO vs métodos heurísticos ...	53
Figura 29. Comparación de Rampas de Perfil de Potencia, vs Métodos Heurísticos	53
Figura 30. Acercamiento del perfil de potencia PSO vs métodos heurísticos	54
Figura 31. Comparación de perfiles de potencia intercambiada, PSO vs CSA	54
Figura 32. Comparación de Rampas de Perfil de Potencia, vs CSA.....	55
Figura 33. Acercamiento del perfil de potencia PSO vs CSA	55

RESUMEN

En los últimos años la demanda energética se ha incrementado a nivel mundial producto de los avances tecnológicos, para afrontar este problema nace la iniciativa conocida como las microrredes (MG). Estas son definidas como redes de distribución de bajo voltaje conectadas con la red eléctrica mediante un punto de acople común. Usualmente las microrredes cuentan con sistemas de gestión energética que se encargan de la administración de potencia de cada elemento de generación distribuida que posea una MG, con el objetivo de reducir los costos de facturación, minimizar el perfil de red intercambiado con la red eléctrica, entre otros. Estos sistemas pueden ser más eficientes al agregar controladores no-lineales combinados con algoritmos de optimización para mejorar la sintonización de sus parámetros. El presente documento describe el diseño de un algoritmo de optimización por enjambre de partículas, para la sintonización de los parámetros de un controlador de lógica difusa, con la finalidad de mejorar el desempeño del sistema de gestión energética de una microrred electro-térmica con conexión a la red eléctrica.

PALABRAS CLAVE:

- **OPTIMIZACIÓN POR ENJAMBRE DE PARTÍCULAS**
- **CONTROLADORES DE LÓGICA DIFUSA**
- **MICRORRED**
- **ESTRATEGIA DE GESTIÓN ENERGÉTICA**
- **AJUSTE DE PARÁMETROS DE UN CONTROLADOR DE LÓGICA DIFUSA**

ABSTRACT

During the last years, the energy demand has increased worldwide as a result of technological advances. To address this problem, the initiative known as microgrids (MG) was born. These MGs are defined as low voltage distribution networks connected to the electrical network through a point of common coupling. Microgrids have an energy management system (EMS), which is responsible of each distributed generation system comprising within the MG to accomplish a defined objective, such as, decrease operating costs (billing costs), or minimizing the grid power profile exchanged with the mains. The efficiency of the EMS could be increased by adding non-linear controllers combined with optimization algorithms to improve the controller's parameters tuning. This work describes the design of a particle swarm optimization algorithm PSO, for tuning the parameters of a fuzzy logic controller, to improve the performance of EMS of an electro-thermal grid-connected microgrid.

KEY WORDS:

- **PARTICLE SWARM OPTIMIZATION**
- **FUZZY LOGIC CONTROLLER**
- **ELECTRO THERMAL MICROGRID**
- **ENERGY MANAGEMENT SYSTEM**
- **PARAMETER TUNING FOR A FUZZY LOGIC CONTROLLER**

CAPITULO I: INTRODUCCIÓN

1.1 Antecedentes

En los últimos años se ha incrementado exponencialmente el uso de la estrategia de control Fuzzy Logic (FLC) para resolver diversos problemas relacionados al: control de reactores nucleares (Najera H, 2003), control de calidad de agua (Gharibi, y otros, 2012), control de elevadores (Jamaludin, Rahim, & Hew, 2009) e incluso es usado en los Sistemas de Gestión Energética (EMS – Energy Management System) de microrredes eléctricas (MG – Microgrids) (Chen, Wu, Song, & Chen, 2013), (Arcos-Aviles D. , y otros, 2018), (Arcos-Aviles D. , y otros, 2017), (Arcos-Aviles D. , Pascual, Marroyo, Sanchis, & Guinjoan, 2018). Una de las ventajas que presenta esta técnica de control es que se basa en el conocimiento heurístico que se posee de un proceso, definido a través de reglas difusas y funciones de pertenencia, con lo que se logra alcanzar una buena aproximación del mundo real.

Según experiencias recolectadas en (Lee, 1990) se afirma que cuando las reglas difusas y funciones de pertenencia son correctamente asignadas los resultados de desempeño obtenidos con FLC pueden llegar a alcanzar un desempeño superior al de otros algoritmos de control convencionales tales como: control PI, control PID, control por espacio de estado, entre otros. Las reglas difusas de una aplicación en específico son definidas por expertos en el área de estudio, especialmente en aquellas que poseen un número no muy extenso de variables, puesto que en sistemas muy complejos (con muchas variables), el número de reglas y funciones de pertenencia crece ampliamente por lo que su definición se dificulta para que un sistema logre alcanzar el desempeño deseado para la aplicación (Esmin, Aoki, & Lambert-Torres, 2002).

Por otro lado, como fruto de los cambios tecnológicos durante los últimos 50 años la demanda de energía ha crecido de manera acelerada. Para afrontar este reto nace la iniciativa económica - ambiental conocida como las MG, que son definidas como una red de distribución de bajo voltaje, conectada a la red de distribución de servicio a través de un punto de acople común (PCC – Point of Common Coupling), (Lasseter, 2002), (Nicos, 2014). Está compuesta por diversos componentes tales como: sistemas de generación distribuida (DG – Distributed Generator), que pueden ser tanto de energía renovable (fotovoltaica y eólica, etc.), como no renovable (generadores a diésel, biomasa, etc.), pueden incorporar cargas controlables y cargas críticas (Mahmoud, Habibi, & Bass, 2012) y sistemas de almacenamiento de energía (ESS – Energy Storage System) como: supercapacitores, almacenadores de energía térmica, baterías, entre otros; los cuales almacenan la energía generada para su posterior uso, además cuentan con un sistema de gestión energética inteligente EMS y controladores locales que permiten una operación confiable, estable y económica de la MG. (Fahad, Elbouchikhi, & Benbouzid, 2018)

El EMS es el encargado de asignar en tiempo real las referencias de potencia activa y reactiva a los diferentes elementos que conforman la MG, según el objetivo que ésta desea alcanzar. La estrategia escogida para el EMS depende exclusivamente de la aplicación a la que se la va a destinar una MG (Arcos-Aviles D. , y otros, 2015), (Kanchev, Lu, Colas, Lazarov, & Francois, 2011).

Dentro de los objetivos del EMS se pueden nombrar los siguientes: planificar el despacho de potencia, minimizar costos de operación, maximizar las ganancias de la MG, minimizar el perfil de potencia intercambiado con la red, y reducir la emisión de gases de invernadero a la atmósfera, entre otros. Por lo general el EMS usa como parámetros los datos recibidos desde la carga, la política de la empresa de servicio eléctrico, información sobre costos de mercado, el despacho, y

la programación de generadores y almacenadores de energía (Su & Wang, 2012), (Olivares, y otros, 2014).

Con la finalidad de alcanzar un mejor desempeño del EMS, se pueden implementar algoritmos de optimización inspirados en la naturaleza, tales como: algoritmo de búsqueda Cuckoo (CSA – Cuckoo Search Algorithm), algoritmo genético (GA – Genetic Algorithm), optimización por enjambre de partículas (PSO – Particle Swarm Optimization), algoritmo de abejas (BA – Bees Algorithm), optimización por colonia de hormigas (ACO – Ant Colony Optimization), entre otros. (Zang, Zhang, & Hapeshi, 2010), (Yang, Dey, & Fong, 2019)

En 1995 Ebehart y Kennedy diseñan una técnica estocástica conocida como PSO, inspirada en el comportamiento social de bandadas de pájaros o escolarización de peces (Ricardo Martínez-Soto, 2014).

Cuando el PSO supera la etapa de entrenamiento puede llegar a generar una solución de alta calidad en corto tiempo, pues su convergencia es muy rápida a diferencia de otros métodos de optimización estocásticos. (Bingül & Karahan, 2011). Además, puede ser utilizado en cualquier área, como: economía, matemáticas, ingeniería, etc. En relación a la verificación de desempeño del PSO en (Esmín, Aoki, & Lambert-Torres, 2002) se presenta una estrategia para el ajuste automático de las funciones de pertenencia de un FLC en una simulación de parqueo de tres automóviles, en la cual se constató que al agregar el PSO se reduce en promedio hasta un 18.22% el número de iteraciones para que el vehículo alcance el punto final en el estacionamiento. Por lo que el autor determina que se puede aumentar el desempeño de un FLC al agregar la técnica de PSO.

Con la objetivo de mejorar el desempeño de un EMS, en (Bevrani, Habibi, Babahajyani, Watanabe, & Mitani, 2012) se presenta una combinación de las técnicas fuzzy-logic y PSO para

optimizar el ajuste automático de los parámetros de un controlador proporcional-integral (PI) basado en frecuencia para los sistemas de una MG, para el análisis de resultados se comparó en simulación el desempeño de tres tipos de controladores en tres diferentes escenarios: el controlador PSO-fuzzy PI, el controlador fuzzy PI y el controlador PI clásico basado en la técnica de Ziegler-Nichols. En donde los datos reflejaron que el controlador PSO-fuzzy PI posee un índice de desempeño del 56% menor al controlador PI clásico y un 48% más bajo que el controlador fuzzy PI, con lo que se demuestra que es el más eficiente de los tres controladores de estudio.

En (García-Gutiérrez, y otros, 2019), se presenta la implementación del CSA para la optimización de los parámetros de un FLC tales como: funciones de pertenencia y base de reglas, de un sistema de levitación magnética, cuyo objetivo es controlar la posición de una esfera. Además, se presenta la comparación de resultados del caso de estudio utilizando diferentes métodos: entre los cuales se tiene: control por espacio de estado, FLC no optimizado, FLC optimizado únicamente en sus funciones de pertenencia, y un FLC que ha sido optimizado tanto en sus funciones de pertenencia como en su base de reglas. Demostrando que este último es el que obtuvo los mejores resultados en comparación a los otros tres.

Finalmente, en (Arcos-Aviles, y otros, 2019), se presenta un caso de estudio en el cual los autores proponen realizar el ajuste de parámetros de un FLC mediante la aplicación de CSA, con la finalidad de mejorar las prestaciones de una EMS para una microrred electrotérmica desarrollada en la investigación planteada en (Arcos-Aviles D. , y otros, 2018).

1.2 Justificación e Importancia

El rendimiento de un FLC depende principalmente de las relaciones entrada-salida establecidas como reglas y funciones de pertenencia, las cuales son desarrolladas por un experto en el área de

estudio en base al conocimiento heurístico que se posee de la aplicación, por lo tanto, si estas reglas no son óptimas el resultado del proceso no llega a ser el esperado (Venayagamoorthy & Doctor, 2004).

Una desventaja del FLC es que, al incrementar el número de variables, la complejidad para definir los parámetros correctos en sus reglas y funciones de pertenencia crece a la par, es por esta razón que, para evitar tediosas horas de análisis para la sintonización de dichos parámetros y errores en el diseño, se plantea realizar el ajuste de los parámetros de un FLC, componente indispensable del EMS de una MG electrotérmica, al incorporar el algoritmo inspirado en la naturaleza PSO. La MG bajo estudio se presenta en la Figura. 1, mientras que en la Figura. 2 se observa el diagrama de bloques de la estrategia de gestión energética basada en lógica difusa utilizada por este EMS. Como se puede observar en la Figura. 2, el bloque 6 corresponde al FLC en el que actuará el algoritmo de PSO para mejorar el desempeño del EMS (Arcos-Aviles D. , y otros, 2018).

Para comprobar que dicho algoritmo cumpla con su objetivo, el cual es suavizar el perfil de potencia intercambiado con la red, se debe evaluar ciertos criterios de calidad que fueron definidos en (Pascual, Barricarte, Sanchis, & Marroyo, 2015), (Pascual, Sanchis, & Marroyo, 2014), por lo que es necesario considerar la formulación de una función de costo global que agrupe todos estos criterios para así asegurar el correcto desempeño del algoritmo PSO.




Figura 1. Red residencial conectada a una microrred electrotérmica

Fuente: (Arcos-Aviles D. , y otros, 2018). ©2018 IEEE, Reprinted, with permission, from D. Arcos-Aviles, F. Guinjoan, J. Pascual, L. Marroyo, R. Gordillo, P. Sanchis, M. P. Marietta y A. Ibarra, “Fuzzy-based energy management of a residential electro-thermal microgrid based on power forecasting” IECON 2018 - 44th Annual Conference of the IEEE Industrial Electronics Society, Washington, DC, 2018, pp. 1824-1829.

Una de las ventajas del ajuste de parámetros del FLC con PSO es la reducción del número de iteraciones por su rápida convergencia, razón por la cual el consumo de recursos del hardware disminuye. Orientado a la aplicación en específico, se busca disminuir el perfil de potencia que se intercambia con la red eléctrica, con lo que se espera una reducción del consumo energético y por lo tanto una reducción en la facturación.




Figura 2. Diagrama de bloques de la estrategia de gestión energética difusa

Fuente: (Arcos-Aviles D. , y otros, 2018). ©2018 IEEE, Reprinted, with permission, from D. Arcos-Aviles, F. Guinjoan, J.

Pascual, L. Marroyo, R. Gordillo, P. Sanchis, M. P. Marietta y A. Ibarra, "Fuzzy-based energy management of a residential electro-thermal microgrid based on power forecasting" IECON 2018 - 44th Annual Conference of the IEEE Industrial Electronics Society, Washington, DC, 2018, pp. 1824-1829.

Para reducir la potencia intercambiada con la red, la EMS utiliza la ecuación 1.1, la cual consiste en la suma de tres componentes esenciales de la microrred. Una de estas es P_{FLC} , la cual es obtenida por la salida del FLC que a su vez tiene como entradas el $SOC(n)$ y $P_E^{3H^*}(n)$, cabe recalcar que en el FLC se implementará el algoritmo PSO, que, al reducir su resultado, se disminuye a su vez el P_{GRID} , pues el resto de parámetros de la ecuación 1.1, son valores definidos en (Arcos-Aviles D. , y otros, 2018).

$$P_{GRID}(n) = P_{CTR}^*(n) + P_{SOC}(n) + P_{FLC}(n) \quad (1.1)$$

Donde:

n : número de muestra

$P_{GRID}(n)$: Potencia intercambiada con la red eléctrica

$P_{CTR}^*(n)$: Potencia media estimada de la microrred

$P_{BAT}(n)$: Potencia de la Batería

$P_{FLC}(n)$: Potencia de salida del FLC

$SOC(n)$: Estado de Carga de la Batería

$P_E^{3H^*}(n)$: Error del pronóstico de potencia de la MG de las últimas 3 horas

1.3 Alcance del proyecto

Mediante el presente proyecto se pretende realizar el ajuste de parámetros de un controlador de lógica difusa para la estrategia de gestión energética de la MG electrotérmica residencial definida en (Arcos-Aviles D. , y otros, 2018), basado el algoritmo de PSO , con el objetivo de minimizar el valor resultante de los criterios de calidad tales como: pico máximo y mínimo del perfil de red, rango de variación de potencia y la máxima rampa de potencia; los cuales se encuentran definidos matemáticamente en (Arcos-Aviles, Pascual, Marroyo, Sanchis, & Guinjoan, 2016), (Arcos-Aviles, y otros, 2017); además de las fluctuaciones y picos de potencia intercambiados con la red.

El ajuste de parámetros y la mejora de la estrategia de gestión energética basada en FLC y PSO se realizará a través de simulaciones mediante Matlab®, con datos obtenidos en la MG de la Universidad Pública de Navarra (UPNa) en el periodo comprendido entre julio de 2013 a julio de 2014.

Para analizar el comportamiento del algoritmo de PSO se realizará un estudio comparativo de los resultados al establecer una función de costo general que englobe todos los criterios de calidad.

Los resultados obtenidos serán comparados con los estudios previos de (García-Gutiérrez, 2019), (Arcos-Aviles D. , y otros, 2018), para comprobar la robustez del sistema en cuanto a la mejora de la estrategia de gestión energética y poder definir cuál es la alternativa más eficiente para esta aplicación.

1.4 Objetivos

1.4.1 Objetivo General

Desarrollar el algoritmo de optimización por enjambre de partículas para la sintonización de los parámetros de un FLC utilizado en una EMS de una MG electrotérmica residencial.

1.4.2 Objetivos Específicos

- Estudiar el algoritmo de optimización por Enjambre de Partículas orientado al ajuste de parámetros del EMS basado en Fuzzy Logic.
- Definir una función de costo que incluya todos los criterios de calidad para la evaluación de la estrategia de gestión de la microrred electrotérmica.
- Comparar el desempeño del perfil intercambiado con la red eléctrica obtenida a través del FLC optimizado mediante PSO versus los resultados obtenidos en un EMS mejorado mediante métodos heurísticos y otro optimizado en base al algoritmo de búsqueda de Cuckoo.

CAPÍTULO II

MARCO TEÓRICO

2.1 Lógica difusa

La lógica difusa es una extensión de la lógica clásica, con la que se permite representar matemáticamente el umbral de incertidumbre que la lógica clásica posee, es decir todos los valores que se encuentran entre el cero y uno lógico, esto a través del uso de conjuntos difusos y funciones de pertenencia asociadas a estos, con la cuales se puede determinar el grado de pertenencia de los elementos. Este modelamiento está basado en el razonamiento natural del ser humano, el cual no es determinista como sucede con la lógica clásica, pues gradúa el valor de verdadero o falso de una afirmación. Por ejemplo, al calificar la altura de una persona, se gradúa esta altura como: muy alto entre 1,80 a 1,90 metros, alto entre 1,70 a 1,80, etc. Existen otros nombres con los que se le conoce a este tipo de lógica, entre los cuales se tiene: flexible, fuzzy o borrosa. (Luna, 2002)

2.1.1 Conjunto difuso

Un conjunto clásico es una colección de elementos, del que es posible determinar en base a un predicado de análisis y un universo dado, si un objeto pertenece, o no pertenece al conjunto. Mientras que un conjunto difuso puede definirse como una clase con límites difusos en la que hay una progresión gradual desde la no pertenencia, hacía la pertenencia, desde cierto punto de vista los conjuntos clásicos pasan a ser un caso particular de los conjuntos difusos. (Zatarain, 2011)

2.1.2 Predicado difuso

En un predicado clásico o booleano, al aplicarlo a un universo de valores x , este divide dichos valores en dos subconjuntos de x , uno pertenece al que verifica dicho predicado, y el otro al que no lo verifica. Como, por ejemplo, sí al conjunto x que se muestra en la ecuación. 2.2, se le aplica el

predicado clásico P definido en ecuación. 2.1, se obtiene la expresión de su pertenencia lógica μ_A que se puede observar en ecuación 2.3. (Zatarain, 2011)

$$P = x \geq 5 \quad (2.1)$$

$$x = [-1; 10] \quad (2.2)$$

$$\mu_A(x) = \begin{cases} 1, & x < 5 \\ 0, & x \geq 5 \end{cases} \quad (2.3)$$

Mientras que, al aplicar un predicado difuso a un universo de valores x , este no divide precisamente en dos subconjuntos de pertenencia, como sucede con un predicado clásico. Para hallar el valor de pertenencia μ es necesario aplicar operaciones entre conjuntos. Cabe mencionar que el predicado difuso requiere ser exclusivamente aplicado a un conjunto difuso.

2.2 Controladores fuzzy logic

La estrategia de control FLC ha incrementado su uso exponencialmente en los últimos años, para resolver diversos problemas relacionados a la ingeniería de control. Una de las ventajas que presenta esta técnica de control es que se basa en el conocimiento heurístico que se posee de un proceso, y que es diseñado a partir de un conjunto de reglas difusas y funciones de pertenencia, con lo que se logra alcanzar una buena aproximación del mundo real.

2.2.1 Componentes del controlador fuzzy logic

El diagrama de bloques de un FLC se muestra a continuación en la Figura 3, mientras que sus principales componentes son detallados a continuación.




Figura 3. Arquitectura del controlador de lógica difuso

Fuente: (Passino & Yurkovich, 1998)

- 1) La base de reglas: Está formada por un conjunto de reglas las cuales contienen el conocimiento del sistema.
- 2) El mecanismo de Inferencia: Tiene como objetivo el evaluar que reglas del conjunto son las más relevantes en un instante de tiempo, para posteriormente decidir la entrada a aplicar en la planta.
- 3) La fuzzificación. Esta interface se encarga de convertir las entradas físicas del controlador para que puedan ser interpretadas y comparadas con el conjunto de reglas de la base de reglas.
- 4) La defuzzyficación: Para la defuzificación se obtienen las conclusiones que el mecanismo de inferencia obtuvo y las convierte en entradas que son enviadas a la planta del sistema.

2.3 Ajuste de Parámetros del Controlador Fuzzy Logic

Los parámetros que se deben ajustar en un FLC, son: el universo de discusión, funciones de pertenencia (MF), y la base de reglas. Estos parámetros deben ser asignados por un experto, que conozca el funcionamiento del sistema, o a su vez mediante la aplicación de algoritmos computacionales de optimización.

2.3.1 Universo de Discurso

El universo de discurso del conjunto difuso hace referencia al rango de todos los posibles valores que puede tomar una variable, y sobre el cuál se podrán incluir las funciones de pertenencia que determinará el experto en control, por ejemplo: sí se desea clasificar a personas por su estatura, el universo de discurso puede ser desde treinta centímetros hasta dos metros [0,30 ; 2].

2.3.2 Funciones de Pertenencia

Las funciones de pertenencia indican el grado de pertenencia que tiene el conjunto x con su predicado difuso P . Además, representan la caracterización de la variable que se mide dentro del universo de búsqueda, cabe destacar que éstas no son probabilidades (Passino & Yurkovich, 1998). En el diseño de controladores por lo general se nombra a cada función usando siglas, como, por ejemplo: Negativo Grande (NG), cero (z), Positivo mediano (PM), etc.

Las funciones de pertenencia generalmente están compuestas por tres parámetros, que son: límite inferior (a); límite superior (b); valor modal o núcleo (m), en algunas funciones, como por ejemplo las trapezoidales, el valor modal está compuesto por dos límites, que son: modal inferior (m_1) y modal superior (m_2).

El Ingeniero en control, puede elegir el tipo de función de pertenencia que va a usar en su diseño (Passino & Yurkovich, 1998). Entre los tipos de funciones que pueden ser utilizadas, se muestran las principales a continuación en la Figura 4.

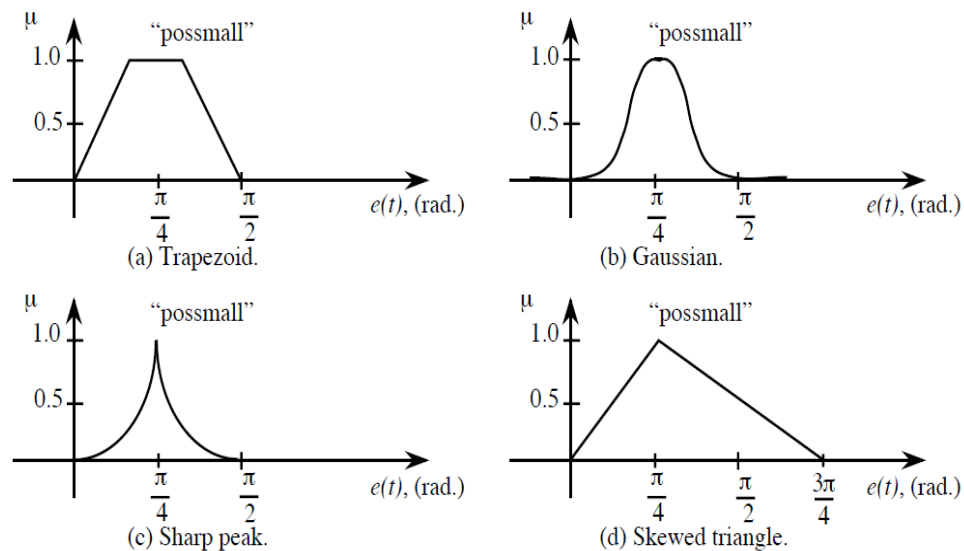


Figura 4. Tipos de funciones de pertenencia

Fuente: (Passino & Yurkovich, 1998)

2.3.3 Base de reglas

La base de reglas está compuesta por reglas difusas Sí-Entonces (IF-THEN), y son expresadas simbólicamente como:

$$\text{IF } \langle \text{premisa} \rangle \text{ THEN } \langle \text{conclusión} \rangle$$

En un sistema clásico si la premisa o también conocida como antecedente es verdadera, la conclusión también lo es. Mientras que en un sistema difuso las reglas se ejecutan parcialmente, cuando el antecedente es cierto con un determinado grado de pertenencia, la conclusión también es cierta en un determinado grado. Por ejemplo, se desea controlar la velocidad V en motor DC, si V es demasiado alta, el sistema debe reducir el voltaje u para evitar daños, una forma de definir esta regla puede ser la siguiente:

$$\text{IF } \langle V = \text{PG} \rangle \text{ THEN } \langle u = \text{PP} \rangle$$

En la evaluación de reglas, se toma las entradas previamente fuzzificadas y son aplicadas a los antecedentes de las reglas difusas. Cuando una regla tiene más de un antecedente, se aplican los operadores AND u OR, para así obtener un solo resultado de la evaluación de esa regla.

2.4 Optimización multiobjetivo

Un problema de optimización multiobjetivo es aquel que está conformado por varias funciones que se deben optimizar simultáneamente, estas forman el vector conocido como vector de optimización $F(x)$. Este tipo de problemas de optimización pueden escribirse de la siguiente forma:

$$\text{Minimizar } F(x) = [f_1(x), f_2(x), \dots, f_n(x)] \quad (2.4)$$

$$\text{Sujeto a } g_j(x) \leq 0, \quad j = 1, 2, \dots, J \quad (2.5)$$

$$h_k(x) = 0, \quad k = 1, 2, \dots, K \quad (2.6)$$

Una de las desventajas de la optimización multiobjetivo es que no siempre se puede alcanzar una solución óptima que minimice todas las funciones a la vez, pues mientras una función mejora su optimización otro puede empeorar, para evitar este conflicto es necesario lograr un equilibrio de objetivos a través de una reformulación conocida como función de costo o función de optimización. La manera más común es formular una función de resultado escalar que represente una combinación ponderada de los objetivos, para esto se determinan cuáles son las funciones con mayor prioridad de optimización y se les asigna una mayor ponderación con respecto a las de menor prioridad. Otra de las desventajas de la optimización multiobjetivo es que por lo general es necesario ejecutar por varias ocasiones el algoritmo para que este alcance una solución óptima aceptable. (Yang, 2014)

2.5 Método de la suma ponderada

El método de la suma ponderada es el más usado en problemas de optimización, su objetivo es alcanzar el mínimo global, mediante la combinación de todas las funciones objetivo en un solo escalar, asignando una determinada ponderación para cada función. La expresión matemática de este método se muestra a continuación en la ecuación 2.7, donde $F(x)$ es la función fitness (Fit), $f_n(x)$ las funciones del problema de optimización multiobjetivo. (Yang, 2014)

$$F(x) = w_1 \cdot f_1(x) + w_2 \cdot f_2(x) + \dots + w_n \cdot f_n(x) \quad (2.7)$$

Donde $w = [w_1, w_2, \dots, w_n]$ corresponde a las ponderaciones asignadas en base a las preferencias del diseñador de la función de costo; una solución aceptable depende exclusivamente de una correcta combinación de estas ponderaciones. (Aranda & Orjuela, 2015)

2.5.1 Inicialización de la población

En un caso ideal la solución óptima de un problema de optimización es independiente de la población inicial, sin embargo, la realidad es totalmente distinta, cuando el espacio de búsqueda es muy grande y la posición inicial de los agentes es creada aleatoriamente, la probabilidad de hallar un resultado óptimo es muy baja, pues existe la posibilidad de que la solución deseada esté en una pequeña región que el algoritmo talvez no explore jamás. Una de las formas de afrontar ese reto es experimentar con varias configuraciones de población inicial, hasta alcanzar un resultado aceptable de la función de costo, y que el algoritmo busque el óptimo global desde esa, la desventaja es que la convergencia puede llegar a ser lenta. (Yang, Dey, & Fong, 2019)

Otra forma de mejorar la convergencia es que la inicialización se la realice en una región que el programador conozca previamente de la cual se pueden obtener los resultados deseados. (Yang, 2014).

2.5.2 Algoritmos heurísticos y metaheurísticos

Los algoritmos metaheurísticos pertenecen al grupo de algoritmos estocásticos, y su diferencia es muy pequeña con los algoritmos heurísticos, los cuales hacen referencia a la búsqueda de soluciones por prueba y error, es así que en un problema de optimización complejo se puede encontrar una solución en un tiempo razonable, sin embargo, no es garantizado que la solución alcanzada sea la más óptima. Mientras que los algoritmos metaheurísticos son un desarrollo especial de los algoritmos heurísticos, donde “meta” significa, de más alto nivel, hablando de su desempeño este generalmente es mejor que el de un heurístico simple, una de las ventajas que presentan los metaheurísticos es que usan búsquedas de soluciones aleatorias, con lo cual se alejan de las búsquedas locales y pasan a buscar en una escala global, haciéndolos adecuados para la optimización global. (Yang, 2014)

Los componentes esenciales de un algoritmo metaheurístico son: diversificación e intensificación, o también conocidos como exploración o explotación. La diversificación se encarga de generar nuevas soluciones que exploren todo el espacio de búsqueda, mientras que la intensificación se refiere a la explotación de una región local en específico. La solución óptima depende de una buena combinación de estos dos elementos. (Yang, Dey, & Fong, 2019)

Los metaheurísticos se clasifican en dos tipos: el primero es basado en la población de agentes o por trayectorias, como, por ejemplo: optimización por enjambre de partículas, algoritmos genéticos, etc. El segundo tipo utiliza un único agente que se desplaza por todo el espacio de

búsqueda, donde los desplazamientos buenos son aceptados como la mejor solución, mientras que los no tan buenos son aceptados con cierta probabilidad. (Yang, 2014)

2.5.3 Algoritmos inspirados en la naturaleza

Se denomina optimizar al proceso de encontrar un resultado que minimice o maximice el objetivo de un determinado problema, para optimizar la solución de un problema en primer lugar se debe tener bien definido el objetivo al que se desea llegar, como por ejemplo: si se desea determinar la mejor ruta para ir a un determinado sitio, se debe tener en cuenta, el uso de combustible, el tiempo de viaje, el estado de la vía, para esto la mejor solución posible será aquella que minimice los parámetros enunciados anteriormente. (Martínez-Vargas & León, 2017)

En la naturaleza existen diversos procesos y comportamientos, tanto en animales como en humanos, que pueden ser imitados a través de algoritmos computacionales. La forma con la que trabajan estos algoritmos es buscar continuamente las mejores soluciones en un espacio de búsqueda, mediante la diversificación e intensificación, la diversificación se refiere a la exploración de nuevas soluciones dentro del espacio de búsqueda, mientras que la intensificación se refiere a la explotación o también conocida como colonización de una región en específico. (Yang, Dey, & Fong, 2019)

Dentro de los algoritmos de optimización inspirados en la naturaleza, se tienen los siguientes: PSO, CSA, GA, ACO, algoritmo de luciérnagas, algoritmo de murciélagos, algoritmo de polinización de flores, etc. (Yang, 2014)

2.6 Optimización por enjambre de partículas

En 1995, Russell Eberhart y James Kennedy diseñan mediante simulaciones, una técnica estocástica para la optimización de funciones continuas no lineales conocida como Optimización

por Enjambre de Partículas (PSO), la cual tiene como fundamento a la vida artificial (A-life – Artificial Life), inspirada en el comportamiento social de bandadas de pájaros y escolarización de peces; además comparte similitudes con la computación evolutiva y algoritmos genéticos. (Eberhart & Kennedy, 1995)

2.6.1 Aplicaciones de la optimización por enjambre de partículas

Existe una gran variedad de problemas de optimización en los cuales se puede incluir el algoritmo del PSO para encontrar la mejor solución a la función de costo de interés; tales como:

Ajuste de parámetros de métodos Scan, usados para encontrar conglomerados de unos o ceros en secuencias binarias, que sirven para encontrar soluciones a problemas epidemiológicos como definen en su trabajo (Corvea, García, & Cardoso, 2012).

Optimización del estacionamiento automático de vehículos mediante el ajuste de las funciones de pertenencia de un FLC mediante simulaciones tal como lo detalla en su trabajo (Esmin, Aoki, & Lambert-Torres, 2002).

Sistemas de Inferencia difusa para la modificación de color ajustado de (Rodríguez, Ponce, & Espitia, 2015), en la cual incluyen el algoritmo PSO para cambiar las imágenes digitales artísticas a un estilo psicodélico.

Control de trayectoria para robots demostrado por (Bingül & Karahan, 2011), en el cual realizan el ajuste de un FLC mediante PSO y realizan la comparación con un controlador PID optimizado por enjambre de partículas.

Optimización de FLC para un sistema de almacenamiento energético, (Taruwona & Nyirenda, 2018) en su trabajo describen el uso del PSO para optimizar los parámetros de las funciones de pertenencia del FLC para mejorar el estado de carga de sus sistemas de almacenamiento de energía.

2.6.2 Parámetros del PSO

Para comprender el algoritmo PSO, es necesario detallar los parámetros y términos utilizados, entre los cuales se tienen los siguientes:

$$x_i = [x_1, x_2, x_3, \dots, x_n] : \text{Vector de Posición} \quad (2.8)$$

$$v_i = [v_1, v_2, v_3, \dots, v_n] : \text{Vector de Velocidad} \quad (2.9)$$

$$x_i \in [x_{i_{min}}, x_{i_{max}}] : \text{Espacio de Búsqueda} \quad (2.10)$$

$$P_{i_{best}} = [P_{i_{best_1}}, P_{i_{best_2}}, \dots, P_{i_{best_n}}] : \text{Vector de simple nostalgia} \quad (2.11)$$

$$G_{best} = [G_{best_1}, G_{best_2}, \dots, G_{best_n}] : \text{Vector de mejor posición global} \quad (2.12)$$

2.6.2.1 Espacio de búsqueda

El espacio de búsqueda EB es el rango en el cuál cada variable de cada partícula del problema de optimización buscará la mejor posición para colonizar. Cabe recalcar que el espacio de búsqueda no siempre debe ser el mismo para todas las variables.

2.6.2.2 Velocidad de las partículas

La velocidad de las partículas v_i , donde i representa el número de la partícula analizado, determina la rapidez con la que se desplazarán las partículas dentro del espacio de búsqueda, mientras mayor sea la velocidad las partículas tendrán una exploración más elevada. Al contrario, cuando esta decrece el enjambre no explora lo suficiente y la posibilidad de que estas exploten en un óptimo local aumenta. El cálculo para la nueva velocidad $v_i(k + 1)$, se encuentra definido en la ecuación 2.13. En la cual se puede observar que es función de: la velocidad actual $v_i(k)$, la posición actual $x_i(k)$, la memoria individual $P_{i_{best}}(k)$, la memoria colectiva G_{best} , las constantes de aceleración C_1 y C_2 , y los parámetros de aceleración estocásticos R_1 y R_2 .

$$v_i(k + 1) = v_i(k) + R_1 C_1 (P_{i_{best}}(k) - x_i(k)) + R_2 C_2 (G_{best} - x_i(k)) \quad (2.13)$$

2.6.2.3 Posición de las partículas

La posición de las partículas, determina el lugar en que cada agente del enjambre se encuentra ubicado actualmente dentro del espacio de búsqueda.

La expresión para el cálculo de la nueva posición de la partícula del enjambre $x_i(k + 1)$ se muestra a continuación en la ecuación 2.14, en donde se puede observar que está es función de la posición actual y la nueva velocidad calculada.

$$x_i(k + 1) = x_i(k) + v_i(k + 1) \quad (2.14)$$

2.6.2.4 Memoria individual y colectiva

El Pbest refleja la memoria individual de cada partícula la cual contiene el recuerdo del mejor lugar que esta alcanzó; el ajuste de la velocidad en función del Pbest se lo conoce como “simple nostalgia”, pues hace que la partícula regrese al que más le gusto en el pasado; mientras que el Gbest es el conocimiento grupal, que representa el sitio al que las partículas buscan alcanzar.

2.6.2.5 Parámetros de aceleración estocásticos

Los parámetros de aceleración estocásticos vienen dados por dos números aleatorios R_1 y R_2 en el rango de 0 a 1, los cuales otorgan al enjambre un comportamiento más realista, al imitar de mejor forma el comportamiento social de una bandada de aves o a la escolarización de peces. Estos parámetros son actualizados para cada partícula en cada iteración del algoritmo. (Yang, Dey, & Fong, 2019)

2.6.2.6 Constantes de aceleración

Las constantes de aceleración definen el peso de los parámetros de aceleración estocásticos, que llevan a las partículas hacia las posiciones de P_{best} y G_{best} . Es decir que dependiendo del ajuste

que se dé a estos parámetros, el enjambre cambiará en su exploración y explotación. Las constantes pueden definirse de las siguientes maneras: cuando se define un valor grande para C_1 en relación al C_2 se obtiene una mayor exploración de las partículas dentro de espacio de búsqueda, mientras que al contrario, si se define C_2 relativamente mayor a C_1 esto produce que el enjambre aterrice anticipadamente en un mínimo local aunque esta no sea la verdadera solución óptima del problema de interés; al definir el mismo valor para C_1 y C_2 provocan una búsqueda más efectiva en el espacio de solución. En la investigación se han definido estas constantes al valor de 2, aunque éstas podrían cambiar de acuerdo al problema a tratar, o bien podrían determinarse de acuerdo al conocimiento del problema. El resumen de lo descrito se puede observar a continuación en la Tabla 1.

Tabla 1

Resumen de la configuración de las constantes de aceleración del PSO

Parámetros	Efecto
$C_1 > C_2$, $C_2 = 0$	Mayor exploración, colonización nula
$C_1 > C_2$, $C_2 > 0$	Mayor exploración, colonización no efectiva
$C_2 > C_1$, $C_1 = 0$	Exploración nula, colonización no efectiva
$C_2 > C_1$, $C_1 > 0$	Menor exploración, colonización no efectiva
$C_1 = C_2 = 2$	Exploración y colonización efectiva

2.6.2.7 Búsqueda multi-dimensional

Para realizar una búsqueda multi-dimensional cada variable se incluye en una sola matriz de dimensión $N \times D$, donde N representa el número de partículas y D el número de variables del problema de optimización. De esta forma se tiene una matriz que guarde las posiciones, y otra matriz que contenga las velocidades del enjambre ambas con las mismas dimensiones $N \times D$.

2.6.2.8 Peso de inercia

La velocidad de cada partícula puede ser limitada para mejorar la capacidad de exploración del problema de interés, este límite se lo conoce como v_{max} , si su valor es muy alto el enjambre mejora

su exploración y podría colonizar en las mejores soluciones pasadas, en cambio sí este es muy pequeño mejora la colonización, pero el enjambre aterrizaría en un mínimo local, y las partículas no explorarían todo el espacio de búsqueda. Otra forma de mejorar de mejorar la exploración del enjambre es mediante el uso del peso de inercia ω , el cual fue introducido en 1998 al algoritmo PSO por (Eberhart & Shi, 2001). El valor de ω decrece linealmente desde su valor máximo ω_{max} hacia su valor mínimo ω_{min} , a medida que el algoritmo se ejecuta. La expresión que puede ser usada para el decrecimiento lineal es la presentada en ecuación 2.15. Donde i representa el número de iteraciones. Usualmente se usan los valores $\omega_{max} = 0.9$ y $\omega_{min} = 0.4$, aunque su adecuada selección genera un balance entre la exploración y la colonización. (Eberhart & Shi, 2001)

$$\omega(k) = \left[\frac{\omega_{min} - \omega_{max}}{(i_{max} - 1)} (i - 1) \right] + \omega_{max} \quad (2.15)$$

Al insertar el peso de inercia ω de la ecuación 2.15 en 2.13 se obtiene la siguiente expresión:

$$v_i(k+1) = \omega(k)v_i(k) + R_1C_1(P_{i_{best}}(k) - x_i(k)) + R_2C_2(G_{best} - x_i(k)) \quad (2.16)$$

2.6.2.9 Factor de constricción

El factor de constricción τ fue introducido al algoritmo PSO, con la finalidad de restringir las nuevas velocidades de las partículas, con lo que en algunos problemas de optimización se puede asegurar su convergencia al ser función de las constantes de la aceleración donde: $\varphi = C_1 + C_2$ $\forall \varphi > 4$, a menudo se usan los valores $\varphi = 4.1$ y $\tau = 0.729$. El cálculo de τ se puede observar en la ecuación 2.17.

$$\tau = \frac{2}{2 - \varphi - \sqrt{\varphi^2 - 4\varphi}} \quad (2.17)$$

El factor de constricción τ de la ecuación 2.17 es incluido en la expresión 2.16 tal como se muestra a continuación:

$$v_i(k+1) = \tau \cdot \left[\omega(k)v_i(k) + R_1 C_1 (P_{i_{best}}(k) - x_i(k)) + R_2 C_2 (G_{best} - x_i(k)) \right] \quad (2.18)$$

2.6.2.10 Dimensiones de vectores del PSO

En un problema multi-variable se deben considerar las dimensiones de cada arreglo del PSO, para esto se presenta a continuación en la Tabla 2 el resumen de las dimensiones que debe tener cada matriz.

Tabla 2

Dimensiones de los vectores del PSO

Arreglo	Dimensión
v	$N \times D$
x	$N \times D$
P_{best}	$N \times D$
G_{best}	$1 \times D$

2.6.2.11 Pseudocódigo y diagrama de flujo del PSO

Una vez detalladas las características del PSO, es necesario conocer el proceso para implementar el algoritmo PSO, el cual se presenta a continuación a manera de pseudocódigo en la Figura 5.

```

Definir EB,N, C1, C2,  $\omega$ , iteraciones máx (Ite).
Inicializar las matrices  $x$  y  $v$  dentro del EB.
Evaluar Fit de cada partícula.
 $P_{best} \leftarrow x$ 
 $G_{best} \leftarrow$  menor Fit del  $P_{best}$ .
mientras  $i < ite$  hacer
  Inicio mientras
    Decrementar  $\omega$ 
    Calcular  $v$  y  $x$  en base a ec. 2.22 y ec. 2.18.
    Evaluar Fit para cada partícula.
    sí Fit(k) < Fit(k-1) entonces
       $P_{best} \leftarrow x$ 
    fin sí
    sí menor Fit de  $P_{best} < G_{best}$  entonces
       $G_{best} \leftarrow P_{best_{menor}}$ 
    fin sí
  fin mientras

```

Figura 5. Pseudocódigo del algoritmo PSO

Para entender de mejor manera el proceso en el que se ejecuta el algoritmo del PSO, se presenta a continuación el diagrama de flujo respectivo el cual se puede observar en la Figura 6. Cabe mencionar que, para el desarrollo del algoritmo, se puede obviar la evaluación fitness inicial, si x y v de cada partícula se inician en los mismos valores. De esta forma el $Pbest$ es inicializado con el vector de posiciones x y el $Gbest$ se inicializa con cualquier partícula del vector $Pbest$.




Figura 6. Diagrama de flujo de algoritmo PSO

2.7 Sistemas de Gestión Energética

Los EMS se define como el conjunto de elementos que interactúan, para poder alcanzar objetivos energéticos establecidos a través de políticas para el uso eficiente de la energía. Un EMS trabaja fundamentalmente con el ciclo de mejora continua, o también llamado la rueda de Deming: Planificar-Ejecutar-Verificar-Actuar. Entre los principales objetivos se pueden nombrar los siguientes: la reducción del consumo energético de un sector geográfico, reducción de emisión de gases contaminantes, además de la generación de energías renovables. Cabe destacar que los objetivos trazados deben estar acorde a la política regional en la que se encuentra el caso de estudio, y estos se deben cumplir en un determinado lapso de tiempo. (Energía, 2014)

Entre los principales criterios generales usados para las EMS se tiene los siguientes:

Energía Inteligente: Contribuir al uso eficiente e inteligente de la energía, priorizando el uso de sistemas de autoconsumo.

Mejorar la competitividad: Priorizar a los sectores de energías renovables, ahorro y eficiencia como motores de economía.

Mejorar Infraestructura: Garantizar la calidad de suministro eléctrico, mudando de los sistemas energéticos convencionales hacia modelos inteligentes y descentralizados.

CAPITULO III:

DESARROLLO DEL ALGORITMO DE OPTIMIZACIÓN POR ENJAMBRE DE PARTÍCULAS

4.1 Descripción del caso de estudio

En el presente trabajo se presenta la optimización de los parámetros de las funciones de pertenencia de un FLC para el sistema de gestión energética de la microrred electrotérmica residencial con conexión a la red de suministro presentada en (Arcos-Aviles D. , y otros, 2018), misma que se puede observar en la Figura 1. Los componentes de la microrred se detallan a continuación:

- Un ESS con una capacidad nominal de 72kWh, conformado por un banco de baterías de plomo-ácido.
- Un sistema de generación de energía renovable híbrido (HRES – Hybrid Renewable Energy System), que posee un generador fotovoltaico (PV – Photo Voltaic), además de una turbina eólica (WT – Wind Turbine), ambas con capacidad nominal de 6kW.
- Cargas domésticas que consumen 7kW de potencia nominal.
- Un sistema de agua caliente sanitaria (ACS), que incluye un grupo de colectores solares térmicos de placas planas con capacidad de 2kW, un calentador eléctrico de agua (EWH – Electric Water Heater) de 2kW, y un sistema de almacenamiento térmico conformado por un tanque de 800 litros de capacidad.

4.2 Sistema de Gestión Energética del caso de estudio

El sistema de gestión energética de la Figura 7 es descrito a profundidad en (Arcos-Aviles D. , y otros, 2018). Mientras que el presente trabajo se centra en mejorar el desempeño del FLC del bloque 6 de la Figura 7. Con lo que se podrá reducir las fluctuaciones del perfil de potencia P_{GRID} , mismo que fue definido anteriormente en la ecuación 1.1.




Figura 7. Diagrama de bloques Fuzzy EMS-FC

Fuente: (Arcos-Aviles D. , y otros, 2018) ©2018 IEEE.

4.3 Controlador Fuzzy Logic del EMS

El controlador difuso usado en el bloque ha sido definido en trabajos anteriores que se pueden encontrar en (Arcos-Aviles D. , y otros, 2018). Este FLC es un sistema M.I.S.O (Multiple Inputs - Single Output), cuyas entradas son: SOC , $P_E^{3H^*}$ y a su salida la componente $P_{FLC}(n)$. Con el algoritmo PSO se pretende mejorar el parámetro $P_{FLC}(n)$, con la finalidad de optimar el perfil de potencia intercambiado con la red en base a la ecuación 1.1. El método de inferencia asumido es la técnica de Mamdani con una base de 25 reglas y su defuzzificación mediante el método del centroide.

4.4 Criterios de Calidad

Los criterios de calidad de la gestión energética son usados para verificar la conducta del perfil de potencia intercambiado con la red, los mismos han sido definidos en trabajos anteriores (Arcos-Aviles D. , y otros, 2015). Con la finalidad de optimizar la estrategia se han seleccionado un total de seis parámetros que deben ser minimizados, en base a los cuales se formulará la respectiva función de optimización, que servirá como fundamento para el diseño de la función de costo del algoritmo de optimización por enjambre de partículas.

Los parámetros de calidad elegidos son los siguientes: Pico máximo $P_{G,MAX}$ y mínimo $P_{G,MIN}$ del perfil de red, rampa de potencia media APD y máxima MPD , rango de variación de potencia PVR y variabilidad del perfil de red PPV . Las expresiones que rigen el comportamiento de estos parámetros se muestran a continuación en las ecuaciones 3.19, 3.20, 3.21, 3.22, 3.23 3.24. Para una mejor comprensión de las mismas, estas se encuentran detalladas en (Pascual, Barricarte, Sanchis, & Marroyo, 2015) y (Pascual, Sanchis, & Marroyo, 2014)

$$P_{G,MAX} = \max(P_{GRID}) \quad (3.1)$$

$$P_{G,MIN} = \min(P_{GRID}) \quad (3.2)$$

$$MPD = \max(|\Delta P_{GRID}|) \quad (3.3)$$

$$APD = \frac{1}{N} \sum_{n=1}^N |\Delta P_{GRID}| \quad (3.4)$$

$$PVR = \frac{P_{G,MAX} - P_{G,MIN}}{P_{LG,MAX} - P_{LG,MIN}} \quad (3.5)$$

$$PPV = \frac{\sqrt{\sum_{f=f_i}^{f_f} P_{GRID,f}^2}}{P_{DC}} \quad (3.6)$$

4.5 Función de costo del problema de optimización

La función de costo usada en este trabajo para el problema de optimización, debe ser la misma que la presentada en (García-Gutiérrez, 2019), esto con la finalidad de que al momento de realizar las comparaciones de los resultados por ambos algoritmos PSO y CSA, estos hayan sido hallados bajo las mismas condiciones. La función objetivo del problema de optimización queda definido de la siguiente forma:

$$f(X) = [P_{G,MAX}, P_{G,MIN}, MPD, APD, PVR, PPV] \quad (3.7)$$

$$g(X) = \begin{cases} -6 \leq P_E \leq 6 \\ 50 \leq SOC \leq 100 \\ k_{(-)} \leq P_{FLC} k_{(+)} \\ 0 \leq k \leq 10 \\ 1 \leq RL \leq 9 \end{cases} \quad (3.8)$$

Donde $f(x)$ de la ecuación 3.7 corresponde al problema de optimización y está sujeto a $g(x)$ de la expresión 3.8, la información completa se encuentra detallada en (García-Gutiérrez, 2019). La función fitness usada en el presente documento se muestra a continuación en la ecuación 3.9.

$$U = 4 \cdot \frac{P_{G,MAX}}{2.56} + 4 \cdot \frac{P_{G,MIN}}{-1.89} + 4 \cdot \frac{MPD}{846} + 2 \cdot \frac{APD}{75} + 2 \cdot \frac{PVR}{0.34} + 1 \cdot \frac{PPV}{1.26} \quad (3.9)$$

4.6 Diseño del algoritmo de optimización por enjambre de partículas

Para el diseño del algoritmo de optimización por enjambre de partículas del presente trabajo, se toma en cuenta los parámetros del FLC a optimizar. Los cuales incluyen: las funciones de pertenencia de sus dos entradas P_{ERROR} , SOC y su salida P_{FLC} , además del universo de discurso de esta última $x_{k(-)(+)}$, las reglas RL de la base para el sistema de inferencia también son consideradas dentro de estos parámetros.

Es así que al tratarse de un problema multidimensional se debe crear una matriz de dimensiones $N \times D$ que guardará las posiciones de cada partícula y otra matriz de las mismas dimensiones para las velocidades.

Las ecuaciones 3.10 y 3.11 muestran cómo está conformado el vector de coordenadas de cada partícula tanto de posición como de velocidad respectivamente.

$$x_i = [x_{P_{ERROR}}, x_{SOC}, x_{PG}, x_{k(-)(+)}, x_{RL}] \quad (3.10)$$

$$v_i = [v_{P_{ERROR}}, v_{SOC}, v_{PG}, v_{k(-)(+)}, v_{RL}] \quad (3.11)$$

La Tabla 3, muestra los parámetros a optimizar, junto al número de coordenadas que ocupa cada uno, con la suma de estas coordenadas se define el valor de D para la matriz de optimización, por lo tanto $D = 72$. Cabe resaltar que el número de coordenadas de cada parámetro es explicado a profundidad en la sección 3.6.1, la cual describe la inicialización de las poblaciones.

Tabla 3
Coordenadas de parámetros a optimizar

Parámetro	Número de coordenadas
P_{ERROR}	11
SOC	11
P_{FLC}	23
$x_{k(-)(+)}$	2
RL	25
Total	72

Finalmente, se deben definir los límites del espacio de búsqueda de acuerdo con los límites del espacio de diseño factible definidos en (4.7), de la siguiente forma:

$$x_{P_{ERROR}} = \{x_{PE} \in X \mid -6 \leq x_{PE} \leq 6\} \quad (3.12)$$

$$x_{SOC} = \{x_{SOC} \in X \mid 50 \leq x_{SOC} \leq 100\} \quad (3.13)$$

$$x_{k(-)(+)} = \{x_{k(-)(+)} \in X \mid 0 \leq |x_{k(-)(+)}| \leq 10\} \quad (3.14)$$

$$x_{PG} = \{x_{PG} \in X \mid k_{(-)} \leq x_{PG} \leq k_{(+)}\} \quad (3.15)$$

$$x_{RL} = \{x_{RL} \in X \mid 1 \leq x_{RL} \leq 9\} \quad (3.16)$$

4.6.1 Población Inicial

Para la generación de la población inicial de las partículas, se considera cada uno de los parámetros descritos en la sección 3.6. A continuación se detalla cada una de las dimensiones del problema de optimización.

4.6.1.1 Población del error de predicción

La entrada del FLC P_{ERROR} abarca las once primeras dimensiones del vector de población [1:11], estos valores corresponden a los tres puntos que forman las funciones de pertenencia triangulares. La cantidad de funciones utilizadas en este trabajo está basada en trabajos anteriores de (Arcos-

Aviles D. , y otros, 2018), con lo que se obtiene un total de cinco funciones de pertenencia distribuidas uniformemente, dentro del universo de discurso definido en la ecuación 3.12 las cuales serán representadas con el subíndice UD , éstas son negativo grande NB , negativo pequeña NS , cero ZE , positivo pequeño PS y positivo grande PB . Para las funciones extremas NB y PB se ha considerado optimizar únicamente uno de sus valores extremos, La Figura 8 muestra la representación de la población inicial del error de predicción.

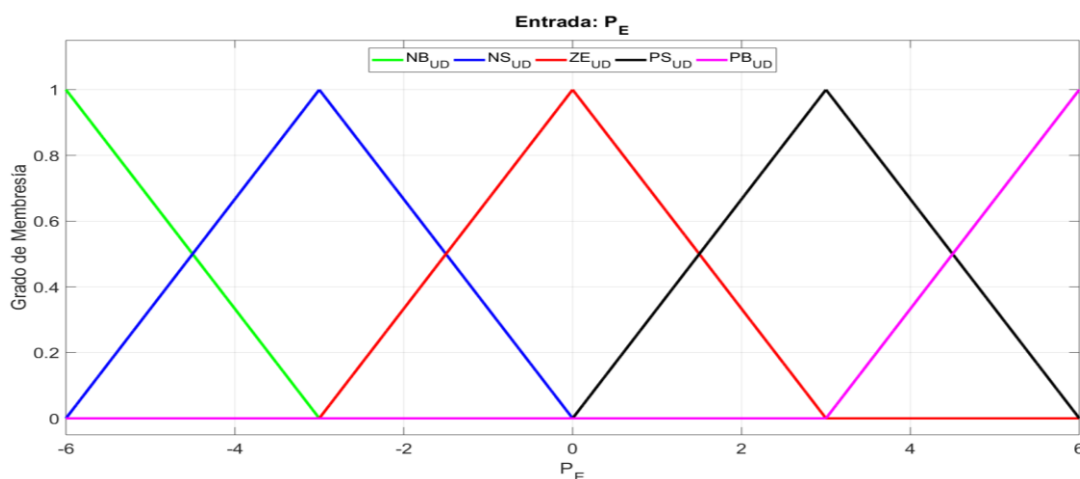


Figura 8. Población inicial de del error de predicción.

Tabla 4

Posiciones iniciales de funciones de pertenencia del P_E

NB_{UD}		NS_{UD}		ZE_{UD}			PS_{UD}		PB_{UD}					
-6	-6	-3	-6	-3	0	-3	0	3	0	3	6	3	6	6

4.6.1.2 Población del estado de carga de la batería

La población inicial de la entrada del FLC correspondiente al SOC, ocupa las siguientes once posiciones del vector x_i de la partícula [12:22], estos valores se encuentran definidos bajo las mismas características de la población error de predicción, a excepción de su universo de discurso

el cual se encuentra definido en la ecuación 3.13. La población inicial uniformemente distribuida del SOC se muestra a continuación en la Figura 9.

Tabla 5

Posiciones iniciales de funciones de pertenencia del SOC

<i>NBUD</i>			<i>NSUD</i>			<i>ZEUD</i>			<i>PSUD</i>			<i>PBUD</i>		
50	50	62.5	50	62.5	75	62.5	75	87.5	75	87.5	100	87.5	100	100

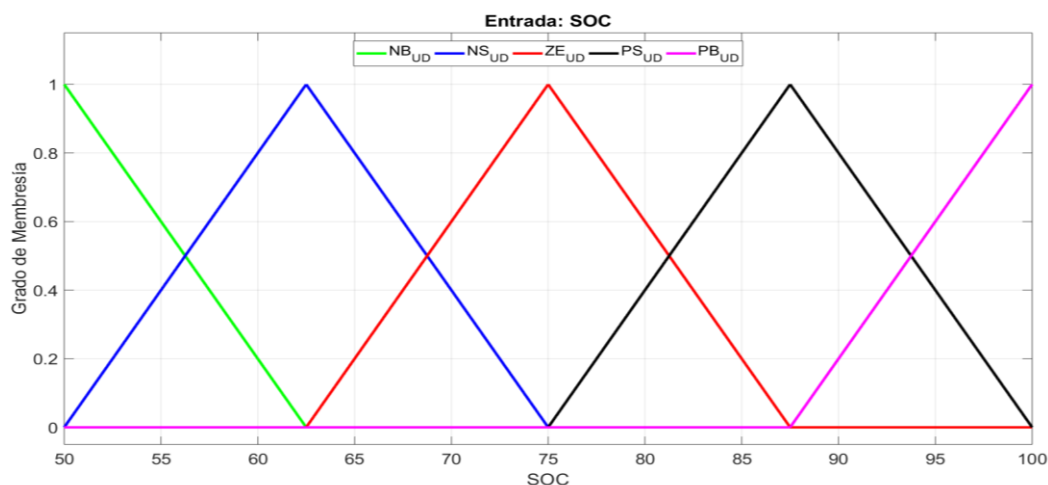


Figura 9. Población inicial del estado de carga de la batería.

4.6.1.3 Población de la potencia del controlador

En cuanto a la población inicial de la salida del FLC P_{FLC} , los valores de los parámetros de las funciones de pertenencia corresponden a las posteriores 23 posiciones del vector de x , tomando como fundamento las funciones presentadas en trabajos anteriores de (Arcos-Aviles D. , y otros, 2018), en donde se observa que se han agregado cuatro funciones de pertenencia adicionales las cuales son: negativo mediano NM, negativo pequeño pequeño NSS, positivo mediano PM y positivo pequeño pequeño PSS, al igual que para el caso de las entradas, las funciones de pertenencia NB y PB serán optimizadas únicamente sus valores extremos; además es necesario realizar la optimización del rango $k_{(+,-)}$, de su universo de discurso, de esta manera se agregan dos

posiciones adicionales al vector x_i con un total de 25, las cuales ocupan las localidades [23:47], la Figura 10 muestra la población inicial uniformemente distribuida de la salida del controlador.

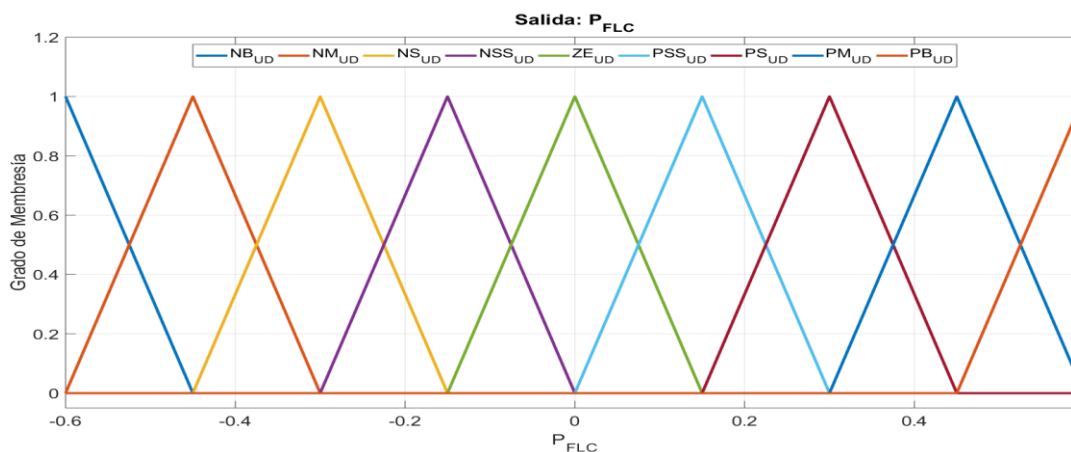


Figura 10. Población inicial de la potencia del controlador.

Tabla 6

Posiciones y rango iniciales de funciones de pertenencia de P_{FLC}

NB_{UD}			NM_{UD}			NS_{UD}			NSS_{UD}			ZE_{UD}		
0.6	0.6	0.45	0.6	0.45	0.30	0.45	0.3	0.15	0.3	0.15	0	0.15	0	0.15
PSS_{UD}			PS_{UD}			PM_{UD}			PB_{UD}			RangouD		
0	0.15	0.3	0.15	0.3	0.45	0.3	0.45	0.6	0.45	0.6	0.6	0.6	-6	6

4.6.1.4 Población de la Base de Reglas

El sistema de inferencia del FLC, al tener dos entradas de cinco funciones de pertenencia cada una, existe un total de 25 posibilidades de reglas que pueden ser ocupados por las nueve funciones de pertenencia de la salida. Por tales motivos para la optimización se deben agregar 25 localidades adicionales al vector de posición x_i ocupando así las posiciones [48:72]. Su espacio de búsqueda está definido en la ecuación 3.14. La población inicial de la base de reglas se define a continuación en la Tabla 7, en donde se puede observar que al igual que en las funciones de pertenencia tanto para la entrada y la salida estas también se encuentran uniformemente distribuidas.

Tabla 7
Base de Reglas Inicial

P_{FLC}		$P_E(n)$				
		<i>NB</i>	<i>NS</i>	<i>ZE</i>	<i>PS</i>	<i>PB</i>
<i>SOC</i>	<i>NB</i>	ZE	PSS	PS	PM	PB
	<i>NS</i>	NSS	ZE	PSS	PS	PM
	<i>ZE</i>	NS	NSS	ZE	PSS	PS
	<i>PS</i>	NM	NS	NSS	ZE	PSS
	<i>PB</i>	NB	NM	NS	NSS	ZE

4.6.2 Parámetros de Ajuste del PSO

Del grupo de parámetros de ajuste que posee el PSO, para el presente trabajo se han utilizado los siguientes: constantes de aceleración C_1 , C_2 , y peso de inercia ω . De acuerdo a la sección 2.6.2.8 el peso de inercia decrecerá gradualmente en cada iteración, mientras que las constantes de aceleración son definidas igualmente en un valor de 2. El factor de constricción es obviado pues las velocidades serán limitadas en forma distinta. En la Tabla 8 se presenta un resumen de estos valores considerados para el diseño del algoritmo PSO.

Tabla 8
Parámetros del PSO

Parámetro	Valor
C_1	2
C_2	2
ω	0.9 \rightarrow 0.4

4.6.3 Limitaciones de Velocidad

Con la finalidad no obtener espacios sin definir entre funciones de pertenencia de los FLC, es necesario limitar la velocidad de todas las variables de cada una de partículas del algoritmo; de no hacerlo el análisis del sistema de inferencia produce un mayor tiempo de ejecución del algoritmo. Por motivos de comparación el límite δ a usarse es del $\pm 5\%$ de la longitud del universo de discurso, de acuerdo al resultado obtenido por el CSA descrito en (García-Gutiérrez, 2019). La Figura 11 muestra la variación que puede sufrir una función de pertenencia en una iteración.

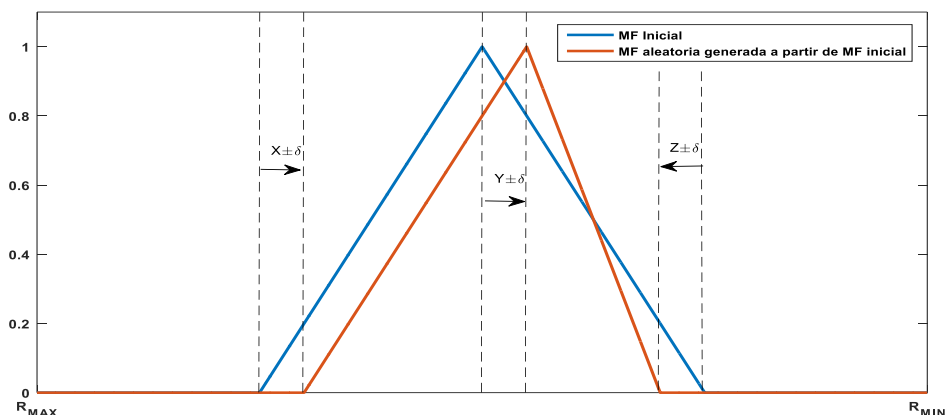


Figura 11. Desplazamiento de nuevas soluciones

Fuente: (García-Gutiérrez, 2019)

4.6.4 Pseudocódigo y diagrama de flujo del PSO implementado

El pseudocódigo y diagrama de flujo del algoritmo PSO implementado se muestra a continuación en las Figuras 12 y 13 respectivamente, en las cuales se puede observar que contienen la acción de limitación de velocidades descritas en la sección 3.6.3.

```

ite ← 300, C1 ← 2, C2 ← 2, ω ← 0.9
x ← UD(25,72) //Posición Uniformemente Distribuida; v ← zeros(25,72)
Evaluar estrategia Fit_IECON2018
Pbest ← x
Gbest ← menor Fit del Pbest.
mientras i < ite hacer
    Decrementar ω
    Calcular v ec. 2.22
    sí v > 5% del EB entonces
        v ← 5% del EB
    fin sí
    Calcular x en base a ec. 2.18.
    Evaluar estrategia IECON2018.
    sí Fit_IECON2018(k) < Fit_IECON2018(k-1) entonces
        Pbest ← x
    fin sí
    sí menor Fit de Pbest < Gbest entonces
        Gbest ← Pbest_menor
    fin sí
fin mientras

```

Figura 12. Pseudocódigo del algoritmo PSO implementado población




Figura 13. Diagrama de flujo del algoritmo PSO implementado.

CAPITULO IV: PRUEBAS Y RESULTADOS

5.1 Simulaciones numéricas.

Para las simulaciones numéricas se utilizó el software MATLAB® en el cual se compiló el algoritmo PSO planteado en este documento, generando un total de 1435 horas de ejecución o bien el equivalente a 60 días completos, cabe destacar que este tiempo es el acumulativo de la fase de entrenamiento del algoritmo PSO. La principal característica del computador usado para la compilación, es que posee un procesador INTEL® Core-I7 de sexta generación, con una frecuencia de reloj de 2.6 GHz.

5.2 Variación de parámetros PSO

Con la finalidad de encontrar una configuración del algoritmo que satisfaga una estabilidad de los criterios de diseño como: tiempo de procesamiento, tiempo de convergencia y mejora de los parámetros de calidad, el algoritmo ha sido ejecutado por 70 ocasiones, y se realizaron variantes en la disposición de sus parámetros tales como: número de partículas, cantidad de iteraciones, constantes de aceleración C_1 y C_2 , rango inicial del universo de discurso de la salida P_{FLC} y el límite del porcentaje de variación de variables δ .

Para determinar el número de iteraciones necesarias para que el algoritmo obtenga un resultado aceptable, se inició con 300 iteraciones por ejecución, como resultado de las pruebas el promedio del número de iteración de convergencia es de 204. Por esta razón, por motivos de dar seguridad al resultado de la ejecución se agrega un 5% dando un total de 215 iteraciones.

En cuanto a el rango inicial del universo de discurso de la salida P_{FLC} se realizaron varias ejecuciones del algoritmo con un rango inicial definido en:

$x_{k(-)} = -1$, $x_{k(+)} = 1$, como resultado de estas ejecuciones, la solución hallada siempre era aproximada el rango de la solución descrita en (García-Gutiérrez, 2019). Sin embargo, se presentó como desventaja el incremento del tiempo de convergencia. Con la finalidad de reducir este tiempo se escogió un valor cercano a la solución del rango $k_{(+,-)}$, de (García-Gutiérrez, 2019), tal como recomienda (Yang, 2014) en su literatura, la cual fue explicada con anterioridad en la sección 2.5.1. Por lo tanto, los valores iniciales escogidos para el rango de la potencia del controlador son: $x_{k(-)} = -0.6$ y $x_{k(+)} = 0.6$.

Después de la fase de entrenamiento, las constantes de aceleración del algoritmo, fueron ajustadas en: $C_1 = 1$ y $C_2 = 2$, para que de esta forma la exploración sea menor a la explotación, como se detalló en la sección 2.6.2.6.

El rango del peso de inercia elegido es: $\omega_i = 1$ y $\omega_f = 0.3$, con lo que se logra una ponderación de la velocidad actual que va desde el 100% en la primera iteración hasta el 30% en la última, con lo que se garantiza la explotación del mínimo global en las últimas iteraciones de la ejecución del algoritmo.

El porcentaje de variación de coordenadas fue fijado en $\delta = \pm 5\%$, tal como está definido en (García-Gutiérrez, 2019), pues se observó después de varias ejecuciones que con un porcentaje mayor al 5%, como por ejemplo: $\delta = 10\%$, el algoritmo puede llegar a generar vacíos entre las funciones de pertenencia, tal como se observa en la Figura 14, lo que provocará incertidumbre en el sistema de inferencia del FLC. Es importante mencionar que, estos vacíos se pueden evitar mediante restricciones en el algoritmo, pero la desventaja es que, al mover las posiciones de los parámetros de las funciones de pertenencia continuas para llenar estos espacios, provoca que el

algoritmo empiece a trabajar desde una posición alejada del óptimo global hallado hasta el momento, por ende, aumenta el tiempo de convergencia.

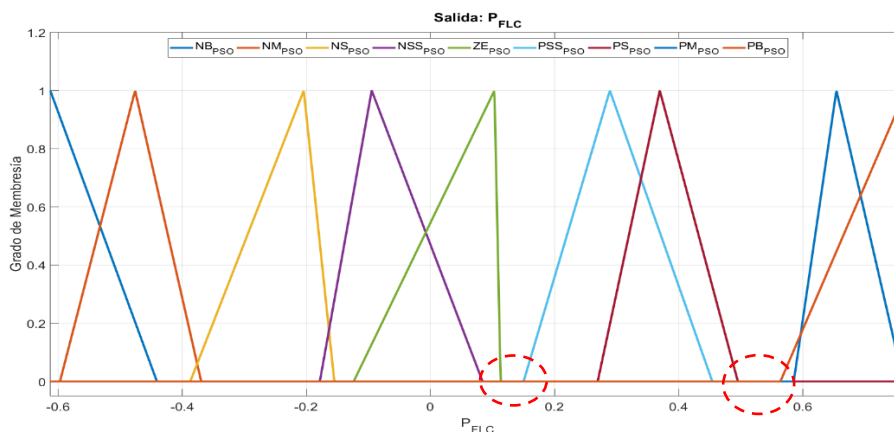


Figura 14. Zonas no definidas de funciones de pertenencia

5.2.1 Tiempo de procesamiento.

En cuanto a tiempo de procesamiento este es directamente proporcional al número de partículas seleccionado para la ejecución, pues en cada iteración el algoritmo analiza cada partícula individualmente. Por esta razón, al incrementar el número de partículas el tiempo de ejecución aumenta. En base al uso de la función “tic-toc” de MATLAB®, es posible obtener el tiempo en el que cada partícula del algoritmo era analizada por el computador, obteniendo así un tiempo promedio 37.2 segundos por partícula, cabe recalcar que este tiempo es variable dependiendo del computador utilizado.

5.2.2 Tiempo de convergencia.

El tiempo de convergencia viene dado por el promedio del número de iteración en el cual se obtuvo el último cambio en el resultado de la función de costo de las diferentes ejecuciones realizadas, con lo cual se pudo determinar que mientras mayor es el número de partículas usado,

aumenta el tiempo de análisis por cada iteración, pero la ventaja es que se necesita menos iteraciones para alcanzar la convergencia. El resumen de estos valores se detalla en la Tabla 9.

En la Tabla 9 se puede observar el tiempo transcurrido en cada iteración, este tiempo es el acumulado durante el análisis desde la primera partícula hasta la última. Mientras que el tiempo de ejecución es el tiempo necesario para completar todas las iteraciones con las que se ajustó el algoritmo, que para este caso son 300.

Es de importancia resaltar que mientras mayor es el número de partículas utilizado, la solución converge en un menor número de iteraciones, aunque el tiempo de convergencia sigue siendo más elevado que al usar un menor número de partículas, por tales motivos el número de partículas seleccionado es de 5, con lo que se reduce el tiempo de ejecución y el tiempo de convergencia.

Tabla 9

Resumen de la información de ejecución del algoritmo PSO

Nº Partículas	Tiempo por Iteración (min)	Tiempo de ejecución (horas)	Convergencia (Iteración Nº)	Tiempo de Convergencia (horas)
5	3.1	15.5	204	10.54
15	9.3	46.5	140	21.70
25	15.5	77.5	107	26.64

5.3 Comparativa de funciones de pertenencia de las entradas del FLC

En esta sección se compara las funciones de pertenencia obtenidas por el PSO, con respecto a las funciones obtenidas mediante métodos heurísticos y el CSA.

5.3.1 Comparativa del error de predicción

Las funciones de pertenencia obtenidas para el error de predicción generadas por el algoritmo PSO se muestran a continuación. En la Figura 15 se muestra la comparación con la población inicial (UD), en donde se aprecia el desplazamiento de las funciones finales. En la Figura 16 se puede

observar la diferencia que existe entre las funciones PSO versus las funciones obtenidas por métodos heurísticos (FC) (Arcos-Aviles D. , y otros, 2018), la cual concuerda con la población inicial uniformemente distribuida.




Figura 15. Funciones de pertenencia P_E PSO finales vs iniciales

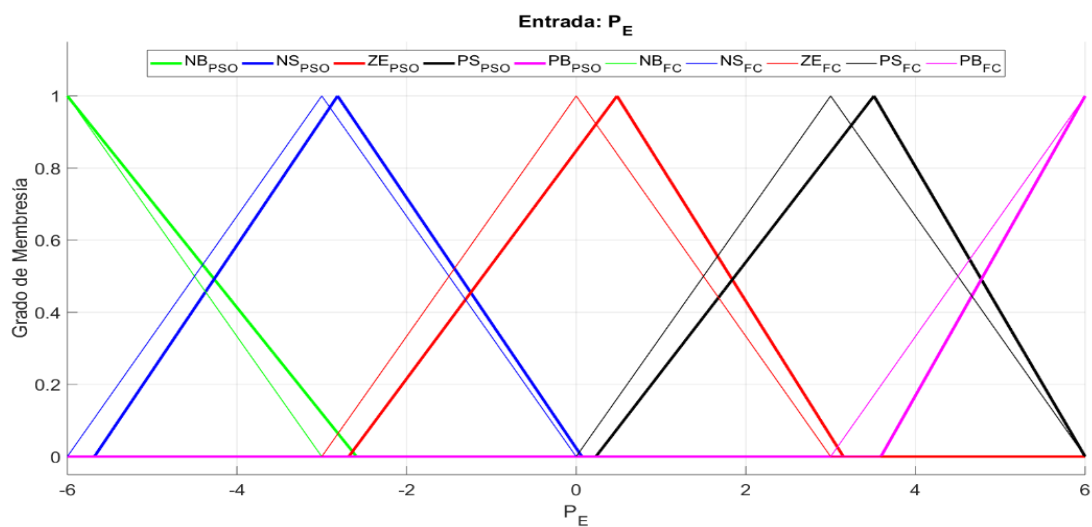


Figura 16. Funciones de pertenencia P_E PSO vs métodos heurísticos

En la Figura 17 se puede observar la comparación de las funciones de pertenencia obtenidas mediante PSO vs las funciones del CSA. A pesar de que el resultado de la función de costo y parámetros de calidad es similar, se puede notar que existen diferencias notorias en las funciones finales del PSO.

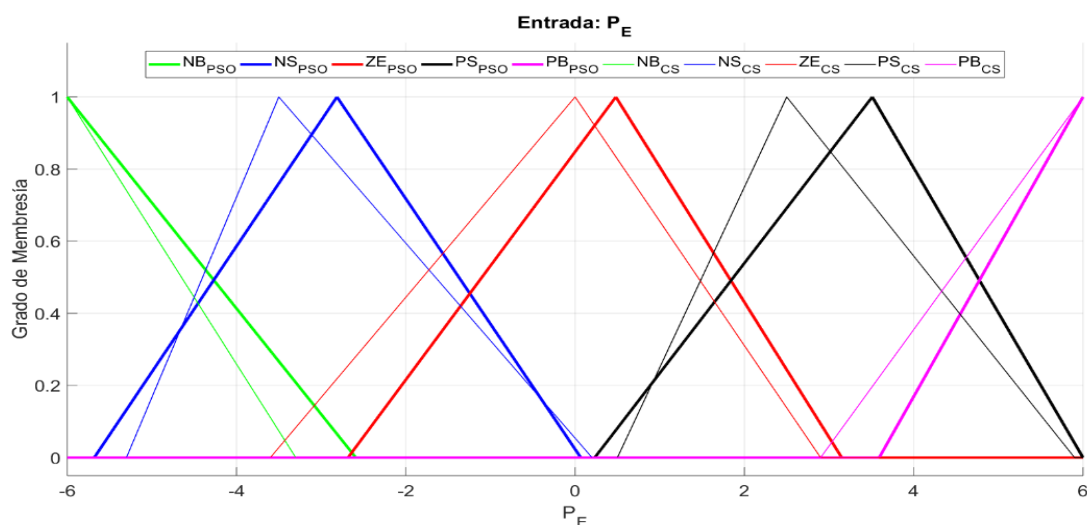


Figura 17. Funciones de pertenencia P_E PSO vs CSA

La Tabla 10 muestra una mayor apreciación de los valores de los parámetros de las funciones de pertenencia de la entrada P_E , obtenidas por diferentes técnicas de origen.

Tabla 10

Comparación de funciones de pertenencia del error de predicción

	<i>NB</i>		<i>NS</i>			<i>ZE</i>		<i>PS</i>			<i>PB</i>			
Fuzzy EMS - FC	-	-	-3	-6	-3	0	-	3	0	3	6	3	6	6
Fuzzy EMS - FC-CSA	-	-	3.3	5.3	3.5	0.2	-	2.9	0.5	2.5	5.9	2.9	6	6
Fuzzy EMS - FC-PSO	-	-	2.59	5.68	2.81	0.07	-	3.15	0.23	3.51	6	3.59	6	6

5.3.2 Comparativa del estado de carga de la batería

En la Figura 18 se puede observar las funciones del SOC obtenidas mediante PSO, a partir de la población inicial. Nótese que estas se han desplazado hacia la derecha al igual que en la entrada Pe-PSO. La Figura 19 y 20 muestran la comparación de las funciones SOC-PSO vs métodos heurísticos, y CSA respectivamente.




Figura 18. Funciones de pertenencia del SOC, PSO final vs inicial

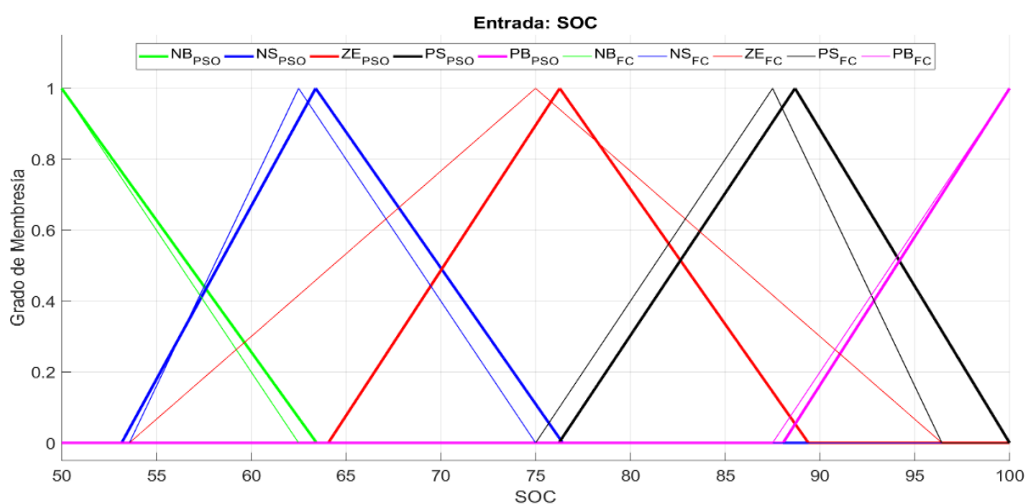


Figura 19. Funciones de pertenencia del SOC, PSO vs métodos heurísticos




Figura 20. Funciones de pertenencia del SOC, PSO vs CSA

De igual forma que para el error de predicción La Tabla 11 muestra una mayor apreciación de los valores de los parámetros de las funciones de pertenencia de las diferentes técnicas de origen para el estado de carga de la batería.

Tabla 11

Comparación de funciones de pertenencia de estado de carga de la batería

	NB		NS		ZE		PS		PB						
Fuzzy EMS -FC	50	50	62.5	53.6	62.5	75	53.7	75.1	96.6	75	87.5	96.4	87.5	100	100
Fuzzy EMS -FC-CSA	50	50	62.6	50.4	62.4	73.6	62.5	71.5	86.6	74.1	87.8	97	88.1	100	100
Fuzzy EMS -FC-PSO	50	50	63.5	53.2	63.4	76.4	64.1	76.3	89.4	76.2	88.7	100	88.1	100	100

5.4 Comparación de las funciones de pertenencia de la salida del FLC.

En cuanto a las funciones de pertenencia para la potencia del controlador, éstas no pueden ser comparadas en una misma imagen debido a que el rango del universo de discurso cambia para cada caso, y la escala no sería la misma.

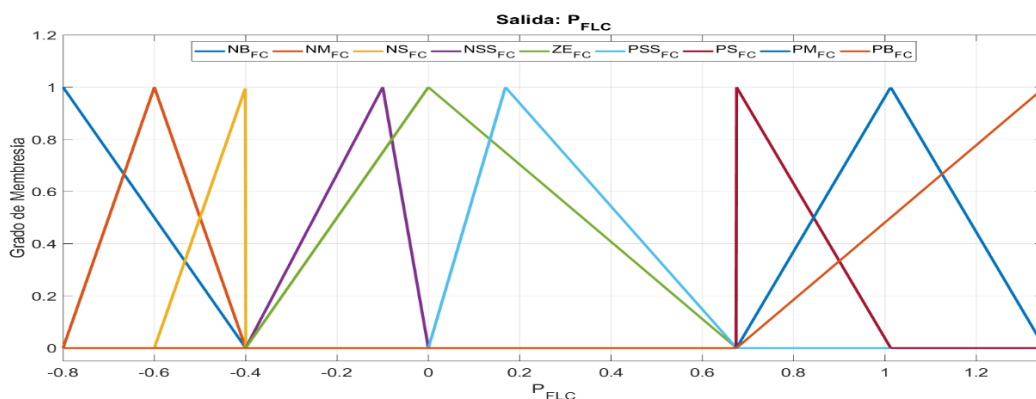


Figura 21. Funciones de pertenencia de P_{FLC} obtenida por métodos heurísticos

(Arcos-Aviles D. , y otros, 2018)

Tabla 12

Parámetros de MF y rango de la salida del FLC obtenido por métodos heurísticos

	<i>NB</i>		<i>NM</i>		<i>NS</i>		<i>NSS</i>					
Fuzzy EMS-FC	-0.8	-0.8	-0.4	-0.8	-0.6	-0.4	-0.6	-0.4	-0.4	-0.4	-0.1	0
	<i>ZE</i>		<i>PSS</i>		<i>PS</i>		<i>PM</i>					
Fuzzy EMS-FC	-0.4	0	0.68	0	0.17	0.68	0.68	0.68	1	0.68	1	1.35
	<i>PB</i>		<i>Rango</i>									
Fuzzy EMS-FC	0.68	1.35	1.35	-0.8	1.35							




Figura 22. Funciones de pertenencia de P_{FLC} obtenida por CSA

Fuente: (García-Gutiérrez, 2019).

Tabla 13

Parámetros de MF y rango de la salida del FLC obtenido por CSA

	<i>NB</i>		<i>NM</i>		<i>NS</i>		<i>NSS</i>					
Fuzzy EMS-FC-CSA	-0.51	-0.51	-0.35	0.49	-0.32	-0.14	0.35	0.21	0.01	0.11	-0.03	0.14
	<i>ZE</i>		<i>PSS</i>		<i>PS</i>		<i>PM</i>					
Fuzzy EMS-FC-CSA	0.08	0.19	0.26	0.06	0.32	0.42	0.3	0.45	0.55	0.36	0.67	0.77
	<i>PB</i>		<i>Rango</i>									
Fuzzy EMS-FC-CSA	0.56	0.78	0.78	-0.51	0.79							

Fuente: (García-Gutiérrez, 2019).

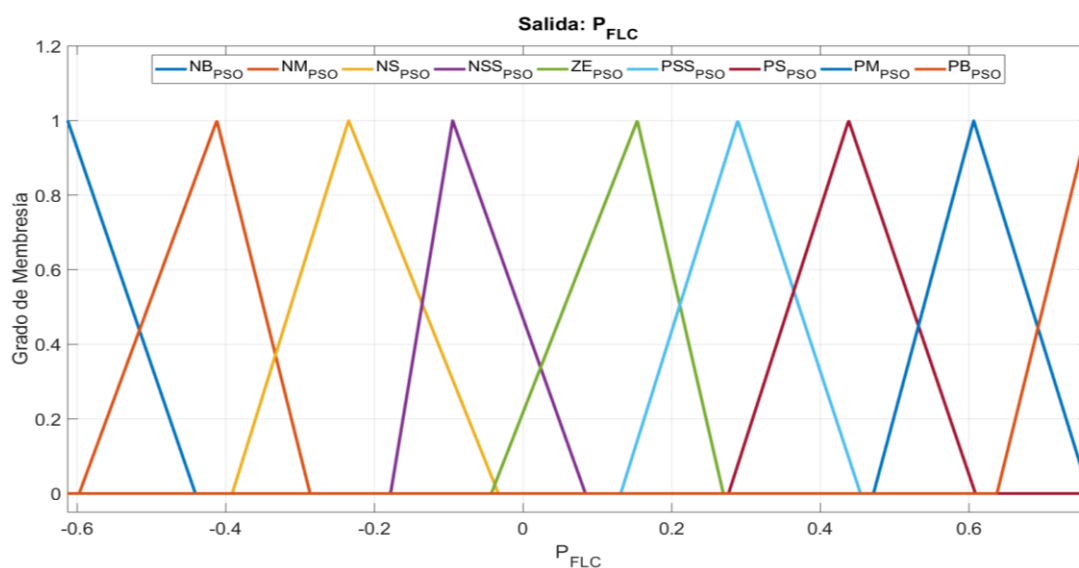


Figura 23. Funciones de pertenencia de P_{FLC} obtenida por PSO

Tabla 14

Parámetros de MF y rango de la salida del FLC obtenido por PSO

	<i>NB</i>		<i>NM</i>		<i>NS</i>		<i>NSS</i>					
Fuzzy EMS FC-PSO	-0.61	-0.61	0.44	-0.6	-0.41	-0.29	0.39	0.24	0.03	-0.18	-0.09	0.08
	<i>ZE</i>		<i>PSS</i>		<i>PS</i>		<i>PM</i>					
Fuzzy EMS FC-PSO	-0.04	0.15	0.27	0.13	0.29	0.45	0.28	0.44	0.61	0.47	0.61	0.76
	<i>PB</i>		<i>Rango</i>									
Fuzzy EMS FC-PSO	0.64	0.76	0.76	-0.61	0.76							

5.5 Comparación de la Base de Reglas.

La base de reglas obtenida como solución de la ejecución del algoritmo PSO del presente documento se presenta en la Tabla 15. En donde se observa que, al partir de una población inicial uniformemente distribuida, esta solo ha cambiado una única regla.

Tabla 15

Base de reglas de EMS-FC optimizada por PSO

P_{FLC}	$P_E(n)$					
	<i>NB</i>	<i>NS</i>	<i>ZE</i>	<i>PS</i>	<i>PB</i>	
<i>SOC</i>	<i>NB</i>	ZE	PSS	PS	PM	PB
	<i>NS</i>	ZE	ZE	PSS	PS	PM
	<i>ZE</i>	NS	NSS	ZE	PSS	PS
	<i>PS</i>	NM	NS	NSS	ZE	PSS
	<i>PB</i>	NB	NM	NS	NSS	ZE

La Tabla 16 muestra la base de reglas obtenida por CSA, que de igual forma se inicializa desde una población uniformemente distribuida, está cambia un total de cuatro reglas, lo cual en comparación con la base de la Tabla 15, no determina que alguna de las dos esté incorrecta.

Tabla 16

Base de reglas de EMS-FC optimizada por CSA

P_{FLC}	$P_E(n)$					
	<i>NB</i>	<i>NS</i>	<i>ZE</i>	<i>PS</i>	<i>PB</i>	
<i>SOC</i>	<i>NB</i>	ZE	ZE	PS	PM	PB
	<i>NS</i>	NSS	ZE	PSS	PS	PB
	<i>ZE</i>	NS	NSS	ZE	PSS	PS
	<i>PS</i>	NM	NS	NSS	ZE	PSS
	<i>PB</i>	NB	NM	NS	NS	ZE

Fuente: (García-Gutiérrez, 2019).

Se puede notar que para ambos casos estas guardan la simetría y lógica necesaria para el sistema de inferencia del FLC, los algoritmos las han encontrado como la mejor solución de la ejecución.

La Tabla 17 muestra la base de reglas descritas originalmente en (Arcos-Aviles D. , y otros, 2018), la cual, en conjunto con las funciones de pertenencia planteadas en el mismo, obtienen como

resultado los parámetros de calidad que han sido dispuestos a optimizar, por los algoritmos metaheurísticos PSO y CSA. Además, se puede observar que estas reglas no están ubicadas de forma simétrica, al igual que las de las Tablas 15 y 16.

Tabla 17

Base de reglas de EMS-FC optimizada por algoritmos heurísticos

P_{FLC}	$P_E(n)$					
	<i>NB</i>	<i>NS</i>	<i>ZE</i>	<i>PS</i>	<i>PB</i>	
<i>NB</i>	PB	PM	PS	PM	PB	
<i>NS</i>	PM	PS	PSS	PS	PM	
<i>SOC</i>	<i>ZE</i>	NS	ZE	PSS	NSS	
	<i>PS</i>	NM	NS	NSS	NS	NM
	<i>PB</i>	NB	NSS	NM	NM	NB

Fuente: (Arcos-Aviles D. , y otros, 2018)

5.6 Evaluación de los parámetros de Calidad.

La evaluación de los parámetros de calidad de la EMS obtenidos mediante el algoritmo PSO del presente documento, se realiza en base a la comparación con los parámetros detallados previamente en la sección 3.4. y los resultados conseguidos por métodos heurísticos descritos en (Arcos-Aviles D. , y otros, 2018), y los alcanzado mediante la ejecución del CSA obtenidos en (García-Gutiérrez, Ajuste de los parámetros del controlador fuzzy logic del sistema de gestión energética de una microrred electrotérmica doméstica conectada a red mediante el algoritmo de búsqueda de cuckoo., 2019).

El primer punto a abordar es que para maximizar el tiempo de vida de la Batería del ESS, el SOC debe mantenerse en un rango definido del $50\% < SOC < 100\%$ y tener mayor frecuencia de repetición en valores cercanos al 75%. Como se puede observar en la Figura 24, el resultado de la optimización es notorio, pues las fluctuaciones del SOC obtenidas por PSO son menores a las del SOC alcanzadas mediante métodos heurísticos.

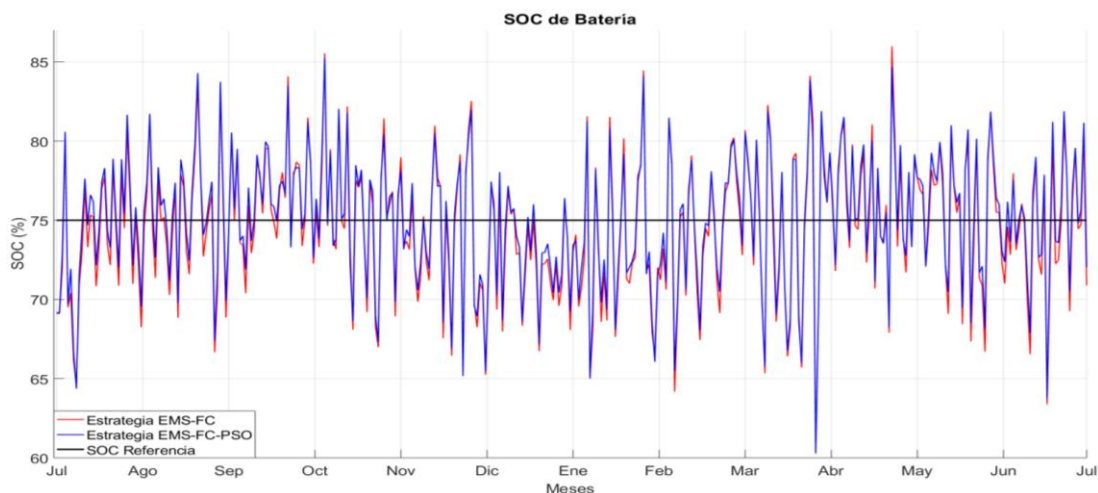


Figura 24. Comparación SOC de batería PSO vs métodos heurísticos

En la Figura 25 se puede apreciar que los valores del SOC en algunos datos son menores a los del CSA. Sin embargo, la mayoría de puntos se mantienen iguales, pues ambos resultados han sido obtenidos mediante algoritmos de optimización. Esto se debe a que cada algoritmo encontró un mínimo diferente, lo que ha producido, que las funciones de pertenencia, al igual que la base de reglas sean distintas entre cada algoritmo, y trabajen de diferente forma en ciertos datos del problema de interés.




Figura 25. Comparación SOC de Batería PSO vs CSA

De acuerdo a lo descrito en la sección 4.6, la Figura 26 corrobora que la frecuencia anual del SOC mejoró con el uso del PSO, obteniendo un incremento del 3.03% en el rango central del 70% - 80%, mientras que se registra una reducción del 0.31% en 50% - 60%, además de incrementos de 0.83% en 90% - 100%.




Figura 26. Comparación de Rangos de SOC, PSO vs métodos heurísticos

Para la comparación de la frecuencia anual del SOC-PSO vs SOC-CSA es menester referirse a la Figura 27, en la cual se observa que las diferencias son prácticamente nulas en casi todos los rangos, a excepción de un incremento del 0.46% en 80% - 90% y una reducción del 0.18% en 80% - 90%, con lo que se demuestra la efectividad de los algoritmos, pues cada uno encontró una solución similar que mejoró el EMS.




Figura 27. Comparación de Rangos de SOC, PSO vs CSA

El segundo punto que se aborda es la reducción de las fluctuaciones del perfil de potencia intercambiada desde la microrred hacia la red eléctrica. Al implementar el algoritmo PSO al EMS, se alcanza la contracción del perfil, como se puede observar en la Figura 28, además esta muestra los puntos máximos y mínimos alcanzados en cada caso. Conjuntamente la reducción del perfil de potencia influye directamente en las rampas de perfil de potencia, alcanzando una disminución del MPD del 42.18%, como se observa en la Figura 29.




Figura 28. Comparación de perfiles de potencia intercambiada, PSO vs métodos heurísticos




Figura 29. Comparación de Rampas de Perfil de Potencia, vs Métodos Heurísticos

Al realizar un acercamiento de la Figura 28, se puede observar en la Figura 30 que en la mayoría de muestras existe un mayor acercamiento al cero al usar PSO, con lo que se puede constatar la reducción del perfil de potencia.




Figura 30. Acercamiento del perfil de potencia PSO vs métodos heurísticos

En el caso de la comparación de perfil de potencia obtenido por el PSO vs CSA, se tiene la Figura 31, la cual muestra que la contracción del perfil de potencia obtenido en ambos casos es similar. Sin embargo, la diferencia es más notoria en cuanto a las rampas de perfil de potencia como se puede observar en la Figura 32 mientras el PSO alcanzó una reducción del MPD del 42.18%, el CSA la superó en un 2%, alcanzando una disminución del 44.17%.

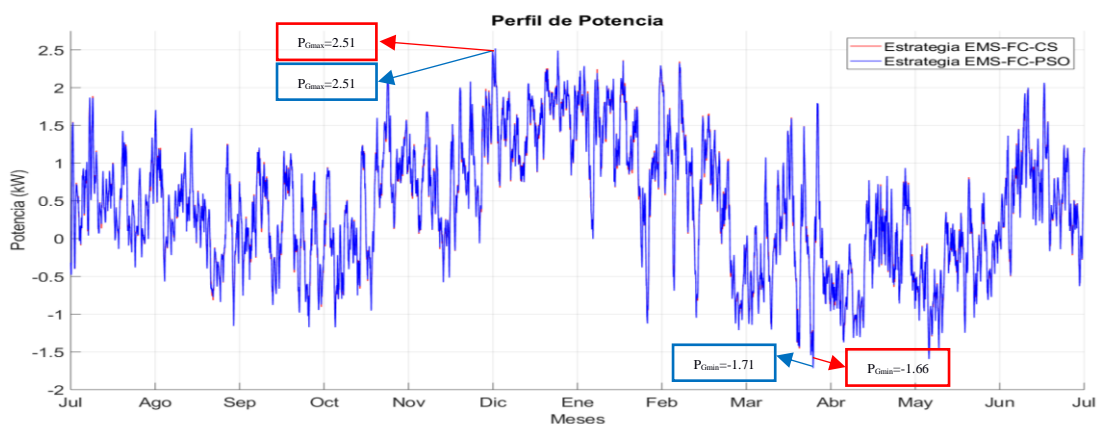


Figura 31. Comparación de perfiles de potencia intercambiada, PSO vs CSA




Figura 32. Comparación de Rampas de Perfil de Potencia, vs CSA

De igual forma que en la comparación del perfil de potencia obtenido por PSO vs métodos heurísticos, un acercamiento en la misma región que la de la Figura 30, permite mostrar los resultados obtenidos por el PSO y el CSA, de la Figura 32 son similares, validando así la reducción del perfil de potencia de ambos algoritmos.

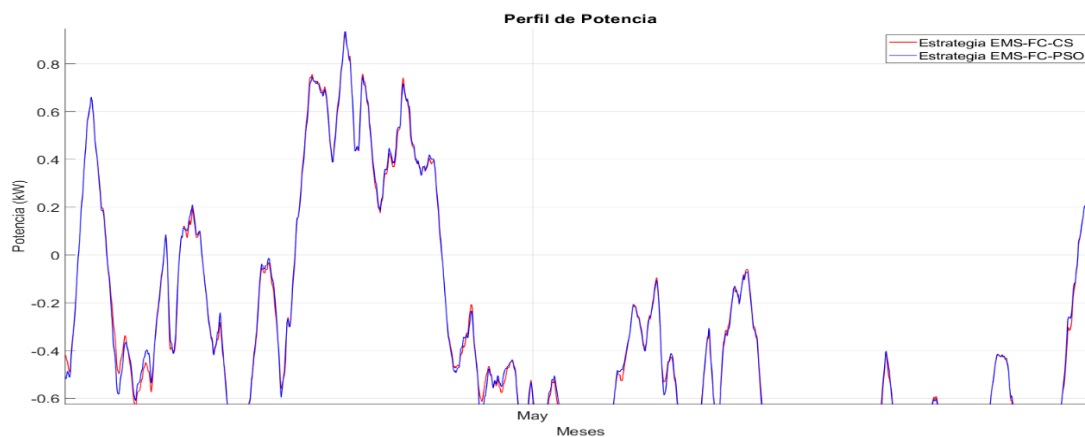


Figura 33. Acercamiento del perfil de potencia PSO vs CSA

A continuación, en la Tabla 18 se muestra en resumen los parámetros de calidad obtenidos mediante métodos por métodos heurísticos, CSA y PSO. En donde se ve reflejada la efectividad de

los algoritmos de optimización frente a un problema de optimización complejo, pues se logró disminuir los valores de los parámetros de calidad de la EMS planteados inicialmente en (Arcos-Aviles D. , y otros, 2018).

Tabla 18
Comparación de los criterios de calidad de EMS

	$P_{G,MAX}[kW]$	$P_{G,MIN}[kW]$	$MPD[W/h]$	$APD[W/h]$	PVR	PPV
Fuzzy EMS-FC	2.56	-1.89	846	0.34	75	1.26
Fuzzy EMS-FC-CSA	2.51	-1.66	472	0.32	75	1.25
Fuzzy EMS-FC-PSO	2.51	-1.71	489.44	0.32	76	1.26

La Tabla 19 muestra la variación porcentual que ha obtenido cada uno de los algoritmos de optimización ejecutados PSO y CSA, donde los valores con signo negativo, reflejan la mejora de los parámetros con respecto a los presentados en (Arcos-Aviles D. , y otros, 2018), mientras que los de signo positivo muestran un incremento en los mismos. Se puede observar que la similitud de los resultados se mantiene en un rango aceptable pues la variación de estos no supera el 2.89%.

Tabla 19
Variación porcentual de los criterios de calidad de EMS

	$P_{G,MAX}\%$	$P_{G,MIN}\%$	$MPD\%$	$APD\%$	$PVR\%$	$PPV\%$
Fuzzy EMS-FC-CSA	-2.07	-12.28	-44.17	-6.80	0.25	-1.13
Fuzzy EMS-FC-PSO	-1.71	-9.39	-42.18	-4.97	0.98	0.16
Diferencia absoluta CSA vs PSO	0.36	2.89	1.99	1.83	0.73	1.29

En cuanto al tiempo de convergencia de los algoritmos tanto del PSO presentado en este documento como del CSA de (García-Gutiérrez, 2019), existe una gran diferencia, tal como se puede observar en la Tabla 20, pues el PSO converge en 10.54 horas mientras que el CSA lo hace

en 85.5. Demostrando así, que para obtener un resultado aceptable el uso del PSO ahorro hasta 69.96 horas en comparación al CSA, lo que equivale a una mejora del 86.91% del tiempo de convergencia. Cabe destacar que el número de partículas del PSO es semejante al número de nidos del CSA. Además, es menester conocer que, para esta comparación, ambos algoritmos fueron ejecutados en el mismo computador, bajo las mismas condiciones.

Tabla 20

Tiempo de convergencia del PSO y CSA

Algoritmo	N° Partículas/ Nidos	Tiempo por Iteración (min)	Convergencia (Iteración N°)	Tiempo de Convergencia (horas)
Fuzzy EMS-FC-PSO	5	3.1	204	10.54
Fuzzy EMS-FC-CSA	25	16.1	300	80.5

CAPITULO V: CONCLUSIONES Y RECOMENDACIONES

7.1 Conclusiones

- Con la ejecución del algoritmo PSO diseñado, se concluye que para una correcta sintonización de parámetros del FLC, tanto en funciones de pertenencia como la base de reglas, es necesario limitar la variación máxima que puede tener las variables en cada iteración, para que de esta forma se alcancen los mejores resultados posibles.
- Al haber implementado el algoritmo PSO a la EMS de estudio, se logró comprimir la el perfil de potencia intercambiado, reduciendo así los valores de pico máximo y mínimo con respecto al perfil obtenido mediante métodos heurísticos al igual que los criterios de calidad planteados para la función de costo.
- El algoritmo PSO en su mejor versión consiguió mejorar los siguientes parámetros de calidad de la EMS de estudio: $P_{G,MAX}$ en 1.71%, $P_{G,MIN}$ en 9.39%, MPD en - 42.18% y APD en 4.97%. Aunque, no logró mejorar los restantes, provocando un incremento del 0.98% en el PVR y del 0.16% en el PPV. Sin embargo, no logró superar los resultados de los criterios de calidad obtenidos por el CSA.
- Al comparar los resultados de los criterios de calidad obtenidos mediante el algoritmo PSO vs CSA, se constató que existe una gran similitud en los mismos, con una diferencia absoluta que no supera el 2.89%. Cabe destacar que ambos algoritmos reflejan una mejora de dichos criterios, con mejoras superiores al 40% como es el caso del MPD. Además, ambas coinciden en el incremento del PVR.

- El tiempo de convergencia del PSO superó al del CSA, con una mejora de 69.96 horas, en otras palabras, se necesita 86.91% menos tiempo para alcanzar un resultado aceptable para el EMS del caso de estudio.

7.2 Recomendaciones

- Para el diseño de algoritmos PSO que buscan determinar los parámetros óptimos de un FLC, se debe evitar que la variación máxima de las variables en cada iteración no supere el $\pm 5\%$ del total del rango del universo de discurso.
- Para ejecuciones fuera de línea se recomienda ejecutar por varias ocasiones el algoritmo, para así asegurar que el resultado global alcanzado sea el más óptimo, Esto debido a que, al ser un algoritmo metaheurístico, se pueden alcanzar nuevas soluciones aleatorias que generen un resultado global óptimo como uno no aceptable para el problema de optimización, pues se pueden estancar en mínimos locales.
- Para la aplicación de algoritmos que busquen dar soluciones óptimas a problemas de optimización complejos, se recomienda utilizar dispositivos con alta velocidad de procesamiento, lo cual conlleva a un ahorro de tiempo, el cual puede ir desde: horas, días e incluso hasta semanas.
- En aplicaciones complejas en las que se requiera un resultado aceptable de optimización en tiempos cortos, se recomienda usar el algoritmo PSO. Mientras que para aplicaciones que necesiten el resultado más óptimo y que el tiempo no sea un obstáculo se recomienda usar el CSA.

7.3 Reconocimientos

Este trabajo es parte del proyecto 2019-PIC-003-CTE titulado: “Ajuste de los parámetros del controlador Fuzzy Logic del sistema de gestión energética de una microrred doméstica conectada a red mediante algoritmos de optimización inspirados en la naturaleza” del Grupo de Investigación en Propagación Control Electrónico y Networking (PROCONET) de la Universidad de las Fuerzas Armadas ESPE.

BIBLIOGRAFÍA

- Aranda, J., & Orjuela, J. (2015). *redalyc.org*. Obtenido de Google Scholar: <https://www.redalyc.org/pdf/4988/498850180004.pdf>
- Arcos-Aviles, D., García-Gutiérrez, G., Guinjoan, F., Carrera, E. V., Pascual, J., Ayala, P., . . . Motoasca, E. (2019). Adjustment of the Fuzzy Logic controller parameters of the energy management strategy of a grid-tied domestic electro-thermal microgrid using the Cuckoo search algorithm. *IECON 2019 - 45th Annual Conference of the IEEE Industrial Electronics Society*, (págs. 115-121).
- Arcos-Aviles, D., Guinjoan, F., Pascual, J., Marroyo, L., Gordillo, R., Sanchis, P., . . . Ibarra, A. (2018). Fuzzy-based energy management of a residential electro-thermal microgrid based on power forecasting. *IECON 2018 - 44th Annual Conference of the IEEE Industrial Electronics Society*, (págs. 1824-1829). Washington, DC, USA. doi:10.1109/IECON.2018.8591575
- Arcos-Aviles, D., Guinjoan, F., Pascual, J., Marroyo, L., Sanchis, P., Gordillo, R., . . . Marietta, M. (2018). A review of fuzzy-based residential grid-connected microgrid energy management strategies for grid power profile smoothing. En E. Motoasca, A. Agarwal, & H. Breesch, *Energy sustainability in built and urban environments* (págs. 165-199). Berlin: Springer.
- Arcos-Aviles, D., Pascual, J., Guinjoan, F., Marroyo, L., Sanchis, P., & Marietta, M. P. (2017). Low complexity energy management strategy for grid profile smoothing of a residential grid-connected microgrid using generation and demand forecasting. *IEEE 26th Int. Symp. Ind. Electron*, 99-105.
- Arcos-Aviles, D., Pascual, J., Guinjoan, F., Marroyo, L., Sanchis, P., & Martin, P. . (2017). Low complexity energy management strategy for grid profile smoothing of a residential grid-connected microgrid using generation and demand forecasting. En *Applied Energy* (págs. 69-84).
- Arcos-Aviles, D., Pascual, J., Marroyo, L., Sanchis, P., & Guinjoan, F. (2016). Fuzzy Logic-Based Energy Management System Design for Residential Grid-Connected Microgrids. *IEEE Trans. Smart Grid*, 1-1.
- Arcos-Aviles, D., Pascual, J., Marroyo, L., Sanchis, P., & Guinjoan, F. (March de 2018). Fuzzy Logic-Based Energy Management System Design for Residential Grid-Connected Microgrids. *IEEE Transactions on Smart Grid*, 9(2), 530-543.
- Arcos-Aviles, D., Pascual, J., Marroyo, L., Sanchis, P., Guinjoan, F., & Marietta, M. P. (2015). Optimal Fuzzy Logic EMS design for residential grid-connected microgrid with hybrid renewable generation and storage. *2015 IEEE 24th International Symposium on Industrial Electronics (ISIE)*, (págs. 742-747). Buzios, Brasil. doi:10.1109/ISIE.2015.7281561

- Arcos-Aviles, D., Sotomayor, D., Proaño, J. L., Guinjoan, F., Marietta, M. P., Pascual, J., . . . Sanchis, P. (2017). Fuzzy energy management strategy based on microgrid energy rate-of-change applied to an electro-thermal residential microgrid. *2017 IEEE 26th International Symposium on Industrial Electronics (ISIE)*, (págs. 99-105). Edinburgh, UK. doi:10.1109/ISIE.2017.8001230
- Bevrani, H., Habibi, F., Babahajyani, P., Watanabe, M., & Mitani, Y. (2012). Intelligent Frequency Control in an AC Microgrid: Online PSO-Based Fuzzy Tuning Approach. *IEE Transactions on Smart Grid*, 3(4), 1935-1944.
- Bingül, Z., & Karahan, O. (2011). A Fuzzy Logic Controller tuned with PSO for 2 DOF robot trajectory control. *Expert Systems with Applications*, 38, 1017-1031.
- Chen, Y.-K., Wu, Y.-C., Song, C.-C., & Chen, Y.-S. (2013). Design and Implementation of Energy Management System With Fuzzy Control for DC Microgrid Systems. *IEEE Transactions on Power Electronics*, 28, 1563 - 1570.
- Corvea, L. R., García, Y. R., & Cardoso, G. C. (2012). Optimización basada en enjambres de partículas para ajustar los parámetros de los métodos scan. *Investigación Operacional*, 23-28.
- Eberhart, R., & Kennedy, J. (1995). Particle Swarm Optimization. *International Conference on Neural Networks* (págs. 1942-1948). Perth, WA, Australia, Australia: IEEE.
- Eberhart, R., & Shi, Y. (2001). Particle Swarm Optimization: Developments, Applications and Resources. *IEEE Conference on Evolutionary Computation*, 1, págs. 81-86.
- Energía, A. A. (2014). *Estrategia Energética Andalucía 2020*. Andalucía: Junta de Andalucía.
- Esmin, A., Aoki, A., & Lambert-Torres, G. (2002). Optimization For Fuzzy Membership Functions Optimization. *IEEE International Conference on Systems, Man and Cybernetics*, 3, pág. 6. Yasmine Hammamet, Tunisia, Tunisia. doi:10.1109/ICSMC.2002.1176020
- Fahad, M., Elbouchikhi, E., & Benbouzid, M. (2018). Microgrids energy management systems: A critical review on methods, solutions, and prospects. *ScienceDirect*, 222, 1033-1055.
- García-Gutiérrez, G. (2019). *Ajuste de los parámetros del controlador fuzzy logic del sistema de gestión energética de una microrred electrotérmica doméstica conectada a red mediante el algoritmo de búsqueda de cuckoo*. Sangolquí: ESPE.
- García-Gutiérrez, G., Arcos-Aviles, D., Carrera, E., Gispert, F., Motoasca, E., Ayala, P., & Ibarra, A. (2019). Fuzzy Logic Controller Parameter Optimization Using Metaheuristic Cuckoo Search Algorithm for a Magnetic Levitation System. *Applied Sciences*, 9(12). doi:10.3390/app9122458

- Gharibi, H., Mahvi, A. H., Nabizade, R., Arabalibeik, H., Yunesian, M., & Sowlatf, M. H. (2012). A novel approach in water quality assessment based on fuzzy logic. *Journal of Environmental Management*, 112, 87-95.
- Gutierrez, E. A. (2018). *Estrategia para la Gestión Eficiente de los Recursos Energéticos en la Universidad Nacional de Colombia- Sede Bogotá*. Bogotá: Universidad Nacional de Colombia.
- Jamaludin, J., Rahim, N., & Hew, W. (2009). Development of a self-tuning fuzzy logic controller for intelligent control of elevator systems. *Engineering Applications of Artificial Intelligence*, 22, 1167-1178.
- Kanchev, H., Lu, D., Colas, F., Lazarov, V., & Francois, B. (2011). Energy Management and Operational Planning of a Microgrid With a PV-Based Active Generator for Smart Grid Applications. *IEEE Transactions on Industrial Electronics*, 4583-4592.
- Lasseter, R. (2002). MicroGrids. *IEEE Power Engineering Society Winter Meeting*, (pág. 305). New York.
- Lee, C. (1990). Fuzzy logic in control systems: fuzzy logic controller. I. *IEEE Transactions on Systems, Man, and Cybernetics*, 404-418.
- Loor, G., Cuenca, L., Castro, M., & Vilaragout, M. (2017). Roadmap for the introduction of smart grids in Ecuador. *International Journal of Physical Sciences and Engineering*, 1(2), 1-10.
- Luna, G. M. (17 de febrero de 2002). *casanchi.com*. Obtenido de <http://casanchi.com/mat/intrologicadifusa01.pdf>
- Mahmoud, T., Habibi, D., & Bass, O. (2012). Fuzzy Logic for Smart Utilisation of Storage Devices in A Typical Microgrid. *2012 International Conference on Renewable Energy Research and Applications (ICRERA)*, (págs. 1-6). Nagasaki. doi:10.1109/ICRERA.2012.6477333
- Martínez-Vargas, A., & León, M. D. (Enero de 2017). *Algoritmos inspirados en la naturaleza para solucionar problemas difíciles*. Obtenido de ResearchGate: https://www.researchgate.net/publication/312940534_Algoritmos_inspirados_en_la_naturaleza_para_solucionar_problemas_dificiles
- Najera H, M. C. (2003). *Design of an analytical aggregation of rules of a diffuse controller and its application in the model of a nuclear research reactor*. México: SEP. Instituto Tecnológico de Tuxtla Gutierrez.
- Nicos, H. (2014). *MicroGrids Architecture and Control*. UK: Wiley.

- Olivares, D. E., Mehrizi-Sani, A., Etemadi, A. H., Cañizares, C. A., Iravani, R., Kazerani, M., . . . Hatziargyriou, N. D. (2014). Trends in Microgrid Control. *IEEE Transactions on Smart Grid*, 5, 1905 - 1919.
- Pascual, J., Barricarte, J., Sanchis, P., & Marroyo, L. (2015). Energy management strategy for a renewable-based residential microgrid with generation and demand forecasting. *Applied Energy*, 158, 12-25.
- Pascual, J., Sanchis, P., & Marroyo, L. (2014). Implementation and Control of a Residential Electrothermal Microgrid Based on Renewable Energies, a Hybrid Storage System and Demand Side Management. . *Energies*, 7(1), 210-237.
- Passino, K. M., & Yurkovich, S. (1998). *Fuzzy Control*. California: Addison Wesley Longman,.
- Ricardo Martínez-Soto, O. C. (2014). Type-1 and Type-2 fuzzy logic controller design using a Hybrid PSO–GA optimization method. *Information Sciences*, 285, 35-49.
- Rodríguez, L., Ponce, I., & Espitia, H. (2015). Sistema de inferencia difusa para la modificación de color ajustado empleando enjambre de partículas. *Revista de Investigaciones - Universidad del Quindío*, 27(1), 46-53.
- Su, W., & Wang, J. (2012). Energy Management Systems in Microgrid Operations. *The Electricity Journal*, 45-60.
- Taruwona, M., & Nyirenda, C. N. (2018). Particle Swarm Optimization of a Mamdani Fuzzy Logic Based Charge Controller for Energy Storage Systems. *IEEE*, 73-78. doi:10.1109/OI.2018.8535687
- Venayagamoorthy, G., & Doctor, S. (2004). Navigation of mobile sensors using PSO and embedded PSO in a fuzzy logic controller. *Industry Applications Conference*. 2, págs. 1200-1206. Seattle: IEEE. doi:10.1109/IAS.2004.1348565
- Yang, X.-S. (2014). *Nature-Inspired Optimization Algorithms*. London: Elsevier.
- Yang, X.-S., Dey, N., & Fong, S. J. (2019). *Springer Tracts in Nature-Inspired Computing*. Springer.
- Zang, H., Zhang, S., & Hapeshi, K. (2010). A Review of Nature-Inspired Algorithms. *Journal of Bionic Engineering*, 7, S232–S237.
- Zatarain, O. (18 de Mayo de 2011). *Universidad Autónoma del Estado de México*. Obtenido de https://www.uaeh.edu.mx/docencia/P_Presentaciones/icbi/assignatura/logicaDifusa.pdf