



**DEPARTAMENTO DE ELÉCTRICA, ELECTRÓNICA Y
TELECOMUNICACIONES**

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

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

**TEMA: “OPTIMIZACIÓN DE PARÁMETROS DE UN
CONTROLADOR EN LÓGICA DIFUSA PARA UNA
MICRORRED DE USO RESIDENCIAL MEDIANTE EL
ALGORITMO EVOLUCIÓN DIFERENCIAL”**

AUTOR: PEREIRA PROAÑO, MARÍA DANIELA

DIRECTOR: DR. ARCOS AVILES, DIEGO GUSTAVO

SANGOLQUÍ

2020



**DEPARTAMENTO DE ELÉCTRICA, ELÉCTRONICA Y
TELECOMUNICACIONES**

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

CERTIFICACIÓN

Certifico que el trabajo de titulación, “OPTIMIZACIÓN DE PARÁMETROS DE UN CONTROLADOR EN LÓGICA DIFUSA PARA UNA MICRORRED DE USO RESIDENCIAL MEDIANTE EL ALGORITMO EVOLUCIÓN DIFERENCIAL” fue realizada por el señorita Pereira Proaño, María Daniela 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, 09 de enero del 2020

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, Pereira Proaño, María Daniela, declaro que el contenido, ideas y criterios del trabajo de titulación: **“OPTIMIZACIÓN DE PARÁMETROS DE UN CONTROLADOR EN LÓGICA DIFUSA PARA UNA MICRORRED DE USO RESIDENCIAL MEDIANTE EL ALGORITMO EVOLUCIÓN DIFERENCIAL”** 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, 09 de enero del 2020

Firma:

Pereira Proaño, María Daniela

C.C.: 171541877-6



**DEPARTAMENTO DE ELÉCTRICA, ELÉCTRONICA Y
TELECOMUNICACIONES**

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

AUTORIZACIÓN

Yo, Pereira Proaño, María Daniela, autorizo a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de titulación: **“OPTIMIZACIÓN DE PARÁMETROS DE UN CONTROLADOR EN LÓGICA DIFUSA PARA UNA MICRORRED DE USO RESIDENCIAL MEDIANTE EL ALGORITMO EVOLUCIÓN DIFERENCIAL”** en el Repositorio Institucional, cuyo contenido, ideas y criterios son de mi responsabilidad.

Sangolquí, 09 de enero del 2020

Firma:

Pereira Proaño, María Daniela

C.C.: 171541877-6

DEDICATORIA

Dedico este trabajo a mi abuelita Aida, por su apoyo constante y su amor durante el tiempo que estuvo, ahora es la estrella más bonita del cielo.

A mi mamá, por estar conmigo en todo momento y hacer suyos mis logros y fracasos en toda mi carrera profesional.

A mis hermanas por su amistad y compañía incondicional.

A mi tía, mi abuelo y mi Blanquita por su cariño, ánimos durante todos estos años y los que faltan por venir.

María Daniela Pereira Proaño

AGRADECIMIENTO

Agradezco a Dios por permitirme culminar un paso más en mi vida.

A mi tutor el Dr. Diego Arcos Avilés por su apoyo y aporte para la realización de este trabajo

A mis amigos, en especial a Santi que me ayudó a buscar soluciones para culminar este trabajo con éxito.

Gracias a todos.

María Daniela Pereira Proaño

ÍNDICE DE CONTENIDO

CERTIFICACIÓN	i
AUTORÍA DE RESPONSABILIDAD	ii
AUTORIZACIÓN	iii
DEDICATORIA	iv
AGRADECIMIENTO	v
ÍNDICE DE CONTENIDO	vii
ÍNDICE DE TABLAS	ixx
ÍNDICE DE FIGURAS	x
RESUMEN	xii
ABSTRACT	xiii
CAPITULO 1	
INTRODUCCIÓN	1
1.1. Antecedentes	1
1.2. Justificación e importancia	2
1.3. Alcance del proyecto	4
1.4. Objetivos General y Específicos	4
1.4.1. Objetivo General	4
1.4.2. Objetivos específicos	5
CAPITULO 2	
MARCO TEÓRICO	6
2.1 Algoritmos inspirados en la naturaleza	6
2.2 Algoritmo de Evolución Diferencial	7
2.3 Mutación cruce y selección en DE	8
2.4 Selección de parámetros	10
2.5 Controladores Fuzzy Logic	11
2.6 Sistemas de gestión energética (EMS)	12
2.7 Descripción de la microrred electrotérmica	12
CAPITULO 3	

DESARROLLO DEL ALGORITMO DE EVOLUCIÓN DIFERENCIAL	14
3.1. Descripción del caso de estudio	14
3.2. Diseño del algoritmo de optimización de Evolución Diferencial	16
3.3. Función de costo de criterios de calidad para evaluación estrategia de gestión.....	23
CAPITULO 4	
PRUEBAS Y RESULTADOS	24
4.1 Valores de referencia para propósitos de comparación.....	24
4.1.1 Valores de referencia optimización Cuckoo	24
4.1.2 Valores de referencia optimización PSO.....	28
4.2 Resultados de simulaciones numéricas	32
4.3 Ventajas y desventajas del algoritmo DE.....	36
4.4 Tiempo de ejecución del algoritmo DE.....	37
4.5 Comparación de los resultados obtenidos a través de la optimización del FLC con el algoritmo DE vs Algoritmo de CS y PSO.	37
CAPITULO 5	
CONCLUSIONES Y RECOMENDACIONES	51
5.1. Conclusiones	51
5.2. Recomendaciones.....	52
5.3. Reconocimientos	52
BIBLIOGRAFÍA	53

ÍNDICE DE TABLAS

Tabla 1 <i>Parámetros de las variables de entrada</i>	18
Tabla 2 <i>Base de Reglas Inicial del Controlador</i>	19
Tabla 3 <i>Base de reglas de EMS-FC con algoritmo de optimización CS</i>	26
Tabla 4 <i>Criterios de calidad de la gestión energética Estrategia EMS-FC con CS</i>	28
Tabla 5 <i>Base de reglas de EMS-FC con algoritmo de optimización PSO</i>	30
Tabla 6 <i>Criterios de calidad de la gestión energética Estrategia EMS-FC con PSO</i>	32
Tabla 7 <i>Posiciones de MF para la entrada P_E mediante DE</i>	33
Tabla 8 <i>Posiciones de MF para la entrada SOC mediante DE</i>	34
Tabla 9 <i>Posiciones de MF y rango de salida para la variable P_{FLC}</i>	35
Tabla 10 <i>Base de reglas de EMS-FC optimizada por DE</i>	36
Tabla 11 <i>Tiempo de ejecución Cuckoo, PSO y DE</i>	37
Tabla 12 <i>Parámetros de funciones de pertenencia y rango de la Salida del FLC por CS</i>	42
Tabla 13 <i>Parámetros de funciones de pertenencia y rango de la Salida del FLC por PSO</i>	42
Tabla 14 <i>Comparación de los criterios de calidad de EMS</i>	49

ÍNDICE DE FIGURAS

Figura 1 Representación Esquemática de vectores de mutación en evolución diferencial con movimiento $\delta = F(x_q - x_r)$	8
Figura 2 Arquitectura de un Controlador Fuzzy Logic.....	11
Figura 3 Arquitectura de la microrred electrotérmica de estudio.....	13
Figura 4 Microrred electrotérmica residencial conectada a la red residencial.....	15
Figura 5 Funciones de pertenencia entrada P_E y SOC respectivamente para calcular la dimensión del problema.	17
Figura 6 Funciones de pertenencia entrada P_{FLC} para calcular la dimensión del problema.....	18
Figura 7 Ejemplo de la generación de los vectores y proceso del algoritmo DE.....	20
Figura 8 Pseudocódigo del algoritmo DE	21
Figura 9 Diagrama de Flujo del algoritmo DE implementado.....	22
Figura 10 MF ajustadas para la entrada P_E mediante el algoritmo CS.....	25
Figura 11 MF ajustadas para la entrada SOC mediante el algoritmo CS.....	25
Figura 12 MF ajustadas para la salida P_{FLC} mediante el algoritmo CS	26
Figura 13 SOC de la batería y rangos. Estrategia EMS-FC con CS	27
Figura 14 Perfil de potencia intercambiado con la red eléctrica. Estrategia EMS-FC con CS.....	27
Figura 15 Rampas del perfil de potencia intercambiado. Estrategia EMS-FC con CS.....	28
Figura 16 MF ajustadas para la entrada P_E mediante el algoritmo PSO.....	29
Figura 17 MF ajustadas para la entrada SOC mediante el algoritmo PSO	29
Figura 18 MF ajustadas para la salida P_{FLC} mediante el algoritmo PSO	30
Figura 19 SOC de la batería y rangos. Estrategia EMS-FC con PSO.....	31
Figura 20 Perfil de potencia intercambiado con la red eléctrica. Estrategia EMS-FC con PSO ..	31
Figura 21 Rampas del perfil de potencia intercambiado. Estrategia EMS-FC con PSO	32
Figura 22 MF ajustadas para la entrada P_E mediante el algoritmo DE.....	33
Figura 23 MF ajustadas para la entrada SOC mediante el algoritmo DE	34
Figura 24 MF ajustadas para la salida P_{FLC} mediante el algoritmo DE	35
Figura 25 MF ajustadas entrada P_E , DE vs CS	38
Figura 26 MF ajustadas entrada P_E , DE vs PSO	39

Figura 27 MF ajustadas entrada SOC , DE vs CS.....	39
Figura 28 MF ajustadas entrada SOC , DE vs PSO	40
Figura 29 MF ajustadas salida P_{FLC} , DE vs CS	41
Figura 30 MF ajustadas salida P_{FLC} , DE vs PSO.....	41
Figura 31 Superficie EMS-PSO, EMS-CS y EMS-DE.....	43
Figura 32 Comparación de perfil de red y SOC de batería entre EMS-DE, EMS-CS y EMS-PSO con picos máximos	45
Figura 33 Comparación de perfil de red y SOC de batería entre EMS-DE, EMS-CS y EMS-PSO con picos mínimos.....	46
Figura 34 Resultados de la simulación SOC promedio diario EMS-DE, EMS-PSO y EMS-CS .	47
Figura 35 Comparación de la evolución SOC en el mes de septiembre 2013	48
Figura 36 Histograma (en %) de los rangos de batería SOC establecidos para EMS-DE, EMS-CS y EMS-PSO	49

RESUMEN

Las fuentes de energía renovables han surgido como una alternativa para satisfacer la creciente demanda energética, mitigar el cambio climático y contribuir al desarrollo sostenible. Debido al desarrollo de nuevas tecnologías para los sistemas de energía basados en la energía renovable, nuevos conceptos aparecen como las microrredes (MG), las cuales son una alternativa prometedora ya que se espera que las MG coexistan con las redes eléctricas tradicionales. La planificación de una microrred es un proceso complejo debido a las alternativas que existen, limitaciones e incertidumbres, por ejemplo, conseguir mediante la gestión energética, la minimización de los picos y fluctuaciones del perfil de potencia que una MG intercambia con la red eléctrica. Como consecuencia de lo anterior aparecen diferentes problemas de optimización a ser solventados, específicamente para el caso de estudio, se implementan soluciones mediante procesos heurísticos y estrategias de Lógica Difusa (Fuzzy Logic). Sin embargo, el costo computacional y el tiempo requerido en el proceso son elevados, por lo que el presente trabajo propone implementar el algoritmo de Evolución Diferencial (DE) inspirado en la naturaleza para el ajuste de los parámetros del controlador de la MG y la optimización de la estrategia de gestión energética. Adicional se realiza un estudio comparativo entre otros dos algoritmos de optimización (Cuckoo Search y PSO).

PALABRAS CLAVE:

- **EVOLUCION DIFERENCIAL**
- **CONTROLADOR LÓGICA DIFUSA**
- **MICRORRED**
- **ESTRATEGIA DE GESTIÓN ENERGÉTICA**

ABSTRACT

Renewable energy sources have emerged as an alternative to meet the growing demand for energy, mitigate climate change and contribute to sustainable development. Due to the development of new technologies for energy systems from renewable energy, new concepts appear in modern energy systems such as microgrids (MG) are a promising alternative since MGs are expected to coexist with traditional power grids. The planning of a microgrid is a complex process due to the alternatives that exist, limitations and uncertainties, for example, achieving energy management by minimizing the peaks and fluctuations in the power profile that a micro-network exchanges with the power grid. As a consequence, different optimization problems appear. In the case of study, heuristic processes and fuzzy logic strategies are implemented. However, the computational cost and the time required in the process are higher, so the present work proposes to implement the algorithm of Differential Evolution (DE) inspired by nature for the adjustment of the parameters of the MG controller and the optimization of the energy management strategy. In addition, a comparative study is carried out between two other optimization algorithms (Cuckoo Search and PSO).

KEYWORDS:

- **DIFFERENTIAL EVOLUTION**
- **FUZZY LOGIC CONTROLLER**
- **MICROGRID**
- **ENERGY MANAGEMENT STRATEGY**

CAPITULO 1

INTRODUCCIÓN

1.1. Antecedentes

La sociedad moderna depende en gran medida del suministro de energía eléctrica. La demanda exponencial de esta ha llevado al agotamiento de los combustibles fósiles como el petróleo y carbón (Vera, Dufo-López, & Bernal-Agustín, 2019). Esto a su vez, ha producido un incremento de los gases de efecto invernadero. Se estima que la demanda mundial de energía crecerá en más de un cuarto para el 2040, cuando se espera que las fuentes de energía renovables (RES- Renewable Energy Sources) representen el 40% de la combinación energética global (Wu et al., 2016). De acuerdo a las estadísticas energéticas de la Agencia Internacional de Energía (IEA-International Energy Agency), la dependencia de energía ha aumentado los últimos 40 años, sin embargo, los sistemas de energía eléctrica no han mejorado de manera significativa durante décadas para sustentar este incremento de consumo energético.

Gracias al desarrollo de nuevas tecnologías para los sistemas energéticos, aparecen nuevos conceptos en los sistemas de energía modernos. Uno de estos conceptos es el de microrred (MG), la cual es una nueva estructura de red eléctrica basada en RES, recursos de generación distribuida (DER), electrónica de potencia y tecnologías de información y comunicaciones (TICs). La microrred fue definida por el Consorcio de Soluciones Tecnológicas de Confiabilidad Eléctrica (CERTS) en 1998 como *“Grupos de generadores que incluyen la recuperación de calor, almacenamiento y cargas, que funcionan como elementos controlables únicos”*. Para el 2002 Lasseter definió a la MG como: *“El conjunto de micro fuentes, cargas y sistemas de*

almacenamiento que operan con un único sistema controlable que puede responder a señales de un controlador central” (Lasseter, 2002).

Debido a la naturaleza modular de las MG, estas pueden funcionar de forma independiente o en conjunto con la red eléctrica principal. Las MGs son una solución para modernizar gradualmente las redes eléctricas existentes.

Las MGs cuentan con un sistema de gestión energética (EMS) que regulan el flujo de potencia a través de todos los elementos de la misma, de acuerdo a los objetivos que esta persiga, las cargas que pueda gestionar y su arquitectura, por ejemplo, maximizar ingresos, minimizar consumo, incrementar eficiencia, etc. (Diego Arcos-Aviles, Pascual, Marroyo, Sanchis, & Guinjoan, 2018).

Una vez definida la arquitectura de la MG, se realiza el diseño de la EMS. Una estrategia adecuada vinculada al EMS proporciona un rendimiento eficiente de la MG, por esta razón se han desarrollado varias estrategias de gestión energética en los últimos años con el objetivo de cubrir una serie de objetivos diferentes (Meng et al., 2016; Olatomiwa, Mekhilef, Ismail, & Moghavvemi, 2016).

1.2. Justificación e importancia

En trabajos previos (D. Arcos-Aviles et al., 2016; Diego Arcos-Aviles et al., 2017; Diego Arcos-Aviles, Pascual, et al., 2018), se desarrollaron varias estrategias de gestión energética, que tenían como objetivo la minimización de los picos, fluctuaciones y rampas del perfil de potencia que una MG intercambia con la red eléctrica. Estas estrategias se basan en un controlador de lógica difusa, donde el ajuste de los parámetros del controlador como: tipo de funciones de pertenencia (MF – Membership Function), número de MFs por entrada/salida, mapeo (i.e., ubicación de cada MF

dentro del rango establecido para cada entrada/salida), y base de reglas; se lo realiza por métodos heurísticos, es decir, un proceso de prueba y error, con el objetivo de minimizar criterios de calidad definidos en (Pascual, Barricarte, Sanchis, & Marroyo, 2015; Pascual, Sanchis, & Marroyo, 2014).

Pese a que los resultados obtenidos en estos trabajos fueron satisfactorios, el proceso de ajuste heurístico es extenso en cuanto a tiempo y es realizado fuera de línea.

Con el objetivo de mejorar dicho proceso de ajuste de parámetros del controlador, optimizar la estrategia de gestión energética basada en el controlador de lógica difusa y reducir el tiempo de ejecución, se propone un algoritmo de optimización inspirado en la naturaleza, en este caso el algoritmo de evolución diferencial (DE). El algoritmo de Evolución Diferencial es un algoritmo de optimización inspirado en la naturaleza desarrollada por Rainer Storn y Kenneth Price, se utiliza este algoritmo por su estructura simple, facilidad de uso, velocidad y robustez y es uno de los mejores algoritmos de tipo genético para resolver problemas con variables de valor real. Se ha utilizado en aplicaciones científicas y de ingeniería para descubrir soluciones efectivas a problemas casi intratables sin recurrir al conocimiento experto.

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.

La optimización por evolución diferencial forma parte de un conjunto de algoritmos metaheurísticos de optimización inspirados en la naturaleza: algoritmo de abejas (BA-Bees Algorithm), algoritmo de Búsqueda Cuckoo, optimización por colonia de hormigas, entre otros (Fister, Yang, Brest, & Fister, 2013; Zang, Zhang, & Hapeshi, 2010).

1.3. Alcance del proyecto

De acuerdo con lo expuesto en la sección anterior, se tomará como base los parámetros y datos reales de la microrred perteneciente a la Universidad Pública de Navarra durante el periodo comprendido entre julio de 2013 a julio de 2014 con un periodo de muestreo de $T_s = 900$ s (Diego Arcos-Aviles et al., 2019; Diego Arcos-Aviles, Pascual, et al., 2018). Se valorará los resultados del perfil de red y criterios de calidad obtenidos con el algoritmo DE. Se considerará también la función de costo global definida en trabajos anteriores (García-Gutiérrez, 2018) por motivos de comparación. Esta función de costo comprende todos los criterios para la evaluación de la calidad del perfil de potencia, convirtiéndose en la función objetivo de optimización.

Finalmente se compararán los resultados obtenidos del algoritmo de evolución diferencial con los resultados obtenidos en dos trabajos de titulación anteriores: algoritmo de búsqueda Cuckoo (CS) (García-Gutiérrez, 2018) y el algoritmo de optimización por Enjambre de Partículas (PSO – Particle Swarm Optimization) (Pacheco, 2019) para comprobar la robustez de la estrategia de gestión energética.

1.4. Objetivos General y Específicos

1.4.1. Objetivo General

- Optimizar los parámetros de un controlador Fuzzy Logic del sistema de gestión energética de una microrred electro-térmica para minimizar los picos y fluctuaciones del perfil de potencia intercambiado con la red.

1.4.2. Objetivos específicos

- Implementar el algoritmo de optimización de evolución diferencial orientado al ajuste de parámetros de EMS basado en fuzzy logic.
- Evaluar los criterios de calidad del perfil de potencia de la microrred resultantes de la optimización por el algoritmo DE mediante la función de costo global.
- Comparar el perfil intercambiado con la red eléctrica obtenido para el controlador FLC optimizado mediante el algoritmo de evolución diferencial con el resultado obtenido mediante el algoritmo CS y PSO.

CAPITULO 2

MARCO TEÓRICO

En este capítulo se describe a detalle las definiciones necesarias para el desarrollo del proyecto de investigación, abarcará principalmente el estado del arte de los temas principales como: algoritmos inspirados en la naturaleza, en especial el algoritmo por evolución diferencial (DE), controladores de lógica difusa, así como la descripción de la microrred electrotérmica del caso de estudio.

2.1 Algoritmos inspirados en la naturaleza

La vida animal y vegetal desarrolla de forma instintiva estrategias y patrones de comportamiento para garantizar su supervivencia (Lindfield & Penny, 2017) por lo que muchos investigadores se han iluminado en este comportamiento para realizar nuevos algoritmos, sobre todo en el campo de la inteligencia artificial (Artificial Intelligence-AI) con el objetivo de resolver problemas de optimización y clasificación. (Bujok, Tvrđík, & Poláková, 2017).

Casi todos los algoritmos inspirados en la naturaleza tienen un elemento aleatorio o estocástico en el proceso computacional. Esto tiene una influencia en la forma en la que se interpretan los resultados y pueden clasificarse en dos tipos: heurísticos y metaheurísticos. Heurístico significa “encontrar” o “descubrir mediante prueba y error”, estos algoritmos son útiles cuando no necesariamente se desea las mejores soluciones sino buenas soluciones fácilmente accesibles (Yang, 2010). Por otro lado, metaheurístico hace alusión a algoritmos de un nivel superior y generalmente funcionan mejor que los de heurística simple, además, utilizan ciertas compensaciones de aleatorización y búsqueda local (Yang, 2010).

Los algoritmos metaheurísticos en general, proporcionan soluciones para problemas que tienen un nivel aceptable de precisión. De acuerdo a (Yang, 2010) los algoritmos metaheurísticos pueden ser clasificados de acuerdo a la población o trayectoria. Por ejemplo, los algoritmos genéticos y de evolución diferencial están basados en la población ya que utilizan un conjunto de cadenas al igual que PSO, búsqueda Cuckoo, y el algoritmo de la luciérnaga (Firefly Algorithm-FA) los cuales utilizan múltiples partículas.

2.2 Algoritmo de Evolución Diferencial

El algoritmo DE es un algoritmo metaheurístico basado en vectores, fue desarrollado por R. Storn y K.Price. Es un algoritmo de búsqueda estocástico con tendencia a auto organizarse, basado en población. En DE, el valor de cada variable está representado por un número real, por lo que no necesita codificación ni decodificación (Bujok et al., 2017).

Las ventajas del algoritmo DE son su estructura simple, facilidad de uso, velocidad y robustez. DE es uno de los mejores algoritmos de tipo genético para resolver problemas con variables de valor real (Yang & Press, 1995) lo que la convierte en una herramienta de diseño de gran utilidad para aplicaciones prácticas de optimización. Se lo ha utilizado en varias aplicaciones científicas y de ingeniería para descubrir soluciones efectivas a problemas casi intratables sin recurrir al conocimiento experto o algoritmos de diseño complejos (Arunachalam, 2008).

Para un problema de optimización d – dimensional con d parámetros, se genera inicialmente una población de n vectores de solución. Se tiene el valor x_i que se conoce como vector inicial, donde $i = 1, 2, \dots, n$ Para cada solución x_i en cualquier generación t se utiliza la notación convencional:

$$x_i^t = (x_{1,i}^t, x_{2,i}^t, \dots, x_{d,i}^t) \quad (2.1)$$

La evolución diferencial consta de tres pasos principales: mutación, cruce y selección.

2.3 Mutación cruce y selección en DE

El algoritmo DE intenta replicar computacionalmente el comportamiento biológico de la evolución. La mutación en la evolución de un individuo consiste en la variación aleatoria de uno de sus genes. El algoritmo DE toma como referencia este comportamiento e inicialmente construye vectores aleatorios x_i en cualquier momento o generación t que son creados a partir de tres individuos de la población elegidos al azar x_p , x_q , y x_r llamados vectores objetivo en t como se muestra en la Figura 1, con el objetivo de provocar que un vector en alguno de sus valores varíe de forma aleatoria. La mutación se realiza mediante el esquema de mutación así:

$$v_i^{t+1} = x_p^t + F(x_q^t - x_r^t) \quad (2.2)$$




Figura 1 Representación Esquemática de vectores de mutación en evolución diferencial con

$$\text{movimiento } \delta = F(x_q - x_r)$$

Fuente: (Fister et al., 2013; Yang, 2010)

En (2.2) la variable F también es denominada factor de escala, el cual controla la longitud del vector de exploración $(x_q - x_r)$ y por lo tanto determina que tan lejos del punto x_i se debe generar la descendencia. Se ha demostrado en la práctica que el esquema con $F \in [0,1]$ es más eficiente y estable (Choi, Lee, & Park, 2017), esto significa que el factor de escala debe ser un valor positivo entre 0 y 1.

Por otro lado, el cruce hace referencia a que los genes se “mezclan” para introducir nuevas combinaciones de genes en la población. En el algoritmo DE, una vez obtenidos los vectores aleatorios, se realiza este proceso de recombinación donde se comparan los vectores aleatorios de la mutación con los vectores originales y como resultado aparecen los vectores de prueba. Este proceso es controlado por el parámetro $Cr \in [0, 1]$ que controla la probabilidad de cruce.

Según Price & Storn existen 10 tipos de esquemas para DE, con la convención DE/x/y/z donde: DE se refiere al algoritmo, x representa el vector a perturbar que puede ser el mejor vector de la generación anterior (best) o un vector elegido de manera aleatoria (rand), y e es el número de vectores considerados para la perturbación de x , y z es el tipo de cruce a utilizar (exponencial o binomial) limitado por el valor de Cr . El esquema de cruce que se utilizará en el caso de estudio será el binomial. El esquema binomial realiza un cruce en cada uno de los componentes d o variables. Al generar un número aleatorio distribuido uniformemente $r_i \in [0, 1]$, el componente Jr de v_i es manipulado de la siguiente forma:

$$u_{j,i}^{t+1} = \begin{cases} v_{j,i} & \text{Si } r_i \leq Cr \\ x_{j,i}^t & \text{de otra manera} \end{cases} \quad J_r = 1, 2, \dots, d. \quad (2.3)$$

En (2.3) se decide aleatoriamente si se intercambia cada componente con un vector donante o no. Cabe recalcar que la estrategia DE/aleatorio/1/bin es el esquema DE básico, se adoptó para el caso de estudio por ser el esquema más simple.

Por último, la selección en la evolución hace referencia a escoger qué individuos pasan a la siguiente generación. En el algoritmo DE, se compara los vectores de prueba con los originales, haciendo que el vector de la siguiente generación que pase tenga el mejor valor de función de desempeño (Storn & Price, 1995), es decir:

$$x_i^{t+1} = \begin{cases} u_i^{t+1}, & \text{Si } f(u_i^{t+1}) \leq f(x_i^t) \\ x_i^t, & \text{de otra manera} \end{cases} \quad (2.4)$$

2.4 Selección de parámetros

La selección de parámetros es importante en el algoritmo DE. El factor de escala de mutación F y la constante de cruce Cr son los dos parámetros de control de importancia del algoritmo. El ajuste de ambos controla el rendimiento del algoritmo. Estudios (Choi et al., 2017; Fister et al., 2013; Yang, 2010) sugieren que los valores deben ajustarse con precisión así:

- El factor de escala F es el más sensible, es el parámetro que afecta la velocidad con la cual evoluciona la población. $F \in [0, 1]$ es eficiente en la práctica. De acuerdo a la literatura (Choi et al., 2017) los mejores valores para el factor de escala son $F = [0.7, 0.9]$.
- El parámetro de cruce Cr muestra mejores resultados cuando $Cr = 0.9$.

Por último, se sugiere que el tamaño de la población n depende de la dimensionalidad d del problema.

2.5 Controladores Fuzzy Logic

El control difuso se hace presente cuando la tarea de modelar o simular sistemas complejos se dificulta, sobre todo en problemas de implementación. El control difuso proporciona una metodología para representar, manipular e implementar el conocimiento heurístico de un humano sobre cómo controlar un sistema. Un controlador en lógica difusa (Fuzzy Logic Controller - FLC) está compuesto de los siguientes elementos (Passino & Yurkovich, 1998):

Base de reglas. - Este componente contiene el conocimiento en forma de un conjunto de reglas If-Then para controlar el sistema.

Mecanismo de inferencia. - También motor de inferencia o módulo de inferencia difusa, que evalúa las reglas de control que son relevantes en el instante actual y decide cual debe ser la entrada a la planta $u(t)$

Fuzzificación. - Convierte las entradas del controlador $r(t)$ y $y(t)$ en información que el mecanismo de inferencia pueda usar fácilmente para activar y aplicar las reglas (información numérica a lingüística).

Defuzzificación. - Convierte las conclusiones del mecanismo de inferencia en entradas reales para el proceso (información lingüística a numérica)




Figura 2 Arquitectura de un Controlador Fuzzy Logic.

Fuente: (Passino & Yurkovich, 1998)

De manera general un FLC es un sistema en lazo cerrado que opera en tiempo real. El controlador fuzzy recopila los datos de salida de la planta $y(t)$, lo compara con la entrada de referencia $r(t)$ y luego decide cuál es la entrada de la planta $u(t)$ para que se cumplan los objetivos de rendimiento.

2.6 Sistemas de gestión energética (EMS)

Un EMS monitorea el flujo de potencia y permite que una MG opere conectada a la red o en modo de isla cuando la energía de la red principal no está disponible (Oriti, 2018). Una buena estrategia vinculada al EMS conduce a un rendimiento eficiente de la MG (Olatomiwa et al., 2016).

En el caso de estudio se presenta una MG electrotérmica de uso residencial y su EMS tiene como objetivo reducir los picos de generación y consumo en el perfil de red, es decir suavizarlo (Diego Arcos-Aviles et al., 2019).

2.7 Descripción de la microrred electrotérmica

Este estudio se lo realiza en una microrred electrotérmica de uso residencial de la Figura 3 (Diego Arcos-Aviles, Gordillo, et al., 2018) . Esta arquitectura incluye los siguientes elementos: un sistema híbrido de energía renovable (HRES) con un generador fotovoltaico (PV) de 6kW y una turbina eólica (WT) de 6kW, un ESS (sistema de almacenamiento de energía) compuesto por un banco de baterías con una capacidad nominal de 72kWh, una demanda de carga doméstica con cargas eléctricas típicas con una potencia nominal de 7kW, un sistema de agua caliente sanitaria (ACS) que consta de un calentador eléctrico de agua (EWH) de 2kW, un conjunto de colectores solares térmicos de placas planas de 2kW, un sistema de almacenamiento térmico representado por un tanque de depósito de agua de 800 litros de capacidad y una demanda térmica equivalente a 2kW(D. Arcos-Aviles et al., 2017; Diego Arcos-Aviles, Gordillo, et al., 2018).




Figura 3 Arquitectura de la microrred electrotérmica de estudio

Fuente: (D. Arcos-Aviles et al., 2017)

CAPITULO 3

DESARROLLO DEL ALGORITMO DE EVOLUCIÓN DIFERENCIAL

En este capítulo se describe el caso de estudio y se diseña el algoritmo de optimización de evolución diferencial definido en el capítulo 2. También se definen parámetros propios del algoritmo que se van a utilizar en la práctica.

3.1. Descripción del caso de estudio

En la Figura 3 se presenta la MG electro-térmica de uso residencial y se considera el EMS de trabajos anteriores (Diego Arcos-Aviles, Gordillo, et al., 2018; Diego Arcos-Aviles et al., 2019), los cuales han tenido como objetivo minimizar las fluctuaciones del perfil de potencia que la microrred intercambia con la red eléctrica con la ayuda de la energía almacenada en la batería ESS para cubrir parte de la energía requerida por EWH y mantener la temperatura del agua del tanque entre su máximo y mínimo (45°C y 65°C). En (Diego Arcos-Aviles, Gordillo, et al., 2018) se define a la potencia intercambiada con la red como la suma de tres componentes:

$$P_{GRID} = P_{CTR}^*(n) + P_{SOC}(n) + P_{FLC}(n) \quad (3.1)$$

Donde P_{GRID} es la potencia intercambiada con la red de suministro, $P_{GRID} < 0$ implica que la red de suministro absorbe potencia de la microrred y $P_{GRID} > 0$ denota una inyección de potencia por parte de la red de suministro hacia la microrred, $P_{CTR}^*(n)$ establece el perfil de potencia promedio de MG, $P_{SOC}(n)$ intenta mantener el centro de SOC de la batería cerca del 75% de la capacidad nominal de la misma y $P_{FLC}(n)$ mejora el perfil de potencia de la red de acuerdo con el SOC de la

batería y el error de pronóstico de MG (D. Arcos-Aviles et al., 2016; Diego Arcos-Aviles et al., 2017).

El EMS basado en fuzzy que se utiliza fue propuesta en estudios anteriores (Diego Arcos-Aviles, Gordillo, et al., 2018) y se presenta en la Figura 4 . Está compuesta de los siguientes bloques: EWH Control, Filtro CMA, Filtro 3H, Filtro pasa bajos, Estimador SOC y el bloque 6 que pertenece al FLC.




Figura 4 Microrred electrotérmica residencial conectada a la red residencial

Fuente: (Diego Arcos-Aviles, Pascual, et al., 2018)

El análisis y descripción completa de los bloques se encuentra en (Diego Arcos-Aviles et al., 2019)

El bloque de mayor interés para el estudio es el bloque 6 , que asume un sistema de inferencia basado en Mamdani y método de defuzzificación de centroide con dos entradas, una salida y 25 reglas (D. Arcos-Aviles et al., 2016).

Todos los parámetros de lógica difusa como las MFs y mapeo se ajustan para minimizar un conjunto de criterios de calidad. Estos criterios de calidad sirven de base para la formulación de la función de costo para la optimización.

Los criterios de calidad son: pico máximo del perfil de red $P_{G,MAX}$, pico mínimo del perfil de red $P_{G,MIN}$, rango de variación de potencia PVR , máxima rampa de potencia MPD , rampa de media potencia APD y variabilidad del perfil de red PPV y se encuentran definidos en (Pascual et al., 2015, 2014)

3.2. Diseño del algoritmo de optimización de evolución diferencial

En el apartado 2.4 del capítulo 2 se definieron los valores de los parámetros del algoritmo DE, por lo que:

Se define el tamaño de la población el cual de acuerdo a la literatura (Yang, 2010) con un valor de $n = 25$ es más que suficiente. Una vez definido el tamaño de la población se consideran los valores de los parámetros de F y Cr así: $F = 0.7$ y $Cr = 0.9$.

El tercer parámetro hace referencia a la dimensión de la solución d , para esto se toma en consideración el número de parámetros a optimizar para las variables de entrada P_E y SOC , así como la salida P_{FLC} de la siguiente manera:

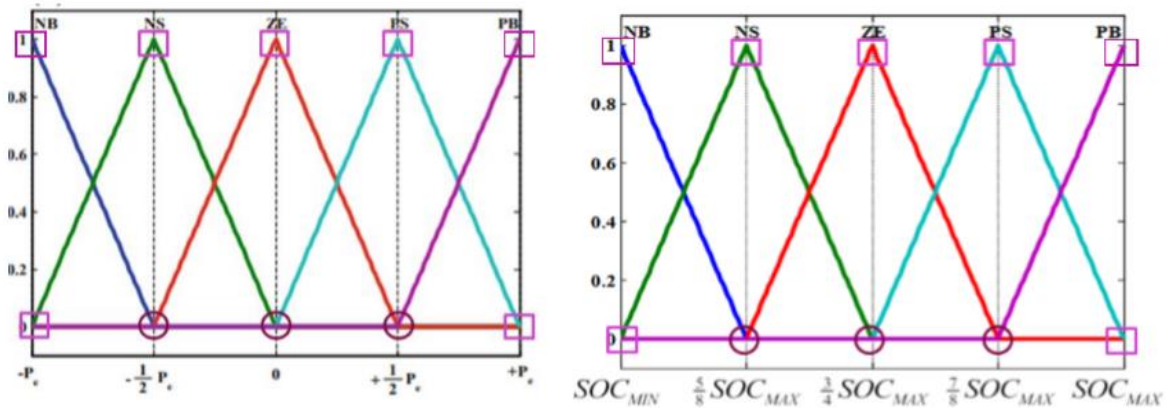


Figura 5 Funciones de pertenencia entrada P_E y SOC respectivamente para calcular la dimensión del problema.

Fuente: (García-Gutiérrez, 2018)

Como se observa en la Figura 5, los cuadrados hacen referencia a un parámetro de cada MF mientras que los círculos representan a dos parámetros en MF adyacentes, esto aplica en las dos variables de entrada ya que cuentan con el mismo número de funciones de pertenencia. El número de parámetros a optimizar se calcula:

$$\#parámetros_{P_E} = 3 \cdot 3 + 2 \cdot 2 = 13 \quad (3.2)$$

$$\#parámetros_{SOC} = 3 \cdot 3 + 2 \cdot 2 = 13 \quad (3.3)$$

Adicionalmente se puede definir los límites del espacio de búsqueda de las variable de entrada de acuerdo con los limites definidos en (García-Gutiérrez, 2018) ya que se trata del mismo caso de estudio:

$$x_{P_E} = \{x_{P_E} \in X \mid -6 \leq x_{P_E} \leq 6\} \quad (3.4)$$

$$x_{SOC} = \{ x_{SOC} \in X \mid 50 \leq x_{SOC} \leq 100 \} \quad (3.5)$$

De acuerdo a la Figura 5, se consideran los parámetros de la Tabla 1:

Tabla 1

Parámetros de las variables de entrada

Parámetro	Descripción
$x_{PE_{MIN}, PE_{MAX}}$	Límites inferior y superior de P_E
$x_{SOC_{MIN}, SOC_{MAX}}$	Límites inferior y superior de SOC

Por otro lado, para la salida del controlador P_{FLC} se tiene 9 MF como indica la Figura 6. Además, se incluye los parámetros de salida máxima y mínima $+k$ y $-k$ respectivamente, los cuales representan el rango de salida. Se calcula el número de parámetros:

$$\#parámetros_{FLC} = 3 \cdot 7 + 2 \cdot 2 + 2 = 27 \quad (3.6)$$




Figura 6 Funciones de pertenencia entrada P_{FLC} para calcular la dimensión del problema.

Fuente: (García-Gutiérrez, 2018)

De igual manera que en los parámetros de entrada, se definen los límites del espacio de búsqueda de la variable de salida de acuerdo con los límites del espacio de diseño:

$$x_{k(-)(+)} = \{ x_{k(-)(+)} \in X \mid 0 \leq |x_{k(-)(+)}| \leq 10 \} \quad (3.7)$$

$$x_{PG} = \{ x_{PG} \in X \mid k_{(-)} \leq x_{PG} \leq k_{(+)} \} \quad (3.8)$$

Por último, para la base de reglas, inicialmente se define mediante el conocimiento heurístico de la microrred de acuerdo a la potencia entregada/absorbida desde y hacia la microrred, como se muestra en la Tabla 2:

Tabla 2
Base de Reglas Inicial del Controlador

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

Fuente: (Diego Arcos-Aviles, Gordillo, et al., 2018)

El número de parámetros a optimizar equivale a las 25 reglas de la Tabla 2.

$$\#parametros_{RL} = 25 \quad (3.9)$$

Y los límites de espacio de búsqueda de las reglas queda definido, así, por el número de MFs de la salida:

$$x_{RL} = \{ x_{RL} \in X \mid 1 \leq x_{RL} \leq 9 \} \quad (3.10)$$

Por lo tanto, el número total de parámetros a optimizar resulta de la suma de (3.2) - (3.3) y (3.9). Este resultado corresponde a la dimensión del problema $d=78$.

Una vez seleccionados los parámetros más importantes propios del algoritmo DE e inicializados, se genera un arreglo de fitness el cual almacena el valor de la función de costo que se definirá más adelante, esto con el objetivo de determinar la mejor solución de cada iteración. Una vez realizado este proceso se desarrolla el algoritmo DE (Santana, 2004). Se utiliza la Figura 7 como ejemplo para una mayor comprensión:

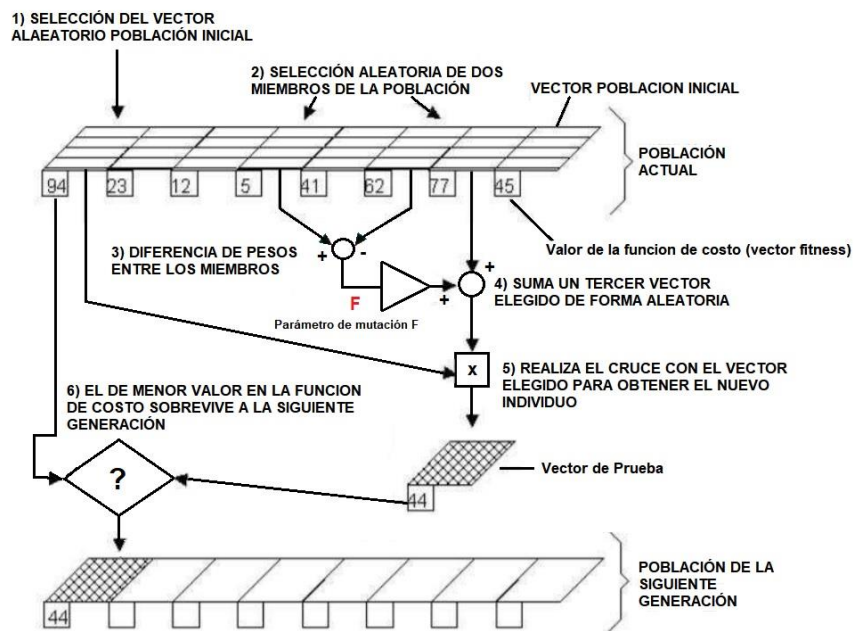


Figura 7 Ejemplo de la generación de los vectores y proceso del algoritmo DE

Fuente: (Santana, 2004)

1. Se elige un vector de forma aleatoria dentro de la población.
2. De manera aleatoria se elige otros dos miembros de la población.
3. Se calcula la diferencia de pesos en el espacio de las variables de los vectores entre los miembros obteniéndose un nuevo vector.
4. Un tercer vector es elegido aleatoriamente de la población y realiza una suma en el espacio de las variables.

5. Este vector de prueba obtenido en el punto 4 realiza el cruce con el vector original inicial para obtener un nuevo individuo que será hijo del cruce.
6. Por último, se realiza una comparación entre el vector padre (vector inicial) y el vector hijo para determinar cuál de los dos pasa a la siguiente generación esta comparación viene definida por la función de costo que se guarda en el vector fitness creado inicialmente. El de menor costo sobrevive a la siguiente generación. Este proceso se realiza de manera iterativa (Santana, 2004).

De manera general, el algoritmo DE se describe en el siguiente pseudocódigo:

```

Pseudocódigo Evolución Diferencial

Inicio

Inicializar la población n=25
Inicializar los parámetros DE F=0.7 Cr=0.9
Inicializar d=78

while (criterio de parada)
  for i= 1 a n:
    Para cada  $x_i$ , selecciona 3 vectores distintos  $x_p, x_q$  y  $x_r$ 
    Generar un nuevo vector  $v_i$  por el esquema DE

      
$$v_i^{t+1} = x_p^t + F(x_q^t - x_r^t)$$


    Generar un índice aleatorio  $J_r \in \{1, 2, \dots, d\}$  por permutación
    Generar un número  $r_i \in [0, 1]$  distribuido al azar
    for j= 1 a d,
      Para cada parámetro  $v_{j,i}$  (jth componente de  $v_i$ ), actualizar

        
$$u_{j,i}^{t+1} = \begin{cases} v_{j,i}^{t+1} & \text{Si } r_i \leq C_r \text{ o } j = J_r \\ x_{j,i}^t & \text{Si } r_i > C_r \text{ y } j \neq J_r \end{cases}$$


    end
    Seleccionar y actualizar la solución por

      
$$x_i^{t+1} = \begin{cases} u_i^{t+1} & \text{Si } f(u_i^{t+1}) \leq f(x_i^t), \\ x_i^t & \text{de otra manera} \end{cases}$$


    end
  end
  Post proceso y salida de la mejor solución encontrada

```

Figura 8 Pseudocódigo del algoritmo DE

Fuente: (Yang, 2010)

De igual manera, en la Figura 9 se presenta un diagrama de flujo que representa el algoritmo de optimización y el proceso de evaluación del EMS:

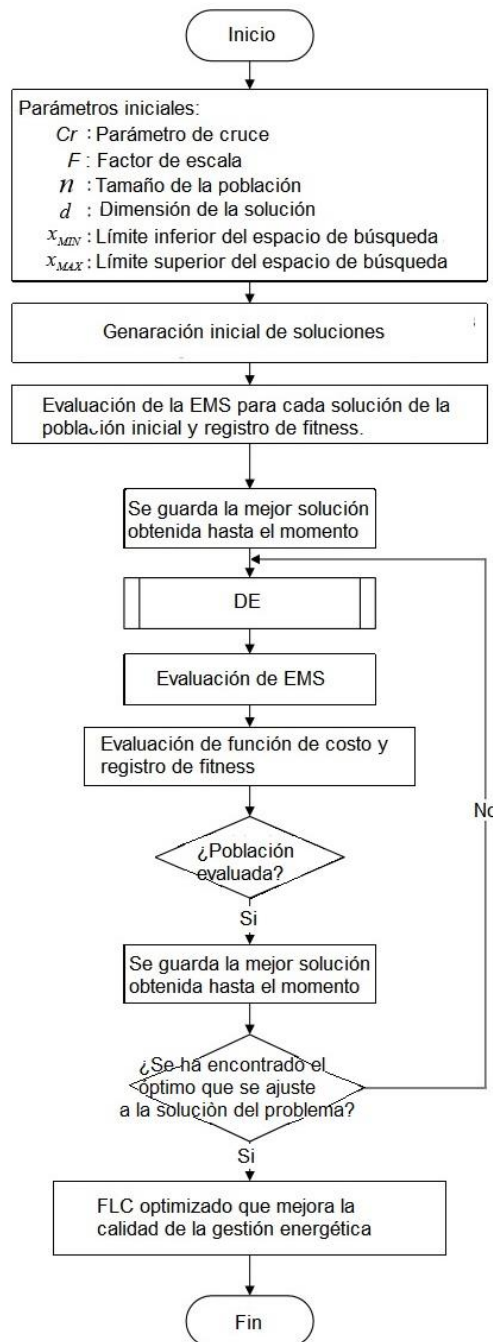


Figura 9 Diagrama de Flujo del algoritmo DE implementado

Fuente: Elaboración Propia

3.3. Función de costo de criterios de calidad para evaluación estrategia de gestión.

Como es un estudio de comparación, se utiliza la misma función de costo descrita en (García-Gutiérrez et al., 2019), esto con el objetivo de que las comparaciones sean bajo las mismas condiciones. Por lo tanto, la función de costo viene definida por:

$$U = w_1 \cdot \frac{P_{G,MAX}}{2.56} + w_2 \cdot \frac{P_{G,MIN}}{-1.89} + w_3 \cdot \frac{MPD}{846} + w_4 \cdot \frac{APD}{75} + w_5 \cdot \frac{PVR}{0.34} + w_6 \cdot \frac{PPV}{1.26} \quad (3.11)$$

Donde w_n representa las ponderaciones asignadas para el problema de optimización en base a las preferencias de diseño del EMS como se detalla en (García-Gutiérrez et al., 2019), y $P_{G,MAX}$, $P_{G,MIN}$, PVR , MPD , APD y PPV son los criterios de calidad de la gestión energética mencionados en el apartado 3.1. En base a (3.11) los pesos quedan definidos así: $w_1 = w_2 = w_3 = 4$, $w_4 = w_5 = 2$ y $w_6 = 1$.

CAPITULO 4

PRUEBAS Y RESULTADOS

En este capítulo se definen los valores de referencia del algoritmo de búsqueda Cuckoo y PSO, para una posterior comparación de los resultados. Además de realizar la comparación de los resultados a través de la optimización de FLC con el algoritmo DE y los algoritmos CS y PSO

4.1 Valores de referencia para propósitos de comparación

Se toma como referencia los resultados obtenidos en (García-Gutiérrez, 2018) y (Pacheco, 2019). A partir de estos, se compara la mejora de la gestión energética mediante el ajuste de parámetros de fuzzy logic.

Los parámetros del controlador fuzzy son: posiciones de funciones de pertenencia para variables de entrada y salida, rango de la variable de salida y base de reglas. La primera variable de entrada es el error de predicción P_E , la cual consta de 5 MF, con 13 parámetros, la segunda variable de entrada es el estado de carga de la batería SOC , consta de 5 MF y 13 parámetros, por otro lado, la salida del controlador P_{FLC} consta de 9 MF y se le atribuyen 27 parámetros.

4.1.1 Valores de referencia optimización Cuckoo

Las funciones de pertenencia ajustadas por el algoritmo CS (García-Gutiérrez, 2018; García-Gutiérrez et al., 2019) se presentan a continuación , así como los parámetros de calidad de la gestión energética resultantes:

- Entrada: Error de predicción, P_E donde $P_{E,MAX} = 6\text{kW}$ y $P_{E,MIN} = -6\text{kW}$.




Figura 10 MF ajustadas para la entrada P_E mediante el algoritmo CS

Fuente:(García-Gutiérrez, 2018)

- Entrada: estado de carga de batería, SOC , donde $SOC_{MAX} = 50\%$ y $SOC_{MIN} = 100\%$

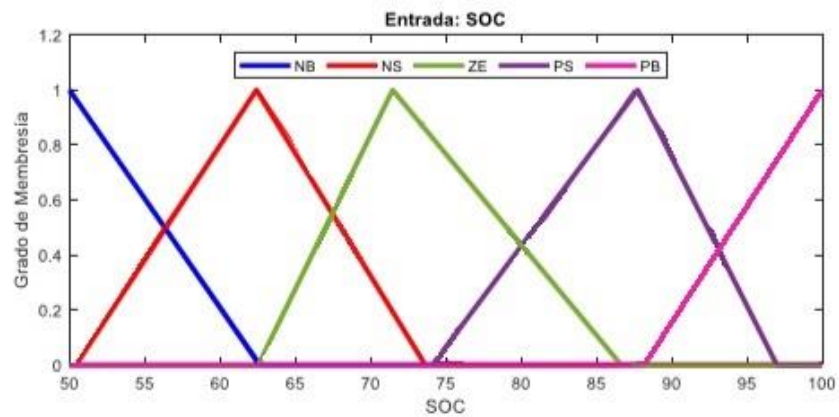


Figura 11 MF ajustadas para la entrada SOC mediante el algoritmo CS

Fuente:(García-Gutiérrez, 2018)

- Salida: salida de FLC, P_{FLC} , donde el rango de salida es -0.501 y 0.7863

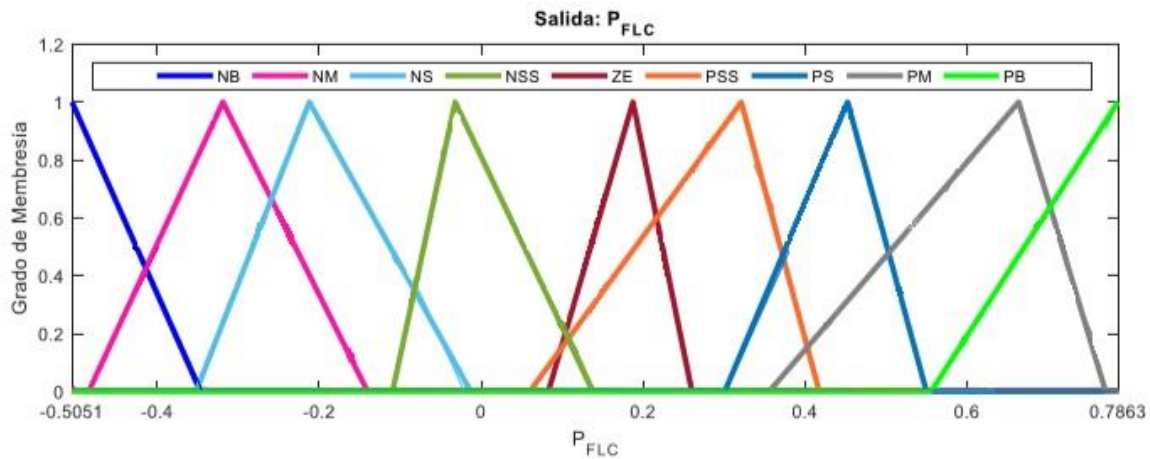


Figura 12 MF ajustadas para la salida P_{FLC} mediante el algoritmo CS

Fuente:(García-Gutiérrez, 2018)

- Base de reglas: La base de reglas con la optimización CS se muestra en la Tabla 3.

Tabla 3

Base de reglas de EMS-FC con algoritmo de optimización CS

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

Fuente:(García-Gutiérrez, 2018)

Las gráficas resultantes de la estrategia de gestión energética y los valores de los criterios de calidad optimizados se muestran a continuación:

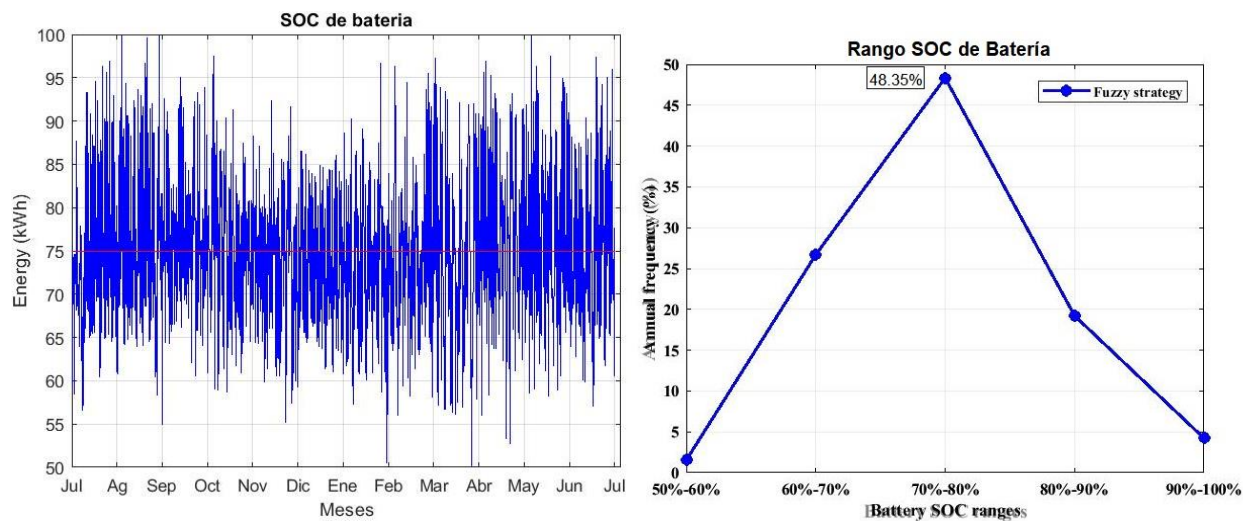


Figura 13 SOC de la batería y rangos. Estrategia EMS-FC con CS

Fuente: (García-Gutiérrez, 2018)

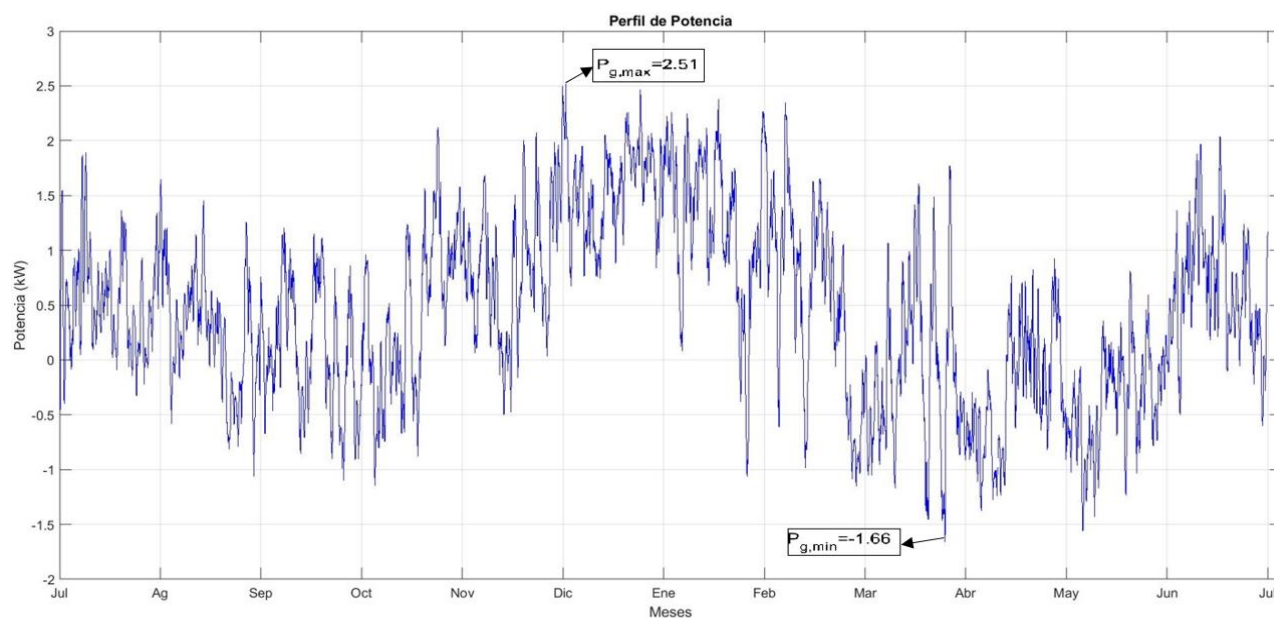


Figura 14 Perfil de potencia intercambiado con la red eléctrica. Estrategia EMS-FC con CS

Fuente: (García-Gutiérrez, 2018)




Figura 15 Rampas del perfil de potencia intercambiado. Estrategia EMS-FC con CS

Fuente: (García-Gutiérrez, 2018)

Tabla 4

Criterios de calidad de la gestión energética Estrategia EMS-FC con CS

	$P_{G,MAX}[kW]$	$P_{G,MIN}[kW]$	$MPD[W/h]$	$APD[W/h]$	PVR	PPV
Fuzzy EMS-FC-CS	2.51	-1.66	472	0.32	75	1.25

Fuente: (García-Gutiérrez, 2018)

4.1.2 Valores de referencia optimización PSO

Se toma también como referencia las funciones de pertenencia ajustadas en el trabajo de optimización por el algoritmo PSO (Pacheco, 2019).

- Entrada: Error de predicción, P_E

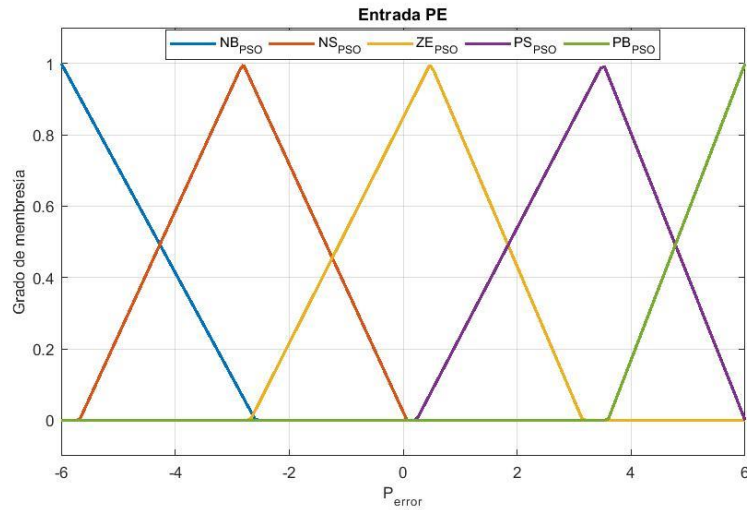


Figura 16 MF ajustadas para la entrada P_E mediante el algoritmo PSO

Fuente: (Pacheco, 2019)

- Entrada: Estado de Carga de Batería, SOC

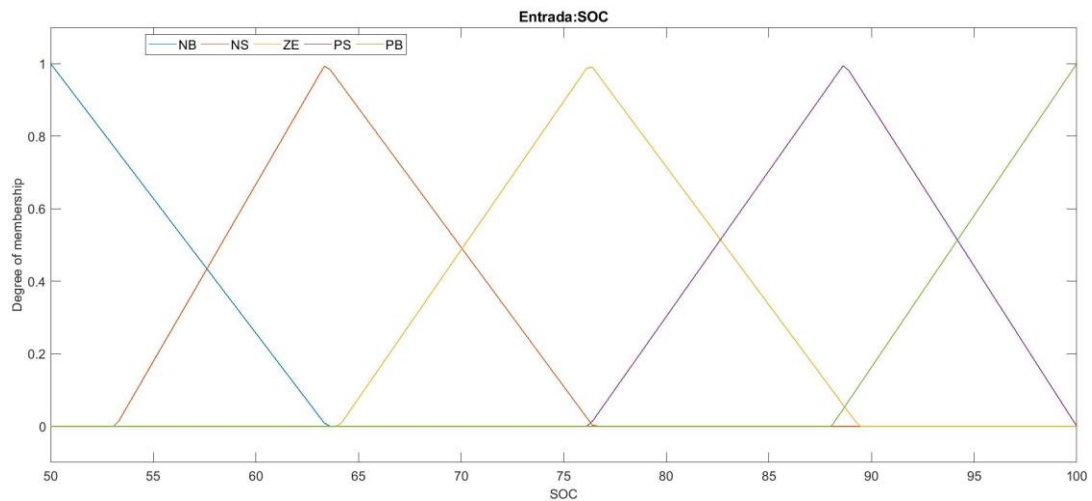


Figura 17 MF ajustadas para la entrada SOC mediante el algoritmo PSO

Fuente: (Pacheco, 2019)

- Salida: Salida de FLC, P_{FLC}




Figura 18 MF ajustadas para la salida P_{FLC} mediante el algoritmo PSO

Fuente: (Pacheco, 2019)

- Base de reglas: La base de reglas con la optimización PSO se muestra en la Tabla 5.

Tabla 5

Base de reglas de EMS-FC con algoritmo de optimización PSO

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

Fuente: (Pacheco, 2019)

Las gráficas resultantes de la estrategia de gestión energética y los criterios de calidad con optimización PSO se muestran a continuación:

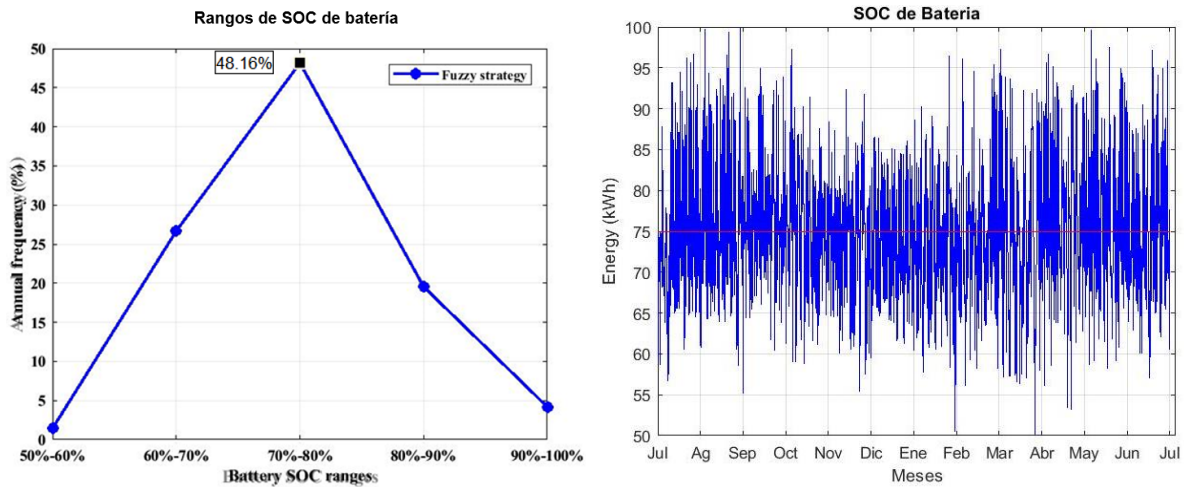


Figura 19 SOC de la batería y rangos. Estrategia EMS-FC con PSO

Fuente: (Pacheco, 2019)




Figura 20 Perfil de potencia intercambiado con la red eléctrica. Estrategia EMS-FC con PSO

Fuente: (Pacheco, 2019)

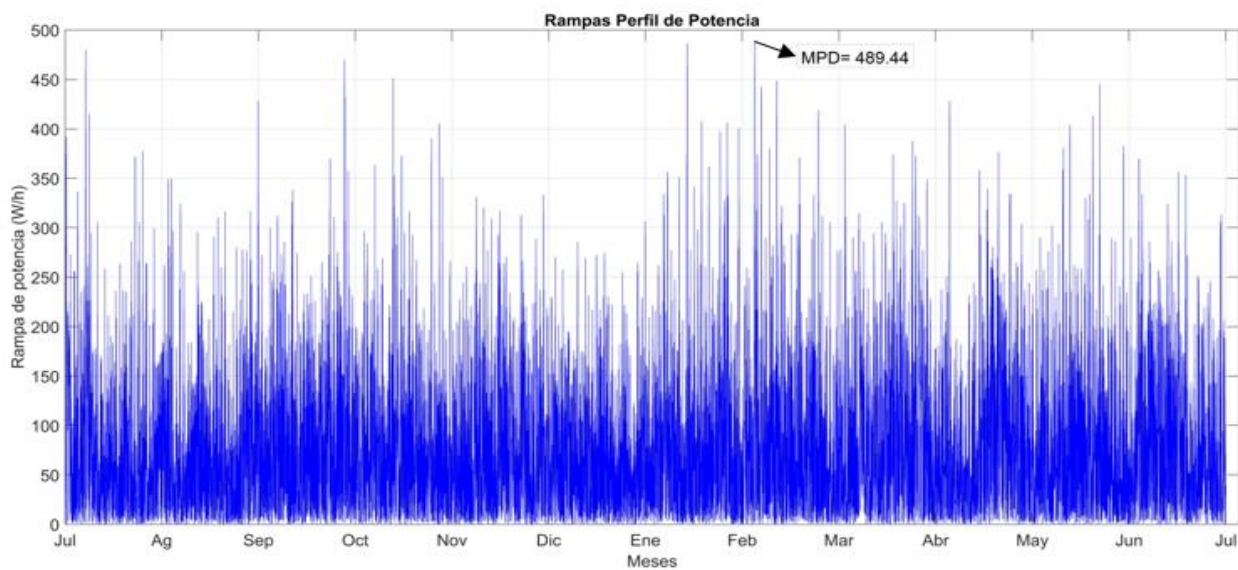


Figura 21 Rampas del perfil de potencia intercambiado. Estrategia EMS-FC con PSO

Fuente: (Pacheco, 2019)

Tabla 6

Criterios de calidad de la gestión energética Estrategia EMS-FC con PSO

	$P_{G,MAX}[kW]$	$P_{G,MIN}[kW]$	$MPD[W/h]$	$APD[W/h]$	PVR	PPV
Fuzzy EMS-FC- PSO	2.51	-1.71	489.44	0.32	76	1.26

Fuente: (Pacheco, 2019)

4.2 Resultados de simulaciones numéricas

El proceso de optimización en total de los parámetros con el algoritmo DE del controlador de Lógica Difusa tomó aproximadamente 1080 horas equivalente a 45 días en una computadora INTEL® Core (TM) i7-8750H CPU @ 2.20 GHz y el programa Matlab que ejecutó 300 iteraciones en total para encontrar la solución que se presenta.

Las funciones de pertenencia de entrada y salida ajustadas mediante el algoritmo DE se presentan a continuación:

- Entrada: Error de predicción, P_E




Figura 22 MF ajustadas para la entrada P_E mediante el algoritmo DE

Tabla 7

Posiciones de MF para la entrada P_E mediante DE

	<i>NB</i>			<i>NS</i>			<i>ZE</i>			<i>PS</i>			<i>PB</i>		
Fuzzy EMS – FC-DE	-6	-6	-5.37	-6	-4.3	-1.36	-3.94	-1.72	3.13	-1.15	3.61	6	4.44	6	6

- Entrada: Estado de Carga de Batería, *SOC*




Figura 23 MF ajustadas para la entrada *SOC* mediante el algoritmo DE

Tabla 8

Posiciones de MF para la entrada SOC mediante DE

	<i>NB</i>			<i>NS</i>			<i>ZE</i>			<i>PS</i>			<i>PB</i>		
Fuzzy EMS – FC-DE	50	50	63.84	50	56.2	72.51	53.86	74.44	90.13	68.97	92.95	100	88.72	100	100

- Salida: Salida de FLC, P_{FLC}




Figura 24 MF ajustadas para la salida P_{FLC} mediante el algoritmo DE

Tabla 9

Posiciones de MF y rango de salida para la variable P_{FLC}

	<i>NB</i>			<i>NM</i>			<i>NS</i>			<i>NSS</i>		
Fuzzy EMS-FC-DE	-0.89	-0.89	-0.77	-0.89	-0.65	-0.26	-0.54	-0.34	-0.26	-0.55	-0.21	0.10
	<i>ZE</i>			<i>PSS</i>			<i>PS</i>			<i>PM</i>		
Fuzzy EMS-FC-DE	-0.42	-0.08	0.14	-0.16	0.23	0.54	-0.17	0.41	0.43	0.35	0.65	0.77
	<i>PB</i>			<i>Rango</i>								
Fuzzy EMS-FC-DE	0.47	0.77	0.77	-0.89	0.776							

Otro resultado de importancia es la base de reglas del controlador optimizadas con el algoritmo DE presentadas en la Tabla 10.

Tabla 10

Base de reglas de EMS-FC optimizada por DE

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

4.3 Ventajas y desventajas del algoritmo DE

De acuerdo al caso de estudio definido en el capítulo 3, las entradas, la salida involucradas en el controlador de la microrred al igual que los criterios de calidad son variables numéricas, por lo que el algoritmo DE se adapta fácilmente ya que no se necesita codificar ni decodificar estos valores.

Una de las desventajas importantes que se encontró mientras se implementó el algoritmo de optimización fue la selección de los parámetros F y Cr , propios del algoritmo definidos en el capítulo 2, los cuales se utilizan para dirigir el proceso de búsqueda a los óptimos globales. El ajuste fino de ambos parámetros controla el rendimiento del algoritmo. Estos se seleccionan de manera heurística y de acuerdo a la experticia del programador. Para el caso de estudio se seleccionaron los valores que recomienda la literatura y se obtuvo resultados favorables, pero cabe recalcar que estos resultados pueden variar hasta ajustarse de forma conveniente al problema de optimización.

4.4 Tiempo de ejecución del algoritmo DE

En cuanto al número de iteraciones, tiempo de ejecución y convergencia, se muestran en la Tabla 11, tanto de los algoritmos de Cuckoo (García-Gutiérrez et al., 2019) y PSO (Pacheco, 2019), como del algoritmo DE:

Tabla 11

Tiempo de ejecución Cuckoo, PSO y DE

Algoritmo	Nº Partículas/ Nidos/ Población/	Tiempo por iteración (min)	Convergencia (Iteración N°)	Tiempo de Convergencia (horas)
PSO	5	3.1	204	10.54
CS	25	16.1	300	80.5
DE	25	10.1	300	60.3

De la Tabla 11 se puede deducir que el algoritmo de optimización PSO tiene menor tiempo de convergencia ya que el número de partículas al igual que el número de iteraciones es menor, en comparación al número de nidos y población del algoritmo de Cuckoo y DE respectivamente. Esto es posible ya que la característica del algoritmo PSO es la convergencia rápida.

4.5 Comparación de los resultados obtenidos a través de la optimización del FLC con el algoritmo DE vs Algoritmo de CS y PSO.

Se realiza las comparaciones de las funciones de pertenencia de los tres algoritmos, la base de reglas, el análisis del perfil de potencia, SOC y los criterios de calidad, con el objetivo de determinar cuál de ellos se desempeña de mejor manera para la aplicación bajo estudio.

- **Comparación funciones de pertenencia**

En las Figuras 25, 26, 27 Y 28 se observa las funciones de pertenencia de las entradas P_E y SOC ajustadas por el algoritmo DE y comparadas con el algoritmo CS y PSO. Cabe recalcar que el proceso de ajuste de las MF es metaheurístico y aleatorio, por lo que la búsqueda de estas depende totalmente del algoritmo elegido.

- **Entrada P_E :**




Figura 25 MF ajustadas entrada P_E , DE vs CS

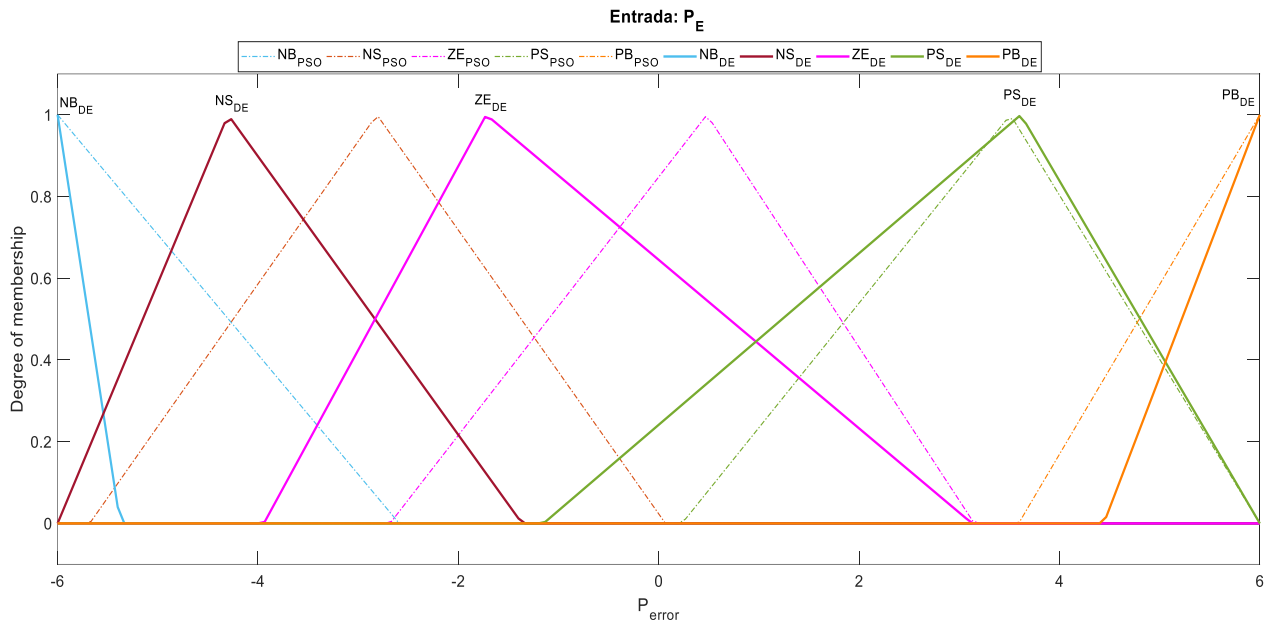


Figura 26 MF ajustadas entrada P_E , DE vs PSO

- Entrada SOC:




Figura 27 MF ajustadas entrada SOC, DE vs CS

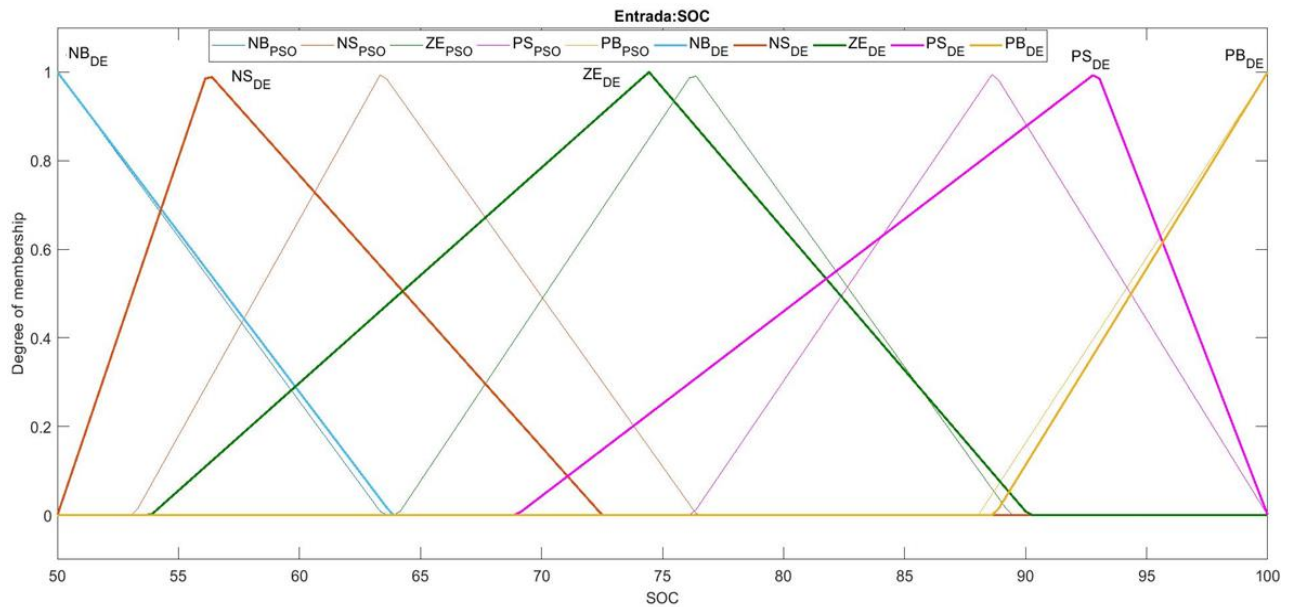


Figura 28 MF ajustadas entrada *SOC*, DE vs PSO

El resultado de las funciones de pertenencia se ajusta de acuerdo al proceso de cada algoritmo a pesar de que las MF se distribuyen a lo largo del mismo rango de variación de cada entrada: el rango de variación de *SOC* con las restricciones de la batería y el rango de P_E que supone un valor de 6kW. Este proceso de ajuste para los tres algoritmos se inició con la búsqueda de soluciones aleatorias a partir de una distribución uniforme, esto con el objetivo de mantener la simetría en la distribución de las MF. La diferencia entre MF encontradas con el algoritmo DE y los dos algoritmos de comparación (CS y PSO) es notable, esta variación se ve reflejada en la variable de salida, en su rango y en la base de reglas que se explicarán más adelante.

Para la salida del controlador P_{FLC} , las MF variarán de acuerdo a la entrada y el espacio de búsqueda dependerá de cada algoritmo como se muestra a continuación:




Figura 29 MF ajustadas salida P_{FLC} , DE vs CS

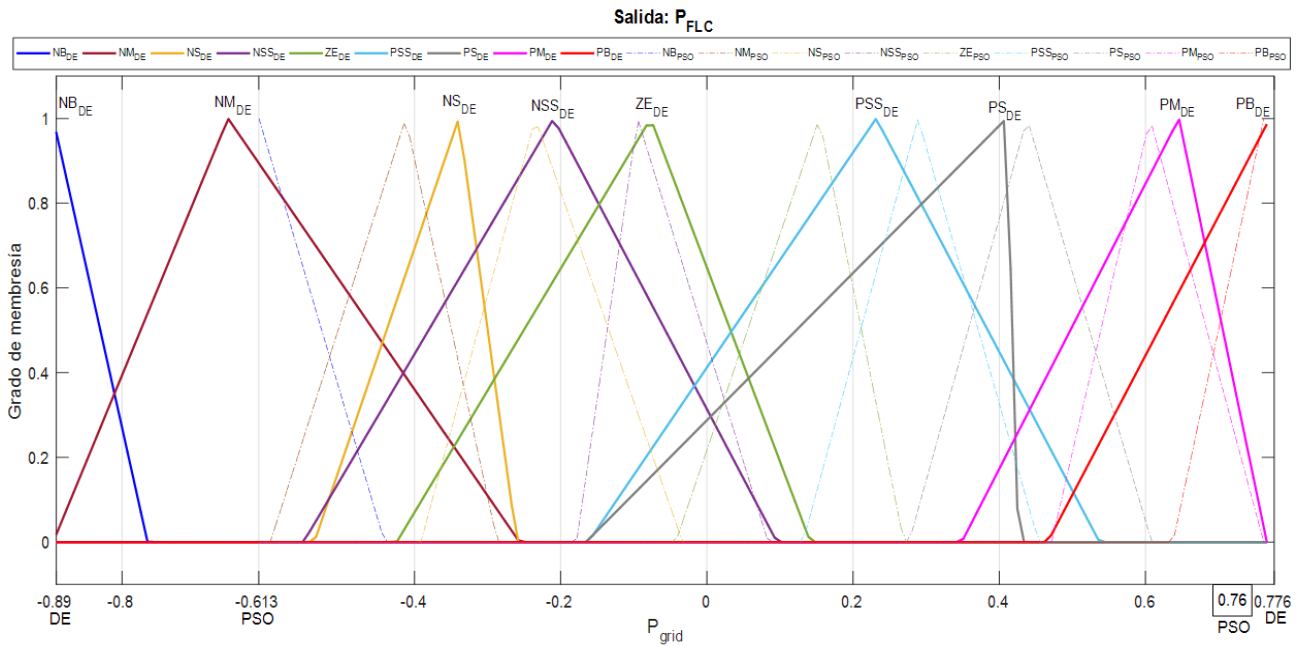


Figura 30 MF ajustadas salida P_{FLC} , DE vs PSO

Se observa que el rango para las MF de cada algoritmo es distinto, esto se debe a que cada algoritmo mediante ajuste y variación encontró la mejor solución en diferente rango de salida. Este rango de salida equivale a la potencia mínima y máxima asignada a la salida del controlador como se muestra en las Tablas 9, 12 y 13 pertenecientes a las posiciones de las MF de P_{FLC} con el algoritmo DE, CS y PSO respectivamente.

Tabla 12

Parámetros de funciones de pertenencia y rango de la Salida del FLC por CS

	<i>NB</i>			<i>NM</i>			<i>NS</i>			<i>NSS</i>		
Fuzzy EMS-FC-CS	-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-CS	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-CS	0.56	0.78	0.78	-0.51	0.79							

Fuente: (García-Gutiérrez, 2018)

Tabla 13

Parámetros de funciones de pertenencia y rango de la Salida del FLC 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							

Fuente: (Pacheco, 2019)

De la Tabla 9 se observa que el algoritmo DE tiene un rango de salida ligeramente mayor hacia el valor de potencia mínimo asignado a la salida del controlador de -0.89 , lo que hace que tanto la base de reglas como la salida difiera considerablemente.

- **Base de reglas**

Se analiza la superficie de control para evaluar la evolución de la salida ante las entradas dentro del universo de discurso. Gracias a las funciones de pertenencia de las variables de entrada y de salida, así como el rango de salida que difiere en cada EMS, se observan en la Figura 31 las superficies de EMS-PSO, EMS-CS y EMS-DE respectivamente:




Figura 31 Superficie EMS-PSO, EMS-CS y EMS-DE

Por la forma de la superficie el algoritmo DE este tiene reglas que cambian significativamente en comparación a los otros algoritmos, como se observa en la Tabla 10.

Por ejemplo, en condiciones de carga total del SOC de la batería: $SOC = 100\%$ y $P_E = 6$, esto implica que: “SI el error de la MG es PB, es decir la potencia neta de MG es mucho mayor al valor medido, y el SOC es PB, es decir que está totalmente cargada $SOC \gg SOC_{REF}$, ENTONCES el comportamiento de la salida del controlador con EMS-DE disminuye fuertemente la potencia de la red para descargar el almacenamiento, es decir $P_{FLC} \ll 0$ ”. A diferencia de EMS-PSO y EMS-CS donde la salida recae en ZE.

Para un valor donde $SOC = 50\%$ y $P_E = -6$, es decir que la batería está completamente descargada $SOC \ll SOC_{REF}$ y la potencia neta de MG es mucho mayor al valor medido, entonces la salida del controlador incrementa de a poco la potencia de red para cargar el almacenamiento (PS), en cambio EMS-PSO y EMS-CS recaen en ZE.

El cambio de base de reglas es consecuencia de la evolución de la salida gracias a cada algoritmo de optimización, esto hace que la MG tenga un comportamiento diferente como se observa en las Tablas 3,5 y 10 afecta a los valores de los criterios de calidad y la EMS en sí.

- **Análisis EMS**

La simulación de la estrategia EMS-DE propuesta se realiza con los datos históricos de julio de 2013 a julio de 2014. Además, los resultados de la simulación se comparan con las estrategias basadas en los algoritmos de CS y PSO descritas anteriormente. La Figura 32 muestra la comparación del perfil de potencia de la red para las tres estrategias. Como se puede observar, los resultados logrados a través de las estrategias son muy similares y bastante aceptables. En la Figura

33, la estrategia EMS-DE logra una potencia máxima alimentada a la red de $P_{G,MIN} = -1.598$ kW, a diferencia de las otras dos propuestas que tienen un $P_{G,MIN} = -1.71$ y $P_{G,MIN} = -1.66$ kW respectivamente. El signo negativo del perfil de potencia indica una potencia absorbida por la red eléctrica. Cabe recalcar que en las tres estrategias reducen de manera similar los picos y fluctuaciones como se muestra en la Figura 32 (círculos negros).




Figura 32 Comparación de perfil de potencia y SOC de batería entre EMS-DE, EMS-CS y EMS-PSO con picos máximos

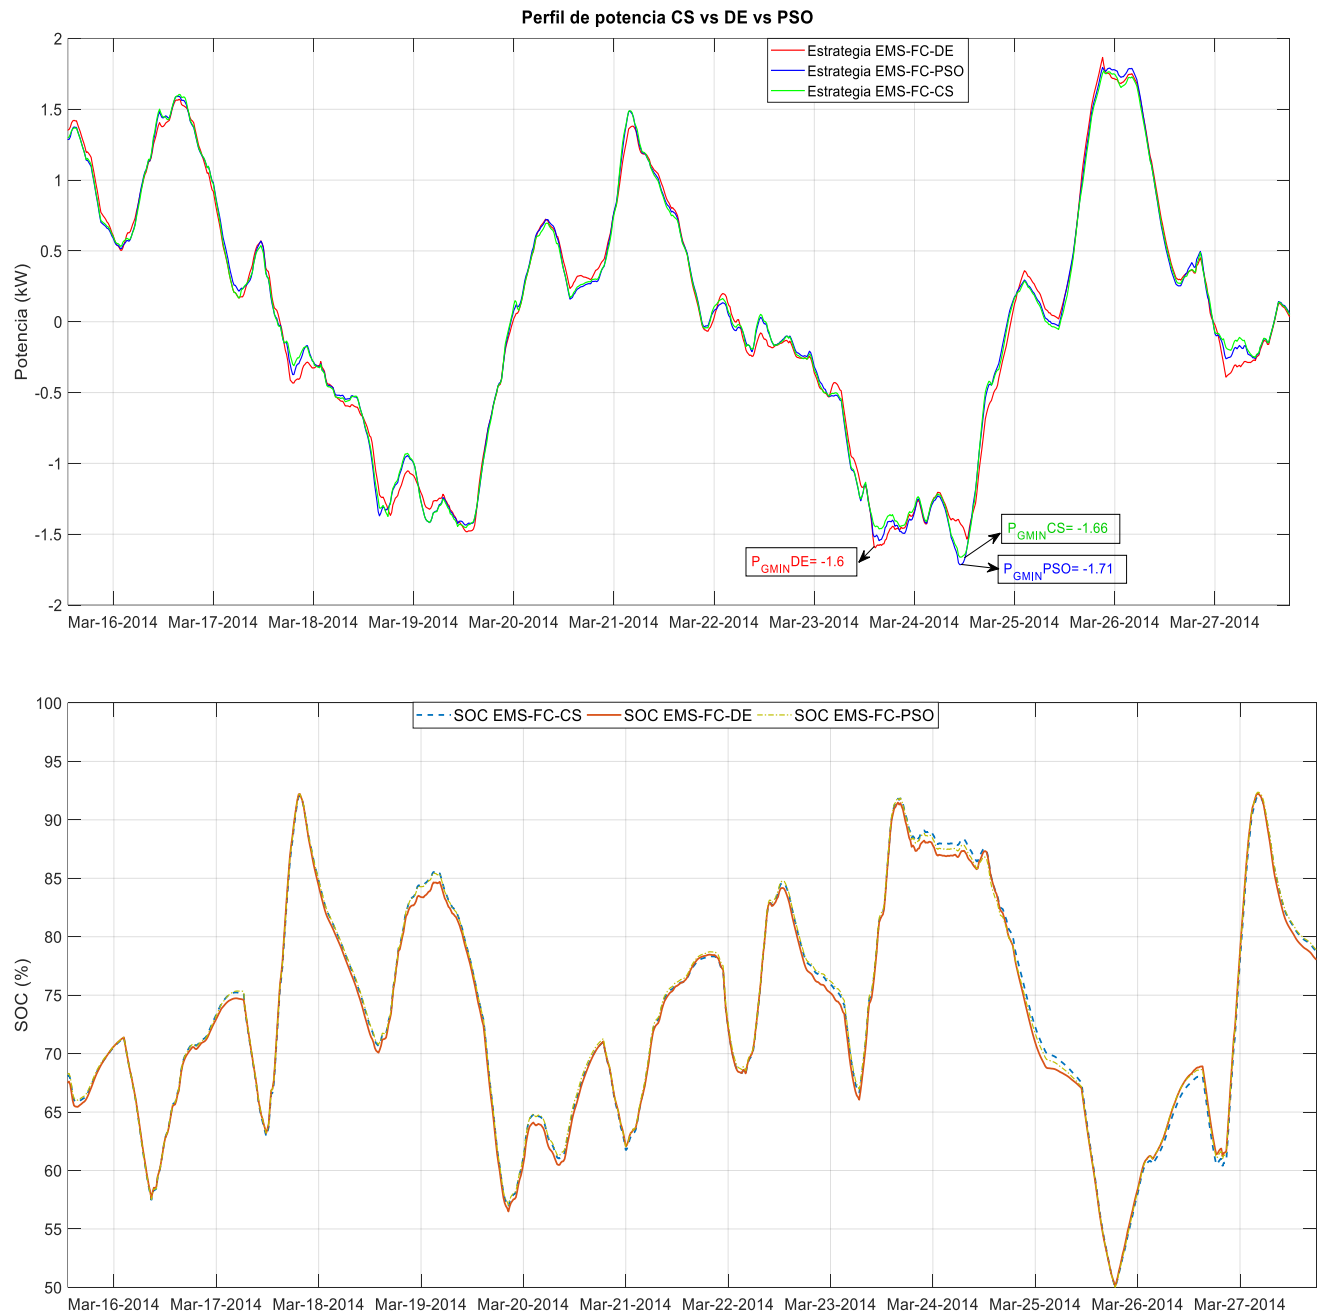


Figura 33 Comparación de perfil de red y SOC de batería entre EMS-DE, EMS-CS y EMS-PSO con picos mínimos

En las Figura 34 y 35 también se compara el perfil de potencia de la red con la evolución del SOC lograda por las tres estrategias analizadas en los periodos donde se presenta los picos máximos

y mínimos de cada EMS. Los resultados indican que la estrategia EMS-DE, a pesar de tener el menor pico positivo y negativo, presenta puntos donde las fluctuaciones son más notorias a diferencia de las otras dos estrategias, incluso el SOC evidencia que en EMS-CS y EMS-PSO oscila más cerca del 75% que el EMS-DE.

Por otro lado, en la Figura 35 ilustra la evolución del SOC de la batería con su perfil promedio diario alcanzado por las tres EMS analizadas. Las tres estrategias siguen el mismo patrón de evolución. Sin embargo, si se toma un tramo del SOC como en la Figura 35 se puede observar que el EMS-CS y el EMS-PSO tienen mayor tendencia a centrarse en el 75% de la capacidad nominal de la batería.




Figura 34 Resultados de la simulación SOC promedio diario EMS-DE, EMS-PSO y EMS-CS




Figura 35 Comparación de la evolución SOC en el mes de septiembre 2013

El comportamiento mejorado de la evolución del SOC de la batería se puede evidenciar en la Figura 37, que muestra el histograma del SOC. Se observa que durante el 47.2% del año en estudio, el SOC del batería alcanzado por la estrategia EMS-DE propuesta se mantiene en un rango entre 70% y 80% de la capacidad nominal de la batería. Este valor no es el mejor si se consideran las estrategias EMS-PSO y EMS-CS, donde predomina el valor de EMS-CS, en donde el 48.35% del año se mantiene en el rango nominal. Esto considera una ligera diferencia de 1.15% en el periodo de tiempo, lo que ayuda a que el ESS compense fluctuaciones que puedan presentarse en la MG.

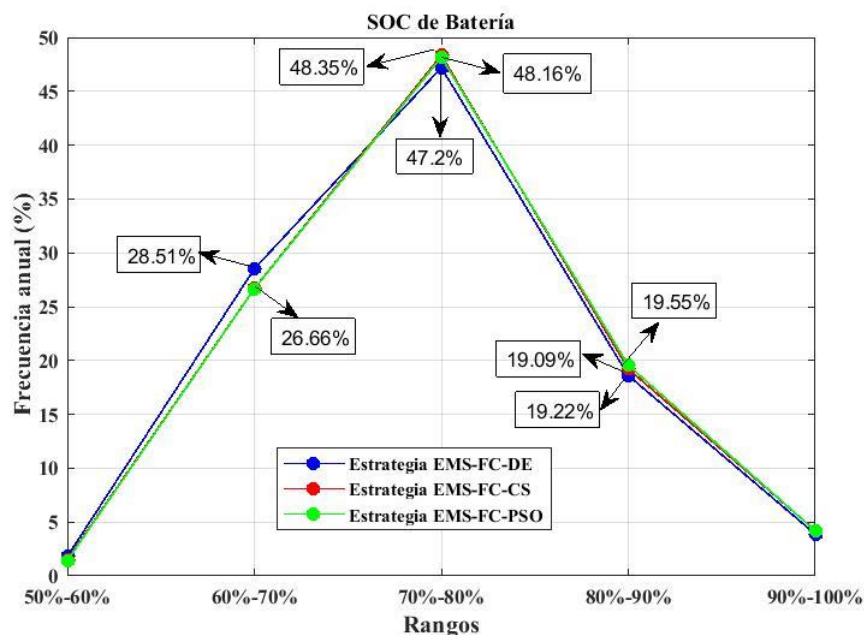


Figura 36 Histograma (en %) de los rangos de batería SOC establecidos para EMS-DE, EMS-CS y EMS-PSO

Por último, el comportamiento de los EMS propuestos se verifica mediante el cálculo de los criterios de calidad descritos en el capítulo 3. Los resultados se resumen en la Tabla 14:

Tabla 14
Comparación de los criterios de calidad de EMS

	$P_{G,MAX}[kW]$	$P_{G,MIN}[kW]$	$MPD[W/h]$	$APD[W/h]$	PVR	PPV	Función de costo
Fuzzy EMS-FC (Diego Arcos-Aviles, Guinjoan, et al., 2018)	2.56	-1.89	486	0.34	75	1.26	-
Fuzzy EMS-FC-CS	2.51	-1.66	472	0.32	75	1.25	5.37
Fuzzy EMS-FC-DE	2.50	-1.598	487	0.32	74	1.29	5.35
Fuzzy EMS-FC-PSO	2.51	-1.71	489.44	0.32	76	1.26	5.45

Se observa que, aunque los valores de cada criterio se asemejan, la estrategia EMS-CS logra una reducción importante en el criterio MPD , con respecto a las otras estrategias. En cuanto al EMS-DE y EMS-CS, los indicadores $P_{G, MAX}$, $P_{G, MIN}$ se redujeron en 0.3% y 3.73%, por el contrario, MPD no se pudo reducir y aumentó en un 79.6% en comparación al de CS, y en un 3.2% en el criterio PPV . Por otro lado, con respecto al EMS-PSO, el indicador más significativo es MPD donde el MPD del EMS-DE se ha reducido en un 0.37%. Estos resultados indican que a pesar de que la estrategia con el algoritmo DE dio un resultado favorable para el rendimiento de la MG al ser comparado con el EMS de la búsqueda Cuckoo este último presenta mejores características y se ajusta de mejor manera a la MG del caso de estudio.

CAPITULO 5

CONCLUSIONES Y RECOMENDACIONES

5.1. Conclusiones

La estrategia EMS -DE logra una potencia máxima alimentada a la red de $P_{G,MIN} = -1.598$ kW, a diferencia de las propuestas de EMS-PSO y EMS-CS que tienen un $P_{G,MIN} = -1.71$ y $P_{G,MIN} = -1.66$ kW respectivamente . A pesar de que la estrategia EMS-DE tiene el menor pico positivo y negativo en el perfil de red, presenta puntos donde las fluctuaciones son más notorias a diferencia de las otras dos estrategias, incluso el SOC evidencia que el EMS-CS y EMS-PSO oscila más cerca del 75% que el EMS-DE.

El comportamiento de la estrategia EMS-DE con respecto a la evolución del SOC de la batería en el año de estudio, la batería se mantuvo en la capacidad nominal de 70%-80% el 47.2% del año, a diferencia del EMS-CS tuvo un mejor desempeño, ya que se mantuvo el 48.35% del año, una diferencia de 1.15% equivalente a aproximadamente 6 días de diferencia.

La estrategia EMS con el algoritmo DE propuesta ha mejorado el perfil de potencia de la red y la evolución del SOC de la batería y cumple con los objetivos propuestos, sin embargo, al compararse con las otras estrategias, la que mejor se ajusta a la aplicación de la MG es el EMS-CS, seguido del EMS-DE y finalmente el EMS-PSO. Esto se puede observar también cuando se analiza los parámetros de calidad. La estrategia EMS-CS logra una reducción importante en el criterio MPD , con respecto a las otras estrategias. En cuanto al EMS-DE y EMS-CS, los indicadores $P_{G,MAX}$, $P_{G,MIN}$ se redujeron en 0.3% y 3.73%, por el contrario, MPD no se pudo reducir

y aumentó en un 79.6%, y en un 3.2% en el criterio *PPV*. En cambio, el *MPD* del EMS-DE se reduce en un 0.37% en comparación al *MPD* obtenido con el EMS-PSO.

5.2.Recomendaciones

Definir los parámetros de los algoritmos de optimización de acuerdo al caso de estudio y requerimientos del problema, por ejemplo, en el caso de DE, seleccionar *Cr* y *F*, de acuerdo a la experticia o a modo de ensayo, ya que al ser un proceso metaheurístico se pueden hallar nuevas soluciones que generen nuevos resultados los cuales pueden ajustarse o no al problema.

Iniciar con una distribución uniforme las funciones de pertenencia para mantener la simetría de las mismas en el rango del universo de discurso.

5.3.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

- Arcos-Aviles, D., Gordillo, R., Guinjoan, F., Sanchis, P., Pascual, J., Marietta, M. P., ... Ibarra, A. (2018). Fuzzy-based energy management of a residential electro-thermal microgrid based on power forecasting. *Proceedings: IECON 2018 - 44th Annual Conference of the IEEE Industrial Electronics Society*, 1824–1829. <https://doi.org/10.1109/IECON.2018.8591575>
- Arcos-Aviles, D., Guinjoan, F., Marietta, M. P., Pascual, J., Marroyo, L., & Sanchis, P. (2016). Energy management strategy for a grid-tied residential microgrid based on Fuzzy Logic and power forecasting. *IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society*, 4103–4108. <https://doi.org/10.1109/IECON.2016.7793088>
- Arcos-Aviles, D., Guinjoan, F., Pascual, J., Marroyo, L., Sanchis, P., Gordillo, R., ... Marietta, M. P. (2019). *A Review of Fuzzy-Based Residential Grid-Connected Microgrid Energy Management Strategies for Grid Power Profile Smoothing*. https://doi.org/10.1007/978-981-13-3284-5_8
- 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. *Applied Energy*, 205(May), 69–84. <https://doi.org/10.1016/j.apenergy.2017.07.123>
- Arcos-Aviles, D., Pascual, J., Marroyo, L., Sanchis, P., & Guinjoan, F. (2018). Fuzzy Logic-Based Energy Management System Design for Residential Grid-Connected Microgrids. *IEEE Transactions on Smart Grid*, 9(2), 530–543. <https://doi.org/10.1109/TSG.2016.2555245>
- Arcos-Aviles, D., Sotomayor, D., Proano, 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. *IEEE International Symposium on Industrial Electronics*, 99–105. <https://doi.org/10.1109/ISIE.2017.8001230>
- Arunachalam, V. (2008). *The University Of Western Ontario Department Of Civil And Environmental Engineering Water Resources Research Report Optimization Using Differential Evolution*.
- Bujok, P., Tvrđík, J., & Poláková, R. (2017). Nature-inspired algorithms in real-world optimization problems. *Mendel*, 23(1), 7–14. <https://doi.org/10.1155/2015/359203>
- Choi, J. H., Lee, K., & Park, C. (2017). Differential Evolution. *KSAS 2017 Fall Conference*, 370–371. <https://doi.org/10.1007/3-540-31306-0>
- Fister, I., Yang, X. S., Brest, J., & Fister, D. (2013). A brief review of nature-inspired algorithms for optimization. *Elektrotehniski Vestnik/Electrotechnical Review*, 80(3), 116–122.
- García-Gutiérrez, G. (2018). *Ajuste de los parámetros del controlador fuzzy logic del sistema de gestión energética de una microrred electrotérmica mediante el algoritmo de búsqueda de Cuckoo*.
- García-Gutiérrez, G., Arcos-Aviles, D., Carrera, E. V, Guinjoan, F., Motoasca, E., Ayala, P., & Ibarra, A. (2019). *Fuzzy Logic Controller Parameter Optimization Using Metaheuristic Cuckoo Search Algorithm for a Magnetic Levitation System*. <https://doi.org/10.3390/app9122458>
- Lasseter, R. H. (2002). MicroGrids. *2002 IEEE Power Engineering Society Winter Meeting. Conference Proceedings (Cat. No.02CH37309)*, 1, 305–308. <https://doi.org/10.1109/PESW.2002.985003>
- Lindfield, G., & Penny, J. (2017). Evolutionary Algorithms. In *Introduction to Nature-Inspired Optimization* (pp. 19–47). <https://doi.org/10.1016/B978-0-12-803636-5.00002-5>

- Meng, L., Sanseverino, E. R., Luna, A., Dragicevic, T., Vasquez, J. C., & Guerrero, J. M. (2016). *Microgrid supervisory controllers and energy management systems: A literature review. Renewable and Sustainable Energy Reviews*, 60, 1263–1273. <https://doi.org/10.1016/j.rser.2016.03.003>
- Olatomiwa, L., Mekhilef, S., Ismail, M. S., & Moghavvemi, M. (2016). Energy management strategies in hybrid renewable energy systems: A review. *Renewable and Sustainable Energy Reviews*, Vol. 62, pp. 821–835. <https://doi.org/10.1016/j.rser.2016.05.040>
- Oriti, G. (2018). *Calhoun: The NPS Institutional Archive DSpace Repository Power Electronics-Based Energy Management System for DoN Microgrids Postgraduate School [video]*. Retrieved from <http://hdl.handle.net/10945/60858>
- Pacheco, D. (2019). *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*.
- 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. <https://doi.org/10.1016/j.apenergy.2015.08.040>
- 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. <https://doi.org/10.3390/en7010210>
- Passino, K. M., & Yurkovich, S. (1998). *Fuzzy Control*.
- Santana, L. (2004). *Un algoritmo basado en Evolución Diferencial para resolver problemas multiobjetivo*.
- Storn, R., & Price, K. (1995). *Evolución diferencial: un esquema adaptativo simple y eficiente para*

la optimización global sobre espacios continuos .

Vera, Y. E. G., Dufo-López, R., & Bernal-Agustín, J. L. (2019). *Energy management in microgrids with renewable energy sources: A literature review. Applied Sciences (Switzerland)*, 9(18).
<https://doi.org/10.3390/app9183854>

Wu, J., Yan, J., Jia, H., Hatziargyriou, N., Djilali, N., & Sun, H. (2016, April 1). *Integrated Energy Systems. Applied Energy*, 167, 155–157. <https://doi.org/10.1016/j.apenergy.2016.02.075>

Yang, X. (2010). *Nature-Inspired Optimization Algorithms*.

Yang, X., & Press, L. (1995). *Chapter 5 Genetic algorithms. In Advances in Exploration Geophysics (Vol. 4)*. [https://doi.org/10.1016/S0921-9366\(06\)80006-X](https://doi.org/10.1016/S0921-9366(06)80006-X)

Zang, H., Zhang, S., & Hapeshi, K. (2010). *A review of nature-inspired algorithms. Journal of Bionic Engineering*, 7(SUPPL.), S232–S237. [https://doi.org/10.1016/S1672-6529\(09\)60240-](https://doi.org/10.1016/S1672-6529(09)60240-7)