



**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: AJUSTE DE LOS PARÁMETROS DEL CONTROLADOR FUZZY
LOGIC DEL SISTEMA DE GESTIÓN ENERGÉTICA DE UNA
MICRORRED ELECTROTÉRMICA MEDIANTE EL ALGORITMO DE
BÚSQUEDA DE CUCKOO.**

AUTOR: GARCÍA GUTIÉRREZ, GABRIEL MAURICIO

DIRECTOR: ING. ARCOS AVILÉS, DIEGO GUSTAVO PHD.

SANGOLQUÍ

2019



**DEPARTAMENTO DE ELÉCTRICA, ELÉCTRONICA Y
TELECOMUNICACIONES**

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

CERTIFICACIÓN

Certifico que el trabajo de titulación, “AJUSTE DE LOS PARÁMETROS DEL CONTROLADOR FUZZY LOGIC DEL SISTEMA DE GESTIÓN ENERGÉTICA DE UNA MICRORRED ELECTROTÉRMICA MEDIANTE EL ALGORITMO DE BÚSQUEDA DE CUCKOO” fue realizado por el señor García Gutiérrez, Gabriel Mauricio 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, 18 de abril del 2019

Firma:

Ing. Arcos Avilés, Diego Gustavo. PhD.

C.C.: 1710879444



**DEPARTAMENTO DE ELÉCTRICA, ELÉCTRONICA Y
TELECOMUNICACIONES**

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

AUTORÍA DE RESPONSABILIDAD

Yo, García Gutiérrez, Gabriel Mauricio, declaro que el contenido, ideas y criterios del trabajo de titulación: **"AJUSTE DE LOS PARÁMETROS DEL CONTROLADOR FUZZY LOGIC DEL SISTEMA DE GESTIÓN ENERGÉTICA DE UNA MICRORRED ELECTROTÉRMICA MEDIANTE EL ALGORITMO DE BÚSQUEDA DE CUCKOO"** 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, 18 de abril del 2019

Firma:

García Gutiérrez, Gabriel Mauricio

C.C.: 1718320946



DEPARTAMENTO DE ELÉCTRICA, ELÉCTRONICA Y

TELECOMUNICACIONES

CARRERA DE INGENIERÍA EN ELECTRÓNICA, AUTOMATIZACIÓN Y

CONTROL

AUTORIZACIÓN

Yo, García Gutiérrez, Gabriel Mauricio, autorizo a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de titulación: **“AJUSTE DE LOS PARÁMETROS DEL CONTROLADOR FUZZY LOGIC DEL SISTEMA DE GESTIÓN ENERGÉTICA DE UNA MICRORRED ELECTROTÉRMICA MEDIANTE EL ALGORITMO DE BÚSQUEDA DE CUCKOO”** en el Repositorio Institucional, cuyo contenido, ideas y criterios son de mi responsabilidad.

Sangolquí, 18 de abril del 2019

Firma:

García Gutiérrez, Gabriel Mauricio

C.C.: 1718320946

DEDICATORIA

A mis padres María y Jorge por su trabajo, cariño y constante apoyo en todos estos años y en los que están por venir.

A mis hermanos Gabriela y Alex por su cariño, amistad y compañía incondicional.

Gabriel García Gutiérrez

AGRADECIMIENTO

En primer lugar, quiero agradecer a mi tutor el Dr. Diego Arcos Avilés por su valiosa cuota de inspiración, apoyo y confianza para la realización del presente trabajo.

Agradezco a mis padres por su amor incondicional, por ser el motor de mi vida, por sus conocimientos, sabiduría, paciencia y por todos los valores que han sabido inculcarme.

A Melisa, por ser mi compañera sentimental durante estos últimos años, por todo el amor y apoyo en los momentos difíciles.

A mis amigos y profesores de la universidad, por todos los momentos, conocimientos y experiencias vividas.

A todos ustedes, muchas gracias

Gabriel García Gutiérrez

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.....	xii
ABSTRACT	xiii
CAPÍTULO I.....	1
1.1 Antecedentes.....	1
1.2 Definición del Problema.....	6
1.3 Justificación e Importancia.....	8
1.4 Alcance del Proyecto	10
1.5 Objetivos.....	11
1.5.1 Objetivo General	11
1.5.2 Objetivos Específicos.....	11
CAPÍTULO II	12
2.1 Descripción de la Microrred Electrotérmica	12
2.2 Criterios de Calidad de la Gestión Energética	14
2.2.1 Pico Máximo del Perfil de Red – $P_{G,MAX}$	15

2.2.2	Pico Mínimo del Perfil de Red - $P_{G,MIN}$	15
2.2.3	Rango de Variación de Potencia – PVR	15
2.2.4	Máxima Rampa de Potencia – MPD.....	16
2.2.5	Rampa de Media Potencia – APD	16
2.2.6	Variabilidad del Perfil de Red – PPV.....	17
2.3	Fuzzy Logic.....	17
2.3.1	Controlador Fuzzy Logic	18
2.4	Optimización	20
2.4.1	Formulación de un Problema de Optimización	20
2.4.2	Método de la Suma Ponderada	22
2.4.3	Algoritmos Heurísticos y Metaheurísticos	23
2.5	Algoritmo de Búsqueda de Cuckoo	25
2.5.1	Vuelos de Lévy	25
2.5.2	Algoritmo de Búsqueda de Cuckoo con Vuelos de Lévy.....	28
CAPÍTULO III		30
3.1	Estrategia de Gestión Energética Basada en Control Fuzzy Logic	30
3.1.1	Bloque 1 – EWH Control.....	32
3.1.2	Bloque 2 – Filtro CMA.....	32
3.1.3	Bloque 3 – Filtro de 3H	33
3.1.4	Bloque 4 – Filtro Pasa Bajos.....	33
3.1.5	Bloque 5 – Estimador SOC.....	34
3.1.6	Bloque 6 – Controlador Fuzzy Logic	35
3.2	Valores de Referencia para Propósitos de Comparación.	35
CAPÍTULO IV		40

4.1	Definición de Parámetros Para Optimizar.....	40
4.2	Definición de Función de Costo.....	43
4.3	Implementación del Algoritmo de Búsqueda de Cuckoo	45
4.3.1	Definición de Parámetros Iniciales del Algoritmo	45
4.3.2	Generación de Población Inicial	46
4.3.3	Intensificación o Explotación	51
4.3.4	Diversificación o Exploración	53
4.4	Diagrama de Flujo del Algoritmo Implementado	55
CAPÍTULO V		56
5.1	Análisis de Resultados	56
CAPÍTULO VI.....		64
6.1.	Conclusiones	64
6.2.	Recomendaciones.....	65
6.3.	Trabajos Futuros.....	65
BIBLIOGRAFÍA.....		66
ANEXOS - PERMISOS DE USO DE CONTENIDO CON COPYRIGHTH		

ÍNDICE DE TABLAS

Tabla 1. <i>Base de Reglas del Controlador Estrategia EMS-FC</i>	38
Tabla 2. <i>Criterios de calidad de la gestión energética Estrategia EMS-FC</i>	39
Tabla 3. <i>Base de Reglas Inicial del Controlador</i>	42
Tabla 4. <i>Valores para normalización de funciones objetivo</i>	44
Tabla 5. <i>Preferencias de las funciones objetivo de optimización</i>	45
Tabla 6. <i>Parámetros iniciales del algoritmo de búsqueda de Cuckoo</i>	46
Tabla 7. <i>Solución aleatoria a partir de una base de reglas inicial (Tabla 3)</i>	51
Tabla 8. <i>Comparación de posiciones de MF para la entrada P_E</i>	57
Tabla 9. <i>Comparación de posiciones de MF para la entrada SOC</i>	58
Tabla 10. <i>Comparación de posiciones de MF y rango de salida para la variable P_{FLC}</i>	59
Tabla 11. <i>Base de Reglas Estrategia EMS-FC optimizadas mediante el algoritmo CS</i>	60
Tabla 12. <i>Base de Reglas Estrategia EMS-FC optimizadas mediante algoritmos heurísticos</i>	60
Tabla 13. <i>Criterios de calidad de la gestión energética Estrategia EMS-FC</i>	63

ÍNDICE DE FIGURAS

Figura 1. Suministro mundial total de energía primaria (1971 - 2015).....	1
Figura 2. Contribución energética por combustible.....	2
Figura 3. Fuentes generadoras de GHG.....	3
Figura 4. Emisiones de CO2 por combustible.....	3
Figura 5. Tasa de crecimiento anual de fuentes de energía renovable (1990 - 2015).....	4
Figura 6. Arquitectura de la Microrred Electrotérmica.....	13
Figura 7. Arquitectura de Controlador Fuzzy Logic.....	19
Figura 8. Tamaños de desplazamiento para diferentes índices de distribución de Lévy, β	27
Figura 9. Seudocódigo del algoritmo de búsqueda de Cuckoo.....	29
Figura 10. Diagrama de bloques Fuzzy EMS-FC.....	31
Figura 11. Diagrama de bloques de la predicción de potencia neta de la MG.....	33
Figura 12. Funciones de pertenencia para la entrada P_E , estrategia EMS-FC.....	36
Figura 13. Funciones de pertenencia para la entrada SOC, estrategia EMS-FC.....	36
Figura 14. Funciones de pertenencia para la salida P_{FLC} , estrategia EMS-FC.....	37
Figura 15. SOC de la batería y rangos. Estrategia EMS-FC.....	38
Figura 16. Perfil de potencia intercambiado con la red eléctrica. Estrategia EMS-FC.....	39
Figura 17. Rampas del perfil de potencia intercambiado. Estrategia EMS-FC.....	39
Figura 18. Definición inicial de funciones de pertenencia para la entrada P_E	40
Figura 19. Definición inicial de funciones de pertenencia para la entrada SOC	41
Figura 20. Definición inicial de funciones de pertenencia para la salida P_{FLC}	42
Figura 21. Generación de población inicial de nidos.....	47
Figura 22. Generación de nuevas MF para población inicial.....	50
Figura 23. Diagrama de flujo del algoritmo de búsqueda de Cuckoo implementado.....	55
Figura 24. MF optimizadas para la entrada P_E mediante el algoritmo CS.....	56
Figura 25. MF optimizadas para la entrada P_E mediante algoritmos heurísticos.....	57
Figura 26. MF optimizadas para la entrada SOC mediante el algoritmo CS.....	57
Figura 27. MF optimizadas para la entrada SOC mediante algoritmos heurísticos.....	58
Figura 28. MF optimizadas para la salida P_{FLC} mediante el algoritmo CS.....	58

Figura 29. MF optimizadas para la salida P_{FLC} mediante algoritmos heurísticos.....	59
Figura 30. Comparación de SOC de batería.....	61
Figura 31. Comparación de rangos de SOC.....	61
Figura 32. Comparación de perfiles de potencia intercambiada.....	62
Figura 33. Comparación de rampas de perfil de potencia.....	62

RESUMEN

El incremento de la demanda energética durante los últimos años ha venido de la mano con el incremento de la población y el desarrollo económico; sin embargo, la oferta energética actual está conformada principalmente por fuentes de energía no renovables y que contaminan el medio ambiente, aunque la tendencia hacia el uso de fuentes de energía renovable se ha incrementado. El desarrollo tecnológico ha permitido el desarrollo de sistemas de generación distribuida con el fin aprovechar las fuentes renovables de energía de una manera cada vez más eficiente, y esto ha dado lugar al surgimiento de las microrredes. Alrededor del mundo las microrredes cada vez más son el foco de estudio y desarrollo en cuanto a su arquitectura, elementos y objetivos de las estrategias de gestión energética asociadas; en este sentido, se han desarrollado una gran cantidad de estrategias de gestión energética para microrredes electrotérmicas basadas en un controlador Fuzzy Logic y cuya optimización de parámetros se ha realizado mediante procedimientos heurísticos de prueba y error con los cuales se han alcanzado buenos resultados; sin embargo, dichos procedimientos involucran un elevado costo computacional por lo que en el presente trabajo se propone la implementación de un algoritmo de optimización inspirado en la naturaleza (Cuckoo Search) que permita realizar la optimización de los parámetros en un menor tiempo y que garantice mayor calidad de la gestión energética.

PALABRAS CLAVE:

- **MICRORRED ELECTROTÉRMICA**
- **EFICIENCIA ENERGÉTICA**
- **ESTRATEGIA DE GESTIÓN ENERGÉTICA**
- **CUCKOO SEARCH**
- **CONTROLADOR FUZZY LOGIC**

ABSTRACT

The increase of energy demand during the last decades has gone hand in hand with population growth and economic development; however, the current energy supply is mainly made up of non-renewable energy sources that pollute the environment, although the trend towards the use of renewable energy sources has been increasing. Technological development has allowed the development of distributed generation systems in order to take advantage of renewable energy sources in an increasingly efficient manner, and this has led to the emergence of microgrids. Around the world, microgrids are increasingly the focus of study and development in terms of their architecture, elements, and objectives of the associated energy management strategies. In this regard, a great number of energy management strategies have been developed for electrothermal microgrids based on a Fuzzy Logic controller and whose parameter optimization has been carried out through heuristic procedures of trial and error with acceptable obtained results. However, these procedures involve a high computational cost so in the present work, the implementation of an optimization nature-inspired algorithm (Cuckoo Search) that allows the optimization of parameters in less time and ensures a higher quality of energy management, is proposed.

KEY WORDS:

- **ELECTROTHERMAL MICROGRID**
- **ENERGETIC EFFICIENCY**
- **ENERGY MANAGEMENT STRATEGY**
- **CUCKOO SEARCH**
- **FUZZY LOGIC CONTROLLER**

CAPÍTULO I

PLANTEAMIENTO DEL PROBLEMA DE INVESTIGACIÓN

1.1 Antecedentes

El crecimiento de la demanda energética, derivada del crecimiento poblacional y desarrollo económico, ha dado paso a un incremento del consumo de energía en las últimas décadas. De acuerdo con información publicada por la Agencia Internacional de Energía (IEA), el suministro total de energía primaria (energía disponible en la naturaleza, antes de ser convertida o transformada) en el mundo (TPES), obtenida principalmente de fuentes tales como: carbón, petróleo, gas natural, fusión nuclear, hídrica, biocombustibles y biomasa, otros (energía geotérmica, solar, calórica, eólica); se ha incrementado de 6101 millones de toneladas de petróleo equivalente (Mtoe) en el año 1973, a 13647 Mtoe en el año 2015 (International Energy Agency, 2017b), lo que representa un incremento del consumo energético del 124% en este período (International Energy Agency, 2017a).




Figura 1. Suministro mundial total de energía primaria (1971 - 2015).

Fuente: (International Energy Agency, 2017b).




Figura 2. Contribución energética por combustible.

Fuente: (International Energy Agency, 2017b).

El incremento en el consumo de energía durante los años ha tenido incidencia en la concentración de gases de efecto invernadero (GHG) en la atmósfera; así lo demuestran estudios realizados por la IEA, donde se afirma que las concentraciones de dióxido de carbono en la atmósfera se han ido incrementado de manera significativa durante el último siglo, comparada con información de la era preindustrial donde la concentración era de 280 partes por millón (ppm). En el año 2016, la concentración media era de 403 ppm, esto representa un incremento del 40% respecto a información de mediados de 1800 y un incremento medio de 2 ppm por año en los últimos 10 años. Un incremento significativo ha ocurrido también en los niveles de metano (CH_4) y óxido nitroso (N_2O) (International Energy Agency, 2017a).

En la Figura 3 se ilustra el impacto del uso de la energía en la generación de GHG, en la cual se evidencia que alrededor del 68% del total de fuentes de energía, son generadoras de estos gases.




Figura 3. Fuentes generadoras de GHG.

Fuente: (International Energy Agency, 2017a).

De la misma manera, los combustibles más demandados para la generación de energía (Figura 2), son los que aportan mayoritariamente en las emisiones de CO₂, tal y como se ilustra en la Figura 4.




Figura 4. Emisiones de CO₂ por combustible.

Fuente: (International Energy Agency, 2017a).

Con todos estos antecedentes, ha surgido en el mundo entero la necesidad de hacer frente a las emisiones de GHG; es así como muchos países en el mundo han centrado sus esfuerzos en mejorar la eficiencia energética e incrementar la producción de energía limpia.

Como resultado de estas iniciativas se ha producido un incremento sustancial del uso de energías renovables (RES) en las últimas décadas, donde la energía solar fotovoltaica (PV) y la energía eólica (WT) son el tipo de RES que han representado el mayor crecimiento a nivel mundial con una tasa media anual de 45.5% y 24%, respectivamente; esto desde el año 1990 hasta el 2015 (International Energy Agency, 2017c). En este sentido, los beneficios que las RES han demostrado en los últimos años, como reducción de la emisión de GHG (Kanchev, Lu, Colas, Lazarov, & Francois, 2011), han favorecido el desarrollo y desempeño de los sistemas de generación distribuida (DG), lo que los convierte actualmente, en una solución competitiva para los sistemas de potencia y las redes inteligentes o Smart Grids (Rahbar, Xu, & Zhang, 2015, p.).




Figura 5. Tasa de crecimiento anual de fuentes de energía renovable (1990 - 2015).

Fuente: (International Energy Agency, 2017c).

En este sentido, un sistema de generación distribuida consta de “pequeñas” fuentes de energía (bajo los 500kW), tales como: celdas solares, celdas de combustible, paneles fotovoltaicos, turbinas eólicas, baterías, ultra capacitores, entre otros (Lasseter, 2001).

De la misma manera, surgen nuevos inconvenientes al intentar combinar fuentes renovables junto con fuentes tradicionales de energía, algunos de estos pueden ser: fluctuaciones inesperadas en la respuesta de las RES las cuales pueden incidir en el voltaje y frecuencia de la red (Kanchev et al., 2011), requerimientos de electrónica de potencia, diferentes métodos de control y despacho (Lasseter, 2001).

Con el fin de solventar los inconvenientes mencionados en el párrafo anterior, nace el término de microrred (MG); cuyo concepto aparece inicialmente en el año 2001, donde R. H. Lasseter la define como un 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, 2001). Este concepto ha sido discutido por varios investigadores a lo largo de la última década (N. Hatziargyriou, Asano, Iravani, & Marnay, 2007; Nikos Hatziargyriou, 2014; Katiraei, Iravani, Hatziargyriou, & Dimeas, 2008). En la actualidad las MG son definidas como una red de distribución de bajo voltaje que consta de cargas, elementos de generación distribuida y sistemas de almacenamiento (ESS) que están conectados a la red de suministro principal en un punto de acoplamiento común (PCC), con una estrategia de gestión energética (EMS) asociada que les permite una operación confiable, segura y económica (Diego Arcos-Aviles et al., 2019; Olivares et al., 2014; Yazdanian & Mehrizi-Sani, 2014).

En este sentido, el EMS cumple una función crucial en el control del flujo de potencia entre los diferentes elementos de la MG y puede estar diseñada de acuerdo a ciertos objetivos (Diego Arcos-Aviles, Pascual, Marroyo, Sanchis, & Guinjoan, 2018), como pueden ser: minimización de costos de operación, maximización de ingresos, y minimización del perfil de potencia intercambiado con la red eléctrica (D. Arcos-Aviles, Sotomayor, et al., 2017; Diego Arcos-Aviles, Guinjoan, et al.,

2018; Diego Arcos-Aviles et al., 2019; Diego Arcos-Aviles, Pascual, et al., 2018; Pascual, Barricarte, Sanchis, & Marroyo, 2015; Pascual, Sanchis, & Marroyo, 2014).

Además, el EMS debe considerar la arquitectura de potencia de la MG y en particular la capacidad de gestión de los diferentes elementos que conforman la MG (conocer qué tipo de fuentes, cargas y elementos de almacenamiento se pueden controlar) (Diego Arcos-Aviles, Pascual, et al., 2018). Finalmente, una vez definida la arquitectura de la MG, se procede a realizar el diseño de la EMS mediante la aplicación de diferentes métodos (Arul, Ramachandaramurthy, & Rajkumar, 2015; Olivares et al., 2014; Yazdanian & Mehrizi-Sani, 2014).

Las nuevas reglamentaciones, incentivos económicos y penalizaciones impuestas por el operador de red, ha promovido el estudio a nivel mundial de la congestión en la línea eléctrica y la estabilidad de la red (Pascual et al., 2015). Estos estudios tienen como objetivo fundamental el disminuir las fluctuaciones y rampas de potencia del perfil intercambiado con la red eléctrica. Por lo que en la actualidad el diseño del EMS se enfoca principalmente en este objetivo.

1.2 Definición del Problema

Basados en estudios previos realizados en conjunto con universidades españolas: Universidad Politécnica de Cataluña (UPC) y Universidad Pública de Navarra (UPNA), se desarrollaron, a lo largo de los últimos 5 años, diversas estrategias de gestión energética basadas en un controlador Fuzzy Logic (FLC – Fuzzy Logic Control) con el objetivo de minimizar el perfil de potencia intercambiado con la red eléctrica y de esta manera cumplir con las restricciones impuestas por el operador de red (D. Arcos-Aviles et al., 2016; D. Arcos-Aviles, Pascual, et al., 2017; D. Arcos-Aviles, Sotomayor, et al., 2017; Diego Arcos-Aviles, Guinjoan, et al., 2018; Diego Arcos-Aviles et al., 2019; Diego Arcos-Aviles, Pascual, et al., 2018).

Las diversas estrategias de gestión energética mencionadas anteriormente fueron aplicadas a una microrred electrotérmica, obteniéndose resultados satisfactorios en la minimización del perfil de potencia intercambiado con la red eléctrica. Estas estrategias comparten un bloque en común, este bloque lo constituye el controlador Fuzzy Logic (FLC) que es el componente fundamental del EMS de estas estrategias debido a que el conocimiento heurístico acerca del comportamiento de la MG permite una fácil implementación de un EMS basado en un FLC (Diego Arcos-Aviles et al., 2019).

Sin embargo, el diseño del controlador Fuzzy Logic, dentro de una estrategia de gestión energética, conlleva la selección de numerosos parámetros como son: 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; que dificultan la adecuada selección de un conjunto de parámetros que minimicen el perfil de potencia intercambiado con la red eléctrica.

La selección de parámetros en estas estrategias se realizó mediante un proceso de optimización fuera de línea y de forma heurística, donde se utilizaron datos históricos de potencia renovable generada y consumo de carga de la residencia, y con el objetivo de minimizar una serie de criterios de calidad utilizados para cuantificar la calidad del perfil de potencia intercambiada con la red eléctrica.

Cabe recalcar que la aplicación de dicha optimización lleva un gran costo computacional, debido a que se requiere comprobar la minimización de los criterios de calidad para cada conjunto de parámetros del controlador, lo que puede resultar en un proceso infinito. Por esta razón, surge la necesidad de contar con un algoritmo de optimización más robusto y potente, que sea capaz de

realizar el ajuste de parámetros del FLC de una manera más rápida y eficiente, y que a su vez mejore la calidad del perfil de potencia intercambiada con la red eléctrica que presenta una MG electrotérmica residencial.

Por otro lado, los algoritmos inspirados en la naturaleza han llegado a ser muy populares a través de los años, un ejemplo de este tipo de algoritmos es el Algoritmo de Búsqueda de Cuckoo (X.-S. Yang, 2014); empleados para la optimización en campos, tales como: operación y control de sistemas de potencia (Balci & Valenzuela, 2004; Varol & Bingul, 2004), procesos químicos (Johnston, 2004), problemas de programación de trabajo (Wu, Lai, & Sun, 2008), problemas de enrutamiento de vehículos (Baker & Ayechev, 2003), redes móviles (Mehboob, Qadir, Ali, & Vasilakos, 2016), optimización multiobjetivo (X.-S. Yang & Deb, 2013), procesamiento de imágenes (Woźniak & Połap, 2014), entre otros.

Si se toman en cuenta estos antecedentes, y con el objetivo de minimizar el perfil de potencia intercambiado entre una microrred electrotérmica residencial y la red eléctrica, es necesario proponer la aplicación del algoritmo de búsqueda de Cuckoo para ajustar los parámetros del controlador Fuzzy Logic, el cual resulta ser el componente principal del EMS que gobierna el funcionamiento de la MG en estudio (Diego Arcos-Aviles, Guinjoan, et al., 2018; Diego Arcos-Aviles et al., 2019).

1.3 Justificación e Importancia

En función a lo expuesto en la sección anterior y con el objetivo de mejorar la sintonización del FLC, se plantea el estudio del ajuste de parámetros del controlador Fuzzy Logic del sistema de gestión energética de una microrred electrotérmica residencial conectada a la red eléctrica mediante el algoritmo de búsqueda de Cuckoo. Para tal efecto, se considerará posteriormente la formulación

de una función de costo global que comprenda, de una manera coherente, todos los criterios empleados para evaluar la calidad del perfil de potencia. Esta función será la función objetivo de optimización.

Una vez realizado el ajuste de parámetros del FLC, se podrá contar con una estrategia de gestión energética optimizada que minimice el perfil de potencia intercambiado con la red eléctrica y así contribuir a la disminución del consumo energético de una microrred residencial a nivel mundial.

Es necesario destacar que el producto de esta investigación contribuirá con la ejecución del **Plan Nacional de Desarrollo “Toda una Vida” 2017 – 2021** (Consejo Nacional de Planificación, 2017), que en su **Eje 2: “Sistema Económico Sostenible al Servicio de la Sociedad y el Ambiente”**, **Objetivo 5: “Impulsar la productividad y competitividad para el crecimiento económico sustentable de manera redistributiva y solidaria**, propone *“Incrementar de 60% al 90% la generación eléctrica a través de fuentes de energía renovable”*.

Además, este proyecto se enmarca dentro de los **Objetivos de Desarrollo Sostenible de la Agenda 2030** publicada por las Naciones Unidas en el año 2016 (CEPAL, 2015). En concreto:

Objetivo 7: “Garantizar el acceso a una energía asequible, segura, sostenible y moderna para todos”, **Meta 7.1: “De aquí a 2030, garantizar el acceso universal a servicios energéticos asequibles, fiables y modernos”**; **Meta 7.2: “De aquí a 2030, aumentar considerablemente la producción de energía renovable en el conjunto de fuentes energéticas”**; **Meta 7.a: “De aquí a 2030, aumentar la cooperación internacional para facilitar el acceso a la investigación y la tecnología relativas a la energía limpia, incluidas las fuentes renovables, la eficiencia energética**

y las tecnologías avanzadas y menos contaminantes de combustibles fósiles, y promover la inversión en infraestructura energética y tecnologías limpias”.

Objetivo 11: *“Lograr que las ciudades y los asentamientos humanos sean inclusivos, seguros, resilientes y sostenibles”*, **Meta 11.1:** *“De aquí a 2030, asegurar el acceso de todas las personas a viviendas y servicios básicos adecuados, seguros y asequibles y mejorar los barrios marginales”*.

Objetivo 12: *“Garantizar modalidades de consumo y producción sostenibles”*, **Meta 12.2:** *“De aquí a 2030, lograr la gestión sostenible y el uso eficiente de los recursos naturales”*; **Meta 12.a:** *“Ayudar a los países en desarrollo a fortalecer su capacidad científica y tecnológica para avanzar hacia modalidades de consumo y producción más sostenibles”*.

1.4 Alcance del Proyecto

Mediante el presente proyecto se pretende realizar el ajuste de parámetros y optimización de la estrategia de gestión energética basada en FLC y algoritmos de predicción, de una microrred electrotrémica residencial mediante el algoritmo de búsqueda de Cuckoo de acuerdo con lo expuesto anteriormente.

El ajuste de parámetros y la optimización de la estrategia de gestión energética basada en FLC se realizará mediante simulaciones numéricas a través de Matlab®. Para estas simulaciones se utilizarán datos históricos obtenidos en la MG de la Universidad Pública de Navarra en el periodo comprendido entre julio de 2013 a julio de 2014 con un periodo de muestreo $T_S = 900$. Los resultados del perfil de red y criterios de calidad obtenidos para el algoritmo de búsqueda de Cuckoo serán comparados con resultados de estudios previos (Diego Arcos-Aviles, Guinjoan,

et al., 2018; Diego Arcos-Aviles et al., 2019), para comprobar la robustez de la optimización de la estrategia de gestión energética.

1.5 Objetivos

1.5.1 Objetivo General

Desarrollar el algoritmo de búsqueda de Cuckoo para realizar el ajuste de los parámetros del controlador Fuzzy Logic del sistema de gestión energética de una microrred doméstica conectada a red.

1.5.2 Objetivos Específicos

- Definir una función de costo que incluya todos los criterios de calidad para la evaluación de la EMS.
- Implementar el algoritmo de búsqueda de Cuckoo para realizar el ajuste de parámetros de un FLC para el EMS de una microrred electrotérmica residencial.
- Comparar el perfil intercambiado con la red eléctrica obtenido con el EMS basado en un controlador Fuzzy Logic optimizado mediante algoritmos heurísticos y mediante el algoritmo metaheurístico de búsqueda de Cuckoo.

CAPÍTULO II

MARCO TEÓRICO

2.1 Descripción de la Microrred Electrotérmica

El controlador Fuzzy Logic de la estrategia de gestión energética que se optimizará en este trabajo está diseñada para trabajar sobre una microrred electrotérmica residencial con conexión a red (Diego Arcos-Aviles, Guinjoan, et al., 2018; Pascual et al., 2014). Dicha microrred está comprendida de los siguientes elementos y su arquitectura se muestra en la Figura 6 (Diego Arcos-Aviles, Guinjoan, et al., 2018) ©2018 IEEE:

- Un sistema híbrido de energía renovable (HRES) que incluye un generador fotovoltaico (PV) de 6 kW y una pequeña turbina eólica (WT) de 6kW.
- Un sistema de almacenamiento de energía (ESS), que consiste en un banco de baterías de plomo-ácido con una capacidad nominal de 72kWh.
- Demanda de carga doméstica, la cual involucra cargas eléctricas típicas (electrodomésticos, iluminación, etc.) con una potencia nominal de 7kW.
- Un sistema doméstico de agua caliente sanitaria (ACS) que consiste de un calentador eléctrico de agua (EWH) de 2kW, un conjunto de colectores solares térmicos de placas planas de 2 kW y un sistema de almacenamiento térmico representado por un tanque de almacenamiento de agua con una capacidad de 800 litros.

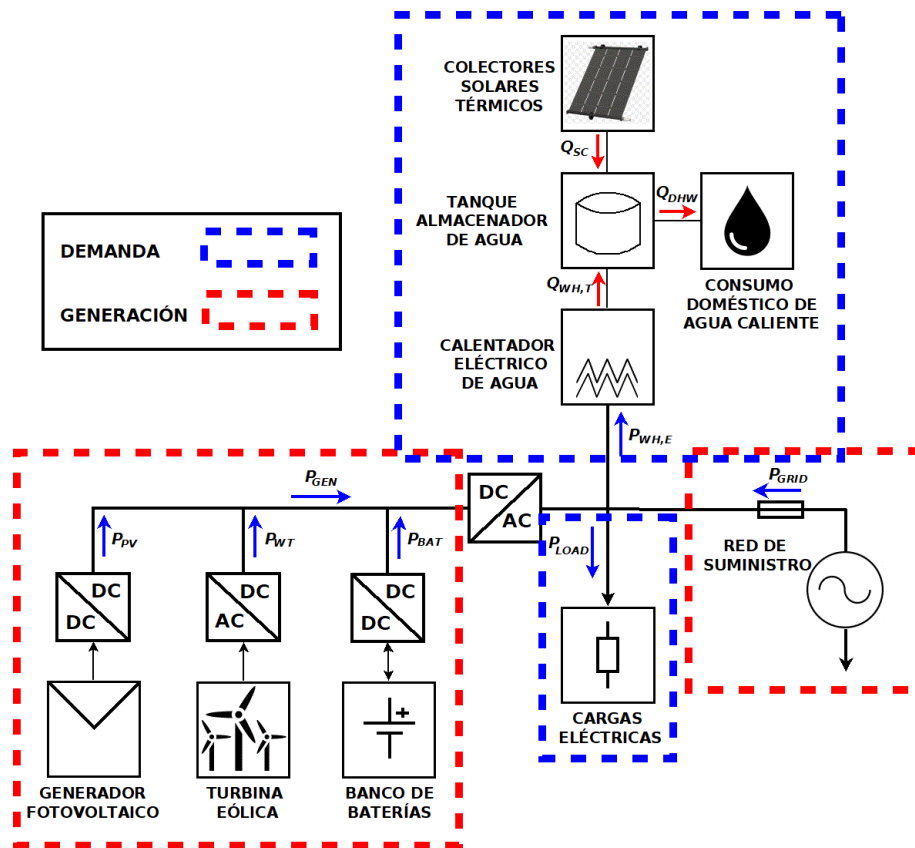


Figura 6. Arquitectura de la Microrred Electotérmica.

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

De acuerdo con la Figura 6, la microrred está constituida por elementos de generación y de demanda.

Por un lado, se tienen los elementos de generación: un generador fotovoltaico, un generador eólico, un banco de baterías y la red de suministro; cuya potencia entregada está representada por P_{PV} , P_{WT} , P_{BAT} y P_{GRID} , respectivamente; cabe recalcar que un flujo de potencia en sentido de las flechas en la Figura 6, representa un flujo positivo; además, $P_{BAT} > 0$ implica un proceso de descarga de la batería y $P_{BAT} < 0$ implica un proceso de carga de la batería, así como $P_{GRID} > 0$ implica una inyección de potencia por parte de la red de suministro hacia la microrred mientras que $P_{GRID} < 0$

implica que la red de suministro absorbe potencia de la microrred (D. Arcos-Aviles, Sotomayor, et al., 2017; Diego Arcos-Aviles, Guinjoan, et al., 2018; Diego Arcos-Aviles et al., 2019).

Por otro lado, se tienen elementos de demanda: cargas eléctricas y el sistema ACS cuya demanda de potencia está representada por P_{LOAD} y $P_{WH,E}$, respectivamente. Además, al referirnos al ACS como un sistema electrotérmico, se definen: la tasa de energía térmica transferida por parte del EWH hacia el sistema de almacenamiento térmico, $Q_{WH,T}$, la tasa de energía térmica recolectada y transferida hacia el sistema de almacenamiento térmico, Q_{SC} , y la tasa de energía térmica transferida desde el sistema de almacenamiento térmico hacia el consumo de agua caliente doméstica, Q_{DHW} (D. Arcos-Aviles, Sotomayor, et al., 2017; Diego Arcos-Aviles, Guinjoan, et al., 2018; Diego Arcos-Aviles et al., 2019).

De acuerdo con la arquitectura descrita anteriormente, se pueden definir las expresiones para la potencia intercambiada con la red de eléctrica de suministro, P_{GRID} , y para la potencia neta de la Microrred, P_{LG} , de la siguiente manera: (D. Arcos-Aviles, Sotomayor, et al., 2017; Diego Arcos-Aviles, Guinjoan, et al., 2018; Diego Arcos-Aviles et al., 2019):

$$P_{GRID} = P_{LOAD} - P_{GEN} - P_{BAT} + P_{WH,E} \quad (2.1)$$

$$P_{LG} = P_{LOAD} - P_{GEN} + P_{WH,E} \quad (2.2)$$

$$P_{GRID} = P_{LG} - P_{BAT} \quad (2.3)$$

2.2 Criterios de Calidad de la Gestión Energética

Los criterios de calidad de la gestión energética son definidos con el fin de evaluar y comparar el comportamiento del perfil de potencia intercambiado con la red eléctrica, de la MG

electrotérmica; para tal efecto, se debe considerar que para un mejor desempeño los criterios de calidad deben ser minimizados. En base a los criterios de evaluación definidos en trabajos anteriores (D. Arcos-Aviles et al., 2016; D. Arcos-Aviles, Pascual, et al., 2017; D. Arcos-Aviles et al., 2015; Diego Arcos-Aviles et al., 2019; Diego Arcos-Aviles, Pascual, et al., 2018; Pascual et al., 2015, 2014), se ha considerado un conjunto de 6 parámetros de calidad, los cuales serán descritos a continuación y en base a los cuales se formulará la función de costo para la optimización mediante el algoritmo de búsqueda de Cuckoo.

2.2.1 Pico Máximo del Perfil de Red – $P_{G,MAX}$

Es la potencia máxima inyectada por la red eléctrica en un año y está definido mediante la siguiente expresión:

$$P_{G,MAX} = \max(P_{GRID}) \quad (2.4)$$

2.2.2 Pico Mínimo del Perfil de Red - $P_{G,MIN}$

Es la potencia máxima absorbida por la red eléctrica en un año y está definido mediante la siguiente expresión:

$$P_{G,MIN} = \min(P_{GRID}) \quad (2.5)$$

2.2.3 Rango de Variación de Potencia – PVR

Cuantifica la eficacia de la estrategia de gestión. Está definido como:

$$PVR = \frac{P_{G,MAX} - P_{G,MIN}}{P_{LG,MAX} - P_{LG,MIN}} \quad (2.6)$$

Donde $P_{LG,MAX}$ y $P_{LG,MIN}$ son la máxima y mínima fluctuación del balance de potencia de la MG (2.2).

2.2.4 Máxima Rampa de Potencia – *MPD*

Representa la máxima tasa de cambio (máxima pendiente producida por dos muestras consecutivas) del perfil de red. Este criterio se expresa en W/h y se encuentra definido como el máximo valor absoluto de las pendientes del perfil de red en el año en estudio, de la siguiente manera:

$$MPD = \max(|P_{GRID}^{\square}|) \quad (2.7)$$

$$P_{GRID}^{\square} = \frac{P_{GRID}(n) - P_{GRID}(n-1)}{T_s} \quad (2.8)$$

Donde P_{GRID}^{\square} es la pendiente producida por dos muestras consecutivas del perfil de red y T_s es el periodo de muestreo.

2.2.5 Rampa de Media Potencia – *APD*

Está definido como el valor absoluto, expresado en W/h, del valor medio anual de las pendientes del perfil de red. Se expresa de la siguiente manera:

$$APD = \frac{1}{N} \sum_{n=1}^N |P_{GRID}^{\square}| \quad (2.9)$$

Donde N es el número de muestras en un año.

2.2.6 Variabilidad del Perfil de Red – *PPV*

Mide la estabilidad del perfil intercambiado con la red eléctrica. Se encuentra definido de la siguiente manera:

$$PPV = \frac{\sqrt{\sum_{f=f_i}^{f_f} P_{GRID,f}^2}}{P_{DC}} \quad (2.10)$$

$$P_{DC} = \frac{1}{N} \sum_{n=1}^N P_{GRID}(n) \quad (2.11)$$

Donde $P_{GRID,f}$ es la potencia de armónico a la frecuencia f , f_i y f_f son el valor inicial y final de frecuencia, y P_{DC} es el valor medio de potencia en un año. Este criterio evalúa únicamente frecuencias con periodos de variación de una semana o menos, debido a que la estrategia de gestión busca compensar las variaciones diarias de potencia (D. Arcos-Aviles et al., 2016; D. Arcos-Aviles, Pascual, et al., 2017; D. Arcos-Aviles et al., 2015; Diego Arcos-Aviles et al., 2019; Diego Arcos-Aviles, Pascual, et al., 2018; Pascual et al., 2015, 2014). Por lo que los valores de f_i y f_f se definen de la siguiente manera:

$$f_i = \frac{1}{T_{Semana}} = \frac{1}{7 \cdot 24 \cdot 3600} = 1.65 \cdot 10^{-6} \text{ Hz} \quad (2.12)$$

$$f_f = \frac{f_s}{2} = \frac{1/T_s}{2} = \frac{1/900}{2} = 5.56 \cdot 10^{-4} \text{ Hz} \quad (2.13)$$

2.3 Fuzzy Logic

La Lógica Difusa o Fuzzy Logic (FL) nació como una alternativa de presentar información en contraste con la idea clásica de que un elemento “es o no es” o “pertenece o no a un conjunto”. FL

permite manejar incertidumbre, ambigüedad e imprecisión en la información al establecer que un elemento puede pertenecer parcialmente a varios conjuntos al mismo tiempo, estos conjuntos se denominan Conjuntos Difusos (Chen & Pham, 2001; D'Negri & De Vito, 2006; Zadeh, 1965).

Un conjunto difuso es una clase de objetos caracterizados por su pertenencia a un continuo grado de pertenencia; este grado de membresía, además, está caracterizado por una función de pertenencia que asigna a cada elemento del conjunto difuso un valor comprendido entre cero y uno, que representan una menor y mayor pertenencia, respectivamente. (Zadeh, 1965).

En este sentido, la idea principal detrás de FL es su capacidad de describir mediante modelos flexibles (conjuntos difusos y reglas lingüísticas), las leyes que rigen el comportamiento de una persona en cuanto a la toma de decisiones para la solución de problemas en la vida real, donde la información de entrada puede resultar vaga, ambigua, imprecisa o incompleta (D'Negri & De Vito, 2006; Nguyen, Prasad, Walker, & Walker, 2002).

2.3.1 Controlador Fuzzy Logic

El control basado en FL tiene en esencia la misma función que los controladores convencionales; sin embargo, a diferencia de éstos, es capaz de gestionar problemas que involucran sistemas de control complejos, ya sea porque estos sistemas presentan modelos no lineales o simplemente no se puede formular un modelo matemático a partir de este sistema. Para este fin, el control basado en FL emplea heurísticas y modelos matemáticos provistos mediante FL en vez de un modelo definido mediante ecuaciones diferenciales (Chen & Pham, 2001; Nguyen et al., 2002).

La arquitectura de un controlador Fuzzy Logic se muestra en la Figura 7:




Figura 7. Arquitectura de Controlador Fuzzy Logic.

Fuente: (Passino & Yurkovich, 1998).

El Controlador Fuzzy Logic tiene cuatro componentes principales (Passino & Yurkovich, 1998):

- 1) Base de Reglas (Rule-Base): Contiene el conocimiento heurístico del funcionamiento del sistema, en forma de un conjunto de reglas, de la mejor manera de controlar dicho sistema.
- 2) Mecanismo de Inferencia (Inference Mechanism): Evalúa qué reglas de control son relevantes en el instante actual y decide cuál debe ser la entrada a la planta, $u(t)$.
- 3) Interfaz de Fuzzificación (Fuzzification): Realiza la conversión del valor de entrada, $r(t)$ y $y(t)$, de tal manera que puedan ser interpretadas y comparadas con las reglas en la Base de Reglas; es decir, se transforman los valores numéricos a valores lingüísticos.
- 4) Interfaz de Defuzzificación (Defuzzification): Realiza la conversión del valor lingüístico resultante de la conclusión alcanzada por el mecanismo de inferencia, en un valor numérico hacia la salida a la planta.

En resumen, se debe ver al FLC como un sistema autónomo que toma decisiones mediante la emulación de la experiencia humana para controlar un sistema (Nguyen et al., 2002); además, opera en un sistema en lazo cerrado y en tiempo real, para lo cual obtiene información de la salida del sistema a controlar y la compara con la entrada de referencia para determinar cuál debe ser la entrada a la planta que permita cumplir los objetivos de desempeño requeridos por el diseñador (Passino & Yurkovich, 1998).

2.4 Optimización

La optimización es una disciplina fundamental en campos de la ciencia tales como la informática, la inteligencia artificial, investigación operativa, problemas de ingeniería y diseños industriales. Además, el objetivo de la optimización puede ser cualquiera: minimizar el consumo de energía y costos, maximizar las ganancias, mejorar el rendimiento y eficiencia de un sistema, etc. (X.-S. Yang, 2014).

Se puede definir a la optimización como un proceso mediante el cual, previamente definida una función de costo que abarca de manera coherente todos los parámetros del problema, se encuentra la mejor solución posible a dicho problema de optimización y en el menor tiempo posible (Muñoz, 2006; X. Yang & Deb, 2009; X.-S. Yang, 2014; X.-S. Yang & Deb, 2013).

2.4.1 Formulación de un Problema de Optimización

Un problema de optimización puede ser definido de la siguiente manera (R. Timothy Marler & Arora, 2010; R.T. Marler & Arora, 2004; X.-S. Yang, 2014):

$$\text{Minimizar: } F(x) = [F_1(x), F_2(x), \dots, F_k(x)]^T \quad (2.14)$$

$$\text{Sujeto a: } g_j(x) \leq 0; j = 1, 2, \dots, m \quad (2.15)$$

Donde k es el número de funciones objetivo y m es el número de funciones límite del problema. $x \in E^n$ es un vector de variables de diseño, y $F(x) \in E^k$ es un vector de funciones objetivo tal que $F_k(x) : E^n \rightarrow E^k$. El espacio de diseño factible está definido como $X = \{x / g_j(x) \leq 0, j = 1, 2, \dots, m\}$. El espacio de criterios factibles está definido como $Z = \{F(x) / x \in X\}$ (R. Timothy Marler & Arora, 2010; R.T. Marler & Arora, 2004).

De acuerdo con el número de funciones objetivo de un problema de optimización, se lo puede clasificar en optimización único objetivo, ($k = 1$), y multiobjetivo, ($k > 1$); los problemas de optimización multiobjetivo los que más se encuentran en problemas de ciencias e ingeniería (X.-S. Yang, 2014).

Existe una gran variedad de métodos sistemáticos para resolver problemas de optimización multiobjetivo y que modelan las preferencias del diseñador junto con su proceso de toma de decisiones de acuerdo con un orden u importancia relativa de cada objetivo. Además, estos métodos pueden clasificarse de acuerdo a la manera en que el diseñador formula estas preferencias, entre los que se tiene: a priori y previo al proceso de optimización, a posteriori y mediante la selección de una solución de entre un conjunto obtenido, sin requerimientos de preferencias, con formulación progresiva de preferencias en la cual el diseñador continuamente provee información al algoritmo de optimización y mediante algoritmos genéticos globales (R.T. Marler & Arora, 2004).

Para la optimización a realizarse en este trabajo, se empleará el método de la suma ponderada, el cual involucra una definición a priori de las preferencias en cuanto a los objetivos de la

optimización. Previo a la presentación de este método, es necesario definir algunos conceptos importantes en optimización (R.T. Marler & Arora, 2004):

Preferencias. – Una preferencia hace referencia a la opinión del diseñador en cuanto a la solución deseada en el espacio de criterios factibles de tal manera que, una vez realizada la optimización del problema, la solución óptima encontrada refleje dichas preferencias.

Función de Preferencia. – Una función de preferencia es una función abstracta en la mente del diseñador y que incorpora perfectamente cada una de sus preferencias respecto a los objetivos de la optimización.

Función de Costo. – Es una función que expresa la importancia relativa de cada uno de los objetivos y busca modelar matemáticamente las preferencias del diseñador.

2.4.2 Método de la Suma Ponderada

Este método es el más común para la resolución de problemas multiobjetivo y consiste en redefinir una nueva función de costo a minimizar/maximizar; a partir de (2.14), de la siguiente manera:

$$U(x) = \sum_{i=1}^k w_i F_i(x) \quad (2.16)$$

Donde w_i es un coeficiente de peso el cual establecerá la importancia relativa de cada función objetivo, $F_i(x)$. Cabe recalcar que la selección de cada coeficiente w_i tiene un significado conceptual por lo que una selección a priori no es posible en una primera instancia además no siempre existe una única solución que minimice todos los objetivos simultáneamente (R. Timothy Marler & Arora, 2010).

El método de suma ponderada busca aproximar la función de preferencia con alguna representación matemática llamada función de costo. Para entender esto, se puede definir una expresión para los gradientes de la función de preferencia $P[F(x)]$ y de la función de costo, de la siguiente manera (R. Timothy Marler & Arora, 2010):

$$\nabla_x P[F(x)] = \sum_{i=1}^k \frac{\partial P}{\partial F_i} \nabla_x F_i(x) \quad (2.17)$$

$$\nabla_x U = \sum_{i=1}^k w_i \nabla_x F_i(x) \quad (2.18)$$

Donde, de acuerdo con (2.17), se puede decir que cada componente de esta expresión representa la satisfacción del diseñador en el cambio de valor de la función objetivo. Si cada una de las ponderaciones, w_i , son seleccionadas apropiadamente, el gradiente de la función de costo es paralelo al gradiente de la función de preferencia; es decir, w_i representaría $\partial P/\partial F_i$. En otras palabras, $\partial P/\partial F_i$ es el cambio aproximado en el valor de la función de preferencia (cambio en la satisfacción del diseñador) que resulta en un cambio en el valor de las funciones objetivo F_i , lo cual resulta en una definición matemática de la importancia de cada uno de los objetivos del problema de optimización (R. Timothy Marler & Arora, 2010).

2.4.3 Algoritmos Heurísticos y Metaheurísticos

La mayoría de los algoritmos clásicos o convencionales son de naturaleza determinística, con la obtención de muy buenos resultados en la optimización de problemas que involucran funciones unimodales, continuas y de pequeña dimensión. Sin embargo, con el surgimiento de problemas más complejos y de mayores dimensiones en los cuales las funciones a optimizar pueden resultar discontinuas y/o multimodales, ha surgido también la necesidad de contar con algoritmos de

optimización que puedan dar solución a estos problemas, como son los algoritmos no determinísticos u estocásticos (X.-S. Yang, 2014).

Dentro de los algoritmos no determinísticos se encuentran los denominados algoritmos aproximados o heurísticos, los cuales se basan principalmente en procedimientos de prueba y error y permiten obtener una solución buena en un tiempo razonable (Muñoz, 2006). Sin embargo, debido a que dichos procedimientos empleados en la búsqueda de la solución no permiten una exploración eficiente del espacio de diseño factible, la “mejor solución” obtenida puede resultar ser un óptimo local mas no un óptimo global (Muñoz, 2006; X.-S. Yang, 2014); además, el conocimiento que el diseñador pueda tener sobre el problema puede resultar crucial para encontrar una buena solución en este tipo de algoritmos ya que una búsqueda “ciega” puede conducir a un proceso infinito sin resultados (X.-S. Yang, 2014).

Por otro lado, como parte de los algoritmos no determinísticos y con el fin de solventar las limitaciones que presentan los algoritmos heurísticos, se desarrollaron los algoritmos metaheurísticos inspirados en la naturaleza. Durante los últimos estos algoritmos años han sido objeto de estudio y aplicación en una gran variedad de campos en las ciencias e ingeniería debido a su eficiencia en la solución de una gran variedad problemas de optimización (Civicioglu & Besdok, 2013; Mohamed & Mohammed, 2013; Rani et al., 2012; X. Yang & Deb, 2009; X.-S. Yang, 2013, 2014; X.-S. Yang & Deb, 2013); en este sentido, su característica principal y que permite su potencialidad es su capacidad de imitar comportamientos y características de sistemas biológicos que han evolucionado a partir de la selección natural a lo largo de millones de años. Algunos ejemplos de estos algoritmos son: Optimización por Enjambre de Partículas (PSO),

Algoritmos Genéticos (GA), Evolución Diferencial (DA), Búsqueda de Cuckoo (CS), entre otros (X.-S. Yang, 2014).

En términos matemáticos, las características de sistemas biológicos de los algoritmos inspirados en la naturaleza pueden resumirse en dos que intensificación y la diversificación. La diversificación hace referencia a la generación de soluciones aleatorias de tal manera que se explore la totalidad del espacio de diseño factible con mayor eficacia en búsqueda de la solución óptima, mientras que la intensificación hace referencia al proceso de búsqueda local en aquellos puntos del espacio de diseño factible en los cuales se tiene información sobre la posible existencia de un óptimo global (Muñoz, 2006; X. Yang & Deb, 2009; X.-S. Yang, 2014; X.-S. Yang & Deb, 2013).

2.5 Algoritmo de Búsqueda de Cuckoo

El algoritmo de búsqueda de Cuckoo (CS) es uno de los algoritmos metaheurísticos inspirados en la naturaleza más reciente en ser desarrollado y está basado en el comportamiento de parasitismo de puesta que presentan ciertas especies de aves cuckoo, dicho comportamiento consiste en la puesta de sus huevos en nidos de otras aves para que sean criados por estas; además, una de las características principales de este algoritmo y que permiten su gran potencialidad en la solución de problemas complejos de optimización, es el uso de Vuelos de Lévy como método de generación de nuevas soluciones (X. Yang & Deb, 2009, ©2009 IEEE; X.-S. Yang, 2014ⁱ).

2.5.1 Vuelos de Lévy

Los Vuelos de Lévy son procesos estocásticos que modelan las características que presentan algunas especies de aves y mamíferos en la búsqueda de alimento dentro de un hábitat natural desconocido (Miramontes, 2014; X. Yang & Deb, 2009; X.-S. Yang, 2014).

En términos matemáticos, los Vuelos de Lévy son un “Recorrido Aleatorio” en los cuales la longitud de desplazamiento se extrae de una distribución de probabilidad (PDF) estable de Lévy, $L(s, \beta)$, donde para valores grandes de s , dicha PDF decae de acuerdo a la siguiente expresión en ley de potencia con la característica de presentar varianzas y medias infinitas (Alexei V. Chechkin, Metzler, Klafter, & Gonchar, 2008; Gutowski, 2001; Levy, 1939; Mantegna, 1994; X. Yang & Deb, 2009; X.-S. Yang, 2014):

$$L(s) \propto |s|^{-1-\beta}, 0 < \beta \leq 2 \quad (2.19)$$

Adicionalmente, la densidad de probabilidad de una distribución estable simétrica de Lévy está dada mediante la siguiente expresión (Mantegna, 1994):

$$L(s, \beta) = \frac{1}{\pi} \int_0^{\infty} e^{-q|s|} \cos(s) dq, 0 < \beta \leq 2 \quad (2.20)$$

Donde β es el coeficiente de la distribución. Cabe recalcar que la expresión (2.20) solo tiene solución para los casos particulares $\beta = 1$ (distribución de Cauchy), $\beta = 2$ (distribución gaussiana), $\beta = 2/3$ y $\beta = 1/2$ (Mantegna, 1994; X.-S. Yang, 2014). Por lo que para los casos en los cuales no se tiene una solución analítica, se emplea el algoritmo para simulación de procesos estables de Lévy, desarrollado por Mantegna en 1994 (Mantegna, 1994) y que se expondrá en la implementación del algoritmo de búsqueda de Cuckoo.

Para determinar el coeficiente, β , más adecuado a utilizarse para la aplicación de vuelos de Lévy en el algoritmo de búsqueda de Cuckoo, se pueden graficar los desplazamientos generados para diferentes coeficientes de la distribución, β , tal como se muestra en la Figura 16.

En este sentido, es conveniente que las nuevas soluciones aleatorias generadas mediante Vuelos de Lévy sean cercanas a las soluciones actuales con ocasionales saltos grandes en búsqueda de soluciones alejadas; con esto se mejora la eficacia de la búsqueda local o intensificación y la búsqueda global o diversificación, ésta última en menor medida. Por este motivo, un coeficiente de distribución de Lévy entre $\beta = 1.3$ y $\beta = 1.7$ es más que suficiente de acuerdo con lo mostrado en la Figura 8. En el presente trabajo y de acuerdo a la literatura (X. Yang & Deb, 2009; X.-S. Yang, 2014), se emplea un valor de $\beta = 1.5$.




Figura 8. Tamaños de desplazamiento para diferentes índices de distribución de Lévy, β .

Fuente: (Aleksei V. Chechkin, Gonchar, Klafter, & Metzler, 2006; Mantegna, 1994).

2.5.2 Algoritmo de Búsqueda de Cuckoo con Vuelos de Lévy

El algoritmo de búsqueda de Cuckoo se basa en tres principios (X. Yang & Deb, 2009, ©2009 IEEE; X.-S. Yang, 2014ⁱ):

- Cada cuckoo pone un huevo (nueva solución de dimensión d) a la vez y lo deja en un nido (solución actual) elegido al azar.
- Los mejores nidos (mejores soluciones) con los mejores huevos (mejor fitness/calidad) pasarán a las siguientes generaciones.
- El número de nidos disponibles (soluciones actuales disponibles) es fijo, y el huevo depositado por un cuckoo (nueva solución) tiene una probabilidad de ser descubierto, $p_a \in [0.1]$. En este caso, el ave dueña del nido puede deshacerse del huevo o simplemente abandonar el nido para crear uno completamente nuevo (crear nuevas y completamente diferentes soluciones). Esta característica potencia la capacidad de diversificación que algoritmo en cuanto a la generación de nuevas y muy diferentes soluciones, con el fin de evitar mínimos locales.

De manera general, el algoritmo de búsqueda de Cuckoo consta de los pasos descritos en el siguiente pseudocódigo:

Seudocódigo Cuckoo Search con Vuelos de Lévy

```

1:  Inicio
2:  Función objetivo  $f(x)$ ,  $x=(x_1, \dots, x_d)^T$ 
3:  Generar población inicial de  $n$  nidos  $x_i$  ( $i=1, 2, \dots, n$ )
4:  While ( $t < \text{MáximaGeneración}$ ) o (Criterio de finalizar)
5:    Obtener nuevo cuckoo mediante vuelo de lévy
6:    Evaluar su calidad / fitness  $F_i$ 
7:    Elegir nuevo nido entre  $n$  (ejemplo  $j$ ) aleatoriamente
8:    Si ( $F_i > F_j$ ) /* '>' Se utiliza para maximizar, '<' para minimizar */
9:      Reemplazar  $j$  por la nueva solución
10: Fin
11:   Una fracción  $p_a$  de los peores nidos son abandonados
12:   Y nuevos nidos son construidos
13:   Mantener mejores soluciones
14:   Ordenar las soluciones y encontrar la mejor
15: Fin mientras
16: Fin

```

Figura 9. Seudocódigo del algoritmo de búsqueda de Cuckoo.

Fuente: (Vilches, 2015).

CAPÍTULO III

ESTRATEGIA DE GESTIÓN ENERGÉTICA

3.1 Estrategia de Gestión Energética Basada en Control Fuzzy Logic

La estrategia de gestión energética y el EMS a optimizar en el presente trabajo hacen referencia a trabajos realizados anteriormente (Diego Arcos-Aviles, Guinjoan, et al., 2018; Diego Arcos-Aviles et al., 2019). El principal objetivo de estos trabajos ha consistido en minimizar las fluctuaciones perfil del potencia que la microrred intercambia con la red eléctrica; ya que con la ayuda de la energía almacenada por el BEES se logra cubrir parte de la energía requerida por el EWH y mantener la temperatura del agua en el tanque en un rango de temperaturas máxima y mínima $45^{\circ}C$ y $65^{\circ}C$, respectivamente (Diego Arcos-Aviles, Guinjoan, et al., 2018). Para la descripción de la EMS, se define en primer lugar la expresión de la potencia intercambiada entre la MG y la red eléctrica, de la siguiente manera:

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

Donde: $P_{CTR}^*(n)$ es el perfil de potencia medio de la MG, $P_{SOC}(n)$ es una componente que busca mantener el valor central de SOC de la batería cercano al 75% de su capacidad nominal, y $P_{FLC}(n)$ mejora el perfil de potencia de acuerdo a la capacidad de la batería y el error de predicción de la MG (Diego Arcos-Aviles, Guinjoan, et al., 2018).




Figura 10. Diagrama de bloques Fuzzy EMS-FC.

Fuente: (Diego Arcos-Aviles, Guinjoan, et al., 2018) ©2018 IEEE.

El diagrama de bloques de la estrategia Fuzzy EMS-FC se presenta en la Figura 10 y consta de los siguientes bloques, descritos de acuerdo con (Diego Arcos-Aviles, Guinjoan, et al., 2018; Diego Arcos-Aviles et al., 2019) ©2018 IEEE.

3.1.1 Bloque 1 – EWH Control

Este bloque es empleado para calcular la cantidad de energía que contribuye la batería para el consumo del EWH, $P_{WH}^B(n)$. Por lo tanto, se redefine la potencia neta de la microrred, $P_{LG}(n)$, definida en (2.2), de la siguiente manera:

$$P_{LG}^*(n) = P_{LG}(n) - P_{WH}^B(n) \quad (3.2)$$

3.1.2 Bloque 2 – Filtro CMA

Este bloque calcula la componente $P_{CTR}^*(n)$ de (3.1), que es la potencia media de la MG, mediante un filtro de Media Móvil Central (CMA) de 24 horas; para tal fin se considera la potencia neta de la MG, $P_{LG}^*(n)$ de las 12 horas anteriores, $P_{LG}^{12H^*}(n)$, y la predicción de la potencia neta de la MG, $P_{LG,FC}^*(n)$ de las 12 horas posteriores, $P_{LG,FC}^{12H^*}(n)$, de acuerdo con la siguiente expresión:

$$P_{CTR}^*(n) = \frac{P_{LG}^{12H^*}(n) + P_{LG,FC}^{12H^*}(n)}{2} \quad (3.3)$$

De manera similar a lo realizado para $P_{LG}(n)$ en (3.2), la energía de la batería se emplea para suplir parte de la energía requerida por el EWH, por lo que se reduce la demanda de carga de la MG. Así, se redefinen las expresiones de la demanda de carga, $P_{LOAD}^*(n)$, y de la predicción de potencia neta de la MG, $P_{LG,FC}^*(n)$, de la siguiente manera:

$$P_{LOAD}^*(n) = P_{LOAD}(n) - P_{WH}^B(n) \quad (3.4)$$

$$P_{LG,FC}^*(n) = P_{LOAD,FC}^*(n) - P_{GEN,FC}(n) \quad (3.5)$$

Además, para el cálculo de la predicción de potencia neta de la MG, $P_{LG,FC}^*(n)$, se emplea el diagrama de bloques mostrado en la Figura 11.

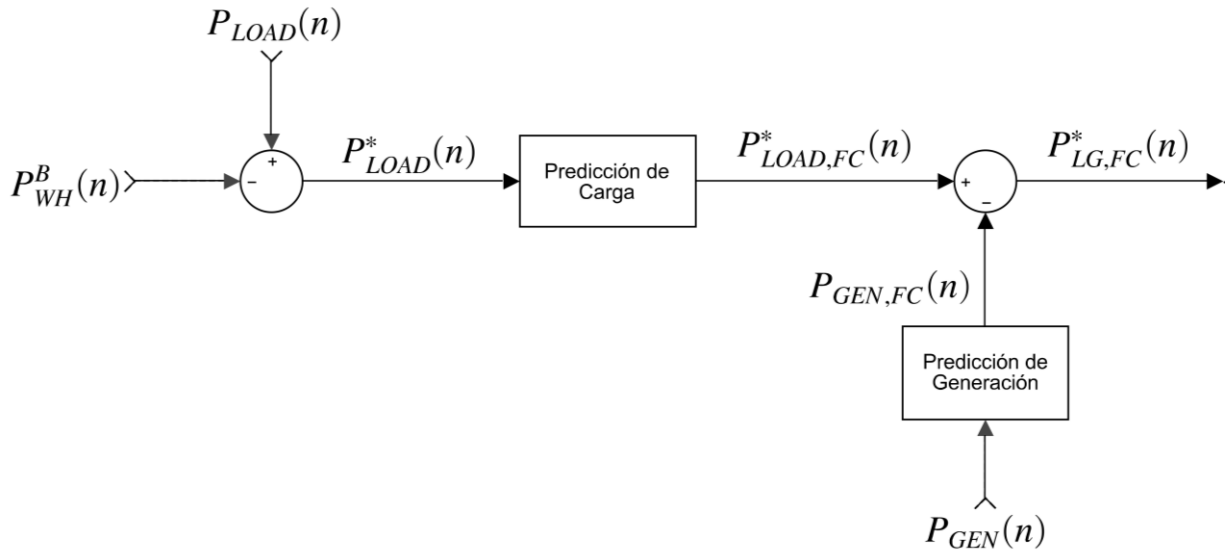


Figura 11. Diagrama de bloques de la predicción de potencia neta de la MG.

Fuente: (Diego Arcos-Aviles, Guinjoan, et al., 2018). ©2018 IEEE.

3.1.3 Bloque 3 – Filtro de 3H

Este bloque calcula el error de predicción de la potencia de la MG de las últimas 3 horas, se considera la potencia neta de la MG (3.2) y su valor de predicción (3.5), de la siguiente manera:

$$P_E^{3H^*}(n) = \frac{1}{M_3} \sum_{k=1}^{M_3} P_E^*(n-k) \quad (3.6)$$

$$P_E^*(n) = P_{LG}^*(n) - P_{LG,FC}^*(n) \quad (3.7)$$

Donde M_3 es el número total de muestras en 3 horas.

3.1.4 Bloque 4 – Filtro Pasa Bajos

Este bloque calcula la componente $P_{soc}(n)$ de (3.1), empleada para mantener el SOC de la batería en un valor cercano al 75% de su capacidad nominal. Además, de acuerdo con la Figura 10,

su valor es proporcional al error calculado entre un valor de SOC de referencia, $SOC_{REF} = 75\%$, y el promedio de SOC de las últimas 24 horas, SOC_{AVG} , de acuerdo con la siguiente expresión:

$$P_{SOC}(n) = k_e [SOC_{REF}(n) - SOC_{AVG}(n)] \quad (3.8)$$

$$SOC_{AVG}(n) = \frac{1}{M_{24}} \sum_{k=1}^{M_{24}} SOC(n-k) \quad (3.9)$$

Donde M_{24} es el número total de muestras en 24 horas y k_e es una constante de proporcionalidad.

3.1.5 Bloque 5 – Estimador SOC

Este bloque es usado para estimar el SOC del ESS, mediante las siguientes expresiones:

$$SOC(n) = SOC(n-1) - \Delta SOC(n) \quad (3.10)$$

$$\Delta SOC = (100 / C_{BAT}) \cdot \eta \cdot P_{BAT}(n-1) \cdot T_s \quad (3.11)$$

Además, de acuerdo con el diagrama de bloques de la Figura 10, se tiene:

$$P_{BAT}(n) = P_{BAT}^{MG}(n) + P_{WH}^B(n) \quad (3.12)$$

$$P_{BAT}^{MG}(n) = P_{LG}(n) - P_{GRID}(n) \quad (3.13)$$

Cabe recalcar que el SOC de la batería debe satisfacer las limitaciones: $SOC_{MIN} \leq SOC(n) \leq SOC_{MAX}$, $SOC_{MIN} = (1-DOD)SOC_{MAX}$, además se considera una profundidad máxima de descarga (DOD) del 50%.

3.1.6 Bloque 6 – Controlador Fuzzy Logic

Este bloque calcula la componente $P_{FLC}(n)$ en (3.1) la cual es usada para mejorar el perfil de potencia intercambiada con la red eléctrica de acuerdo con el SOC de la batería y al error de predicción de la potencia de la MG en las últimas 3 horas.

El controlador Fuzzy Logic asume un sistema de inferencia basado en Mamdani y método de defuzzificación de centroide (Passino & Yurkovich, 1998) con dos entradas, una salida y 25 reglas de acuerdo a lo definido en trabajos anteriores (Diego Arcos-Aviles, Guinjoan, et al., 2018; Diego Arcos-Aviles et al., 2019).

3.2 Valores de Referencia para Propósitos de Comparación.

El proceso optimización del controlador en trabajos realizados anteriormente (Diego Arcos-Aviles, Guinjoan, et al., 2018; Diego Arcos-Aviles et al., 2019), ha consistido en un ajuste fuera de línea y mediante métodos heurísticos, obteniéndose buenos resultados; a partir de estos, se comprobará la mejora en la gestión energética mediante el ajuste de parámetros del FLC a realizarse en el presente trabajo.

Los parámetros del controlador Fuzzy Logic actuales: posiciones de funciones de pertenencia para las variables de entrada y salida, rango de la variable de salida y base de reglas, se presentan a continuación, así como los parámetros de calidad de la gestión energética resultantes.




Figura 12. Funciones de pertenencia para la entrada P_E , estrategia EMS-FC.

Fuente: (D. Arcos-Aviles et al., 2016). ©2016 IEEE.

Donde $P_{E,MAX} = 6\text{kW}$ y $P_{E,MIN} = -6\text{kW}$.




Figura 13. Funciones de pertenencia para la entrada SOC , estrategia EMS-FC

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

Donde $SOC_{MIN} = 50\%$ y $SOC_{MAX} = 100\%$.




Figura 14. Funciones de pertenencia para la salida P_{FLC} , estrategia EMS-FC

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

Donde $P_N = -0.8\text{kW}$ y $P_P = 1.35\text{kW}$.

Como se mencionó anteriormente, el ajuste de los parámetros de las funciones de pertenencia se realizó mediante procedimientos heurísticos de prueba y error mientras la base de reglas fue modificada de acuerdo con el conocimiento heurístico de la MG y sus requerimientos específicos de funcionamiento, a modo de ejemplo: si el error de predicción en la MG tiene un valor negativo grande ($P_E^{3H}(n) \ll 0$, la predicción de la potencia neta de la MG resulta mucho más grande que la medida), y la energía almacenada en el ESS se encuentra en un nivel muy bajo ($SOC(n) \ll SOC_{REF}$, lo cual significa que la batería está muy descargada), entonces la estrategia incrementa considerablemente la potencia de red para cargar el ESS ($P_{FLC} \gg 0$). Además, las reglas por sobre la diagonal implican que la potencia entregada por la red de distribución incrementa de acuerdo con el incremento al error de predicción; por otro lado, por debajo de la diagonal las reglas implican

que la inyección de potencia por parte de la red decrece conforme la energía almacenada en el ESS aumenta (D. Arcos-Aviles, Pascual, et al., 2017).

Tabla 1
Base de Reglas del Controlador Estrategia EMS-FC.

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

Fuente: (Diego Arcos-Aviles, Guinjoan, et al., 2018). ©2018 IEEE.

Las gráficas resultantes de la estrategia de gestión energética se muestran a continuación y servirán para una futura comparación:




Figura 15. SOC de la batería y rangos. Estrategia EMS-FC

Fuente: (Diego Arcos-Aviles, Guinjoan, et al., 2018). ©2018 IEEE.

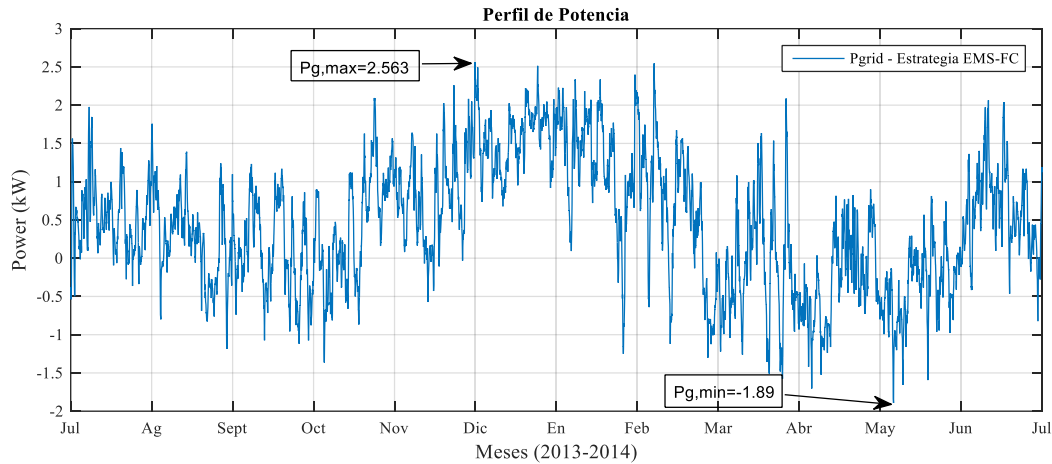


Figura 16. Perfil de potencia intercambiado con la red eléctrica. Estrategia EMS-FC.

Fuente: (Diego Arcos-Aviles, Guinjoan, et al., 2018). ©2018 IEEE.




Figura 17. Rampas del perfil de potencia intercambiado. Estrategia EMS-FC.

Fuente: (Diego Arcos-Aviles, Guinjoan, et al., 2018). ©2018 IEEE.

Tabla 2

Criterios de calidad de la gestión energética Estrategia EMS-FC.

EMS Estrategia	$P_{G,MAX}$ (kW)	$P_{G,MIN}$ (kW)	MPD(W / h)	PVR	APD(W / h)	PPV
Fuzzy EMS-FC (Diego Arcos-Aviles, Guinjoan, et al., 2018)	2.56	-1.89	846	0.34	75	1.26

Fuente: (Diego Arcos-Aviles, Guinjoan, et al., 2018). ©2018 IEEE.

CAPÍTULO IV

AJUSTE DE PARÁMETROS DEL CONTROLADOR FUZZY LOGIC

4.1 Definición de Parámetros Para Optimizar

Los parámetros del FLC a optimizar involucran las MF de las variables de entrada, MF de la variable de salida, rango de la variable de salida del controlador y la base de reglas. Para la definición de cada uno de dichos parámetros y su optimización, se empleará su configuración inicial, de la siguiente manera:

La primera variable de entrada es el error de predicción, P_E , y consta de 5 MF distribuidas inicialmente de la siguiente manera:




Figura 18. Definición inicial de funciones de pertenencia para la entrada P_E .

Fuente: (D. Arcos-Aviles et al., 2016). ©2016 IEEE.

Donde cada MF está definida por tres parámetros correspondientes a sus posiciones a excepción de aquellas en los extremos que se encuentran definidas por dos parámetros cada una; además, en

las figuras cada cuadrado equivale a un parámetro mientras cada círculo hace referencia a dos parámetros en MF adyacentes. El número de parámetros a optimizar para a variable de entrada, P_E , se calcula:

$$\# \text{ parámetros}_{P_E} = 3 \cdot 3 + 2 \cdot 2 = 13 \quad (4.1)$$

La segunda variable de entrada es el estado de carga de la batería, SOC , y consta de 5 MF distribuidas inicialmente de la siguiente manera:




Figura 19. Definición inicial de funciones de pertenencia para la entrada SOC .

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

Se calcula el número de parámetros:

$$\# \text{ parámetros}_{SOC} = 3 \cdot 3 + 2 \cdot 2 = 13 \quad (4.2)$$

La salida del controlador, P_{FLC} , consta de 9 MF distribuidas inicialmente de la siguiente manera:

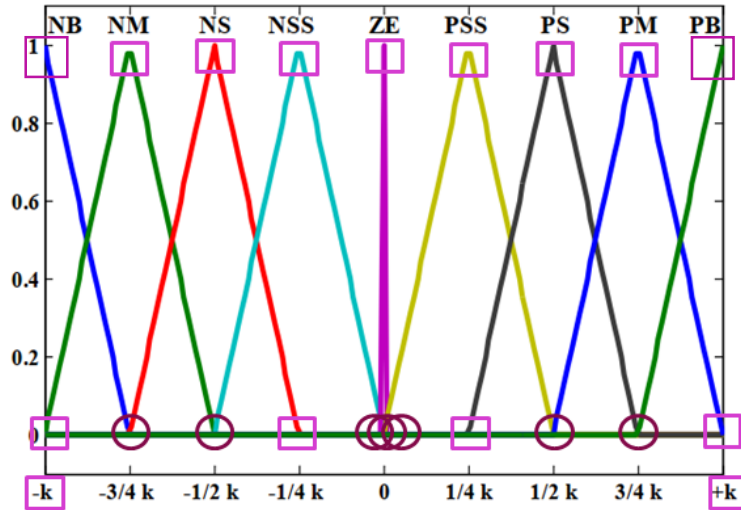


Figura 20. Definición inicial de funciones de pertenencia para la salida P_{FLC} .

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

De la misma manera que en caso anterior y con la inclusión de los parámetros de salida máxima, $+k$, y mínima $-k$, se calcula el número de parámetros:

$$\# \text{ parámetros}_{P_{FLC}} = 3 \cdot 7 + 2 \cdot 2 + 2 = 27 \quad (4.3)$$

La base de reglas inicial es presentada en la Tabla 3 y fue definida mediante el conocimiento heurístico del funcionamiento de la microrred de acuerdo a la potencia entregada/absorbida hacia/desde la microrred (Diego Arcos-Aviles et al., 2019).

Tabla 3
Base de Reglas Inicial del Controlador.

P_{FLC}		$P_E(n)$				
		NB	NS	ZE	PS	PB
$SOC(n)$	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, Guinjoan, et al., 2018). ©2018 IEEE.

El número de parámetros a optimizar equivale a cada una de las reglas descritas en la Tabla 3.

$$\# \text{ parámetros}_{RL} = 25 \quad (4.4)$$

Por lo tanto, el número total de parámetros a optimizar resulta de la suma de (4.1) - (4.4).

$$d = 13 + 13 + 27 + 25 = 78 \quad (4.5)$$

Cabe recalcar que el valor de d corresponde al número de variables de diseño y para el algoritmo de búsqueda de Cuckoo hace referencia a la dimensión de la solución (cuckoo) de acuerdo con lo mencionado en la Sección 2.6.2.

4.2 Definición de Función de Costo

Para poder resolver de buena manera el problema de optimización, se debe diseñar una función de costo que abarque de manera coherente todos los objetivos que evalúan la optimización; para el caso del problema propuesto, estos objetivos son los descritos en la Sección 2.3 y miden la calidad de la gestión energética del EMS.

Debido a que el número de objetivos es mayor a 1, se trabaja con un problema de optimización multiobjetivo. En este sentido, se empleará el método de la suma ponderada, ya expuesto anteriormente de manera general en la Sección 2.5.2, para formular la función de costo.

En primer lugar, se formula el problema de optimización:

$$\text{Minimizar: } F(X) = [P_{G,MAX}, P_{G,MIN}, PVR, MPD, APD, PPV]^T \quad (4.6)$$

$$\text{Sujeto a: } g(X) = \begin{cases} -6 \leq P_E \leq 6 \\ 50 \leq SOC \leq 100 \\ k_{(-)} \leq P_{FLC} \leq k_{(+)} \\ 0 \leq |k_{(-),(+)}| \leq 10 \\ 1 \leq RL \leq 9 \end{cases} \quad (4.7)$$

Previo a la formulación de la función de costo, es necesario normalizar los valores de cada una de las funciones objetivo, para lo cual se divide cada una para los siguientes valores que representan los últimos parámetros de calidad obtenidos en (Diego Arcos-Aviles, Guinjoan, et al., 2018):

Tabla 4

Valores para normalización de funciones objetivo.

EMS Estrategia	$P_{G,MAX}$ (kW)	$P_{G,MIN}$ (kW)	MPD(W / h)	PVR	APD(W / h)	PPV
Fuzzy EMS-FC (Diego Arcos-Aviles, Guinjoan, et al., 2018)	2.56	-1.89	846	0.34	75	1.26

Fuente: (Diego Arcos-Aviles, Guinjoan, et al., 2018). ©2018 IEEE.

La función de costo queda definida de la forma:

$$U = w_1 \cdot \frac{P_{G,MAX}}{2.56} + w_2 \cdot \frac{P_{G,MIN}}{-1.89} + w_3 \cdot \frac{MPD}{846} + w_4 \cdot \frac{APD}{75} + w_5 \cdot \frac{PVR}{0.34} + w_6 \cdot \frac{PPV}{1.26} \quad (4.8)$$

Donde cada una de las ponderaciones se determinan de acuerdo con las preferencias específicas que se tengan para cada objetivo de acuerdo con el problema en cuestión.

En este sentido, para la determinación de las ponderaciones ha establecido un orden de preferencia en base a las preferencias del diseñador de la EMS, del siguiente modo:

Tabla 5

Preferencias de las funciones objetivo de optimización.

Mayor Preferencia	$P_{G,MAX}(kW), P_{G,MIN}(kW), MPD(W/h)$
	$APD(W/h), PPV$
Menor Preferencia	PVR

En base a lo descrito en la Tabla 5, se deciden valores para cada una de las ponderaciones de la función de costo basadas en las preferencias descritas. Con el fin de priorizar la minimización de $P_{G,MAX}, P_{G,MIN}, MPD$ por sobre APD, PPV y estos por sobre PVR , se define la siguiente igualdad:

$$w_1 | w_2 | w_3 = 2 \cdot w_4 | w_5 = 2 \cdot w_6 \quad (4.9)$$

De este modo, para un valor arbitrario, $w_6 = 1$, se define la siguiente función de costo a optimizar:

$$U = 4 \cdot \frac{P_{G,MAX}}{2.56} + 4 \cdot \frac{P_{G,MIN}}{-1.89} + 4 \cdot \frac{MPD}{846} + 2 \cdot \frac{APD}{75} + 2 \cdot \frac{PVR}{0.34} + 1 \cdot \frac{PPV}{1.26} \quad (4.10)$$

4.3 Implementación del Algoritmo de Búsqueda de Cuckoo

4.3.1 Definición de Parámetros Iniciales del Algoritmo

En primer lugar, se define el tamaño de la población de nidos disponibles el cual de acuerdo a la literatura (X.-S. Yang, 2014), con un valor de $n = 25$ será más que suficiente.

El segundo parámetro del algoritmo, el cual es el encargado de controlar la cantidad de nuevas y diferentes soluciones que serán creadas en cada iteración de acuerdo con la idea de que el huevo de cuckoo tiene una probabilidad de ser descubierto o no, es la probabilidad $p_a \in [0,1]$. De acuerdo con la literatura (X.-S. Yang, 2014), un valor de $p_a = 0.25$ es más que suficiente.

El tercer parámetro hace referencia a la dimensión de la solución a encontrar (huevo de cuckoo), el cual ya se definió anteriormente como $d = 78$.

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:

$$x_{P_E} = \{x_{P_E} \in X \mid -6 \leq x_{P_E} \leq 6\} \quad (4.11)$$

$$x_{SOC} = \{x_{SOC} \in X \mid 50 \leq x_{SOC} \leq 100\} \quad (4.12)$$

$$x_{P_G} = \{x_{P_G} \in X \mid k_{(-)} \leq x_{P_G} \leq k_{(+)}\} \quad (4.13)$$

$$x_{k_{(-),(+)}} = \{x_{k_{(-),(+)}} \in X \mid 0 \leq x_{k_{(-),(+)}} \leq 10\} \quad (4.14)$$

$$x_{RL} = \{x_{RL} \in X \mid 1 \leq x_{RL} \leq 9\} \quad (4.15)$$

En la siguiente tabla se resumen cada uno de los parámetros iniciales del algoritmo:

Tabla 6

Parámetros iniciales del algoritmo de búsqueda de Cuckoo.

n	Población de cuckoos/nidos
P_a	Probabilidad de descubrimiento
d	Dimensión de un cuckoo/nido
$x_{P_{E_{MIN}}}, P_{E_{MAX}}$	Límites inferior y superior de P_E
$x_{SOC_{MIN}}, SOC_{MAX}$	Límites inferior y superior de SOC
$x_{P_{G_{MIN}}}, P_{G_{MAX}}$	Límites inferior y superior de P_G
$x_{k_{(-)}}, x_{k_{(+)}}$	Límites inferior y superior de $k_{(-)}$ y $k_{(+)}$
$x_{RL_{MIN}}, x_{RL_{MAX}}$	Límites inferior y superior de las reglas RL

4.3.2 Generación de Población Inicial

En esta fase, se genera el conjunto de nidos/soluciones iniciales representas por una matriz $n \times d$ de acuerdo con los parámetros: tamaño de población de cuckoos/nidos, n , y dimensión de cuckoo, d , definidos anteriormente; además, se genera un arreglo de Fitness o calidad el cual almacena el

valor de la función de costo para cada solución generada y con esta información determinar cuál solución es la mejor en cada proceso iterativo. Tal como se ilustra a continuación:




Figura 21. Generación de población inicial de nidos.

Con el principal objetivo de que las soluciones aleatorias generadas (población inicial) conserven cierta lógica dentro de la teoría de control Fuzzy Logic, su generación se la realizará al agregar valores aleatorios a los parámetros iniciales descritos en la Sección 4.1 de acuerdo con el procedimiento descrito a continuación:

En primer lugar, a cada una de posiciones las MF de las variables de entrada y salida descritas en la Sección 4.1, se le suma un valor de desplazamiento aleatorio, δ ; esto permite obtener un conjunto de soluciones aleatorias muestreadas del espacio de búsqueda pero que resultan similares en simetría y distribución en comparación a las distribuciones iniciales ilustradas en las Figuras 18,19 y 20. El valor de δ se obtiene de una distribución uniforme definida de la siguiente manera:

$$\delta \square U(-5\% \cdot R, 5\% \cdot R); R = R_{MAX} - R_{MIN} \quad (4.16)$$

Donde R_{MIN} y R_{MAX} hacen referencia al valor mínimo y máximo, respectivamente, del rango de cada variable de entrada o salida según corresponda y un valor de 5% del rango se ha definido

como criterio de diseño para que las soluciones aleatorias generadas sean cercanas a la distribución inicial uniforme de MF.

De acuerdo con lo dicho descrito anteriormente, se definen los parámetros δ_{PE} , δ_{SOC} y δ_{PG} que se emplearán para la generación de la población aleatoria inicial para las variables P_E , SOC y, P_G respectivamente.

➤ Variable de entrada al FLC: Error de Predicción, P_E .

$$x_{P_E,MAX} = 6kW; x_{P_E,MIN} = -6kW \quad (4.17)$$

$$R_E = x_{P_E,MAX} - x_{P_E,MIN} = 12 \quad (4.18)$$

$$\delta_{P_E} \square U(-5\% \cdot 12, 5\% \cdot 12) \quad (4.19)$$

$$\delta_{P_E} \square U(-0.6, 0.6) \quad (4.20)$$

➤ Variable de entrada al FLC: Estado de Carga, SOC .

$$x_{SOC,MAX} = 100\%; x_{SOC,MIN} = 50\% \quad (4.21)$$

$$R_{SOC} = x_{SOC,MAX} - x_{SOC,MIN} = 50 \quad (4.22)$$

$$\delta_{SOC} \square U(-5\% \cdot 50, 5\% \cdot 50) \quad (4.23)$$

$$\delta_{SOC} \square U(-2.5, 2.5) \quad (4.24)$$

➤ Variable de salida del FLC: Potencia del Controlador, P_{FLC} .

Debido a que el valor máximo y mínimo de la variable de salida también son parámetros para optimizar; de acuerdo con la definición del problema, sus valores iniciales pueden generarse mediante una distribución uniforme de la siguiente manera:

$$|k_{(-),(+)}| \square U(0,10) \quad (4.25)$$

Se continua con el cálculo:

$$x_{P_G,MAX} = k_{(+)}; x_{P_G,MIN} = k_{(-)} \quad (4.26)$$

$$R_{P_G} = x_{P_G,MAX} - x_{P_G,MIN} \quad (4.27)$$

$$\delta_{P_G} \square U(-5\% \cdot R_{P_G}, 5\% \cdot R_{P_G}) \quad (4.28)$$

En segundo lugar, con la base de reglas del controlador y de la misma manera que para las MF, se parte de la distribución inicial descrita en la Sección 4.1. Para generar la población inicial, a cada regla se le agrega un desplazamiento que es un número entero obtenido de una distribución uniforme de números enteros, de la siguiente manera:

$$RL_{1,25} = RL_{1,25} + \delta_{RL_{1,25}} \quad (4.29)$$

$$\delta_{RL_{1,25}} \square U(-1,1) \quad (4.30)$$

Cabe recalcar que, aunque idealmente los resultados finales del algoritmo deberían ser independientes del procedimiento de inicialización, en la realidad los resultados dependen considerablemente de las soluciones iniciales generadas debido a que al tratarse de un problema complejo y al no conocer la naturaleza del espacio de búsqueda, soluciones iniciales encontradas cercanas a posibles óptimos globales pueden incrementar la probabilidad de que el óptimo global

sea encontrado (X.-S. Yang, 2014). Por esta razón, se empleó como procedimiento de inicialización el descrito.

En la Figura 22, se ilustra el proceso para generar una nueva MF aleatoria a partir de una MF inicial de acuerdo con lo descrito anteriormente, donde X, Y, Z representan los parámetros de la MF.




Figura 22. Generación de nuevas MF para población inicial.

De la misma manera, en la Tabla 7 se presenta un ejemplo de una solución inicial aleatoria generada para la base de reglas, de acuerdo con lo expuesto anteriormente.

Tabla 7

Solución aleatoria a partir de una base de reglas inicial (Tabla 3).

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

4.3.3 Intensificación o Explotación

Esta fase consiste en la generación de nuevas soluciones aleatorias cercanas a las soluciones creadas en la población inicial con el fin de mejorar dichas soluciones; las nuevas soluciones son aceptadas de acuerdo con los siguientes criterios:

- Un cuckoo pone un huevo en un nido (se crea una nueva solución) que es muy parecido al huevo ya existente en un nido de la población inicial.
- Si el huevo de cuckoo tiene un buen ajuste respecto al huevo del nido, el huevo de cuckoo reemplaza al ya existente, caso contrario, el huevo de cuckoo es destruido por el ave dueña del nido; en otras palabras, solo si las nuevas soluciones creadas (cuckoos) son mejores pasarán a las siguientes generaciones.

Para una generación $G(G > 0)$, una nueva solución es generada de acuerdo con la siguiente expresión:

$$x_{MF,G+1} = x_{MF,G} + \alpha \cdot Lévy(\beta) \quad (4.31)$$

$$\alpha = \alpha_0 \cdot (x_{MF,G} - x_{MF,best}) \quad (4.32)$$

Donde $\alpha_0 > 0$ es un factor de escalamiento para los desplazamientos obtenidos de la distribución de Lévy, $x_{MF,G}$ es la solución actual de mapeo de MF y $x_{MF,best}$ es la mejor solución encontrada hasta el momento; es necesario tomar en cuenta que del factor de escalamiento, α_0 , depende cuan cerca/lejos se encuentren las nuevas soluciones además de que desplazamientos muy grandes pueden dar lugar a soluciones fuera del dominio de solución lo cual no es conveniente. En este sentido, de acuerdo a la literatura, un coeficiente de $\alpha_0 = 0.01$ o $\alpha_0 = 0.1$ puede ser suficiente en la mayoría de problemas (X.-S. Yang, 2014), aunque en otros estudios se han conseguido mejores resultados al emplear un coeficiente variable $\alpha_0 \sim U(0,1)$ (Wang, Yin, & Zhong, 2015). En el presente trabajo, de acuerdo con la literatura (Wang et al., 2015; X.-S. Yang, 2014) y con el objetivo principal de que las nuevas soluciones no generen saltos muy grandes y se conserve cierta lógica dentro de la teoría de control FL en la disposición de las MF, el coeficiente α_0 para la generación de nuevas soluciones en cada iteración será obtenido de una distribución uniforme definida de la siguiente manera:

$$\alpha_0 \square U(0.01, 0.1) \quad (4.33)$$

Adicionalmente, los vuelos de Lévy son generados mediante el algoritmo de Mantegna de acuerdo a la expresión (Mantegna, 1994):

$$Lévy(\beta) = \frac{U}{|V|^{1/\beta}} \quad (4.34)$$

$$U \square N(0, \sigma^2), V \square N(0, 1) \quad (4.35)$$

Donde (4.35) hace referencia a que los valores de U son obtenidos de una distribución Gaussiana normal con media cero y varianza σ^2 . La varianza se calcula mediante la expresión:

$$\sigma^2 = \left[\frac{\Gamma(1+\beta)}{\beta \cdot \Gamma\left(\frac{1+\beta}{2}\right)} \cdot \frac{\sin\left(\frac{\beta\pi}{2}\right)}{2^{\frac{\beta-1}{2}}} \right]^{1/\beta} \quad (4.36)$$

Ha sido demostrado en varios estudios que el algoritmo de Mantegna produce números aleatorios que obedecen la distribución requerida (Mantegna, 1994; Wang et al., 2015; X. Yang & Deb, 2009; X.-S. Yang, 2014).

Cabe recalcar que el proceso anteriormente descrito se aplica únicamente para los parámetros referentes a posiciones de MF y rango máximo y mínimo de salida del FLC.

Para la generación de nuevas soluciones (intensificación) en el caso de la base de reglas, en una generación $G(G > 0)$, una nueva solución es generada de acuerdo con la siguiente expresión:

$$x_{RL,G+1} = x_{RL,G} + s_{RL} \cdot (x_{RL,G} - x_{RL,best}) \quad (4.37)$$

Donde $x_{RL,G}$ es la solución actual de disposición de la base de reglas, $x_{RL,best}$ es la mejor solución para la base de reglas encontrada hasta el momento, s_{RL} es un número aleatorio entero que desplaza la base de reglas en cada nueva búsqueda y está definido como:

$$s_{RL} \square N(0,1) \quad (4.38)$$

4.3.4 Diversificación o Exploración

Esta característica de los algoritmos metaheurísticos permite la generación de soluciones en puntos del espacio de diseño factible lo suficientemente lejos de las soluciones actuales con el fin de evitar quedar atrapados en mínimos locales (Muñoz, 2006; X.-S. Yang, 2014).

En el algoritmo en cuestión, esta característica se implementa mediante el parámetro p_a que ya fue expuesto en la Sección 2.6.2 y que da lugar a la generación de nuevas soluciones en puntos alejados del espacio de diseño factible mediante permutaciones aleatorias de las soluciones ya encontradas anteriormente (Wang et al., 2015; X. Yang & Deb, 2009; X.-S. Yang, 2014).

En primer lugar, una solución de prueba es generada mediante un valor de “mutación” que se obtiene al calcular el desplazamiento diferencial entre dos soluciones actuales seleccionadas de manera aleatoria y al multiplicar este valor por un número aleatorio. En segundo lugar, una nueva solución se obtiene mediante una “recombinación” resultante entre una solución actual y la solución de prueba (Wang et al., 2015). Este procedimiento puede formularse matemáticamente de la siguiente manera:

$$X_{G+1} = \begin{cases} X_G + r \cdot (X_{m,G} - X_{n,G}); & p_a \leq 0.25 \\ X_G & ; p_a > 0.25 \end{cases} \quad (4.39)$$

Donde m y n son índices aleatorios, y r es un número aleatorio en el rango $r \in [0,1]$.

Cabe mencionar que el algoritmo repite los procesos de intensificación y diversificación en cada iteración hasta que se encuentra la solución que minimiza la función definida en (4.10) y que involucra la mejora de la calidad de gestión energética de la EMS descrita en el presente trabajo.

4.4 Diagrama de Flujo del Algoritmo Implementado




Figura 23. Diagrama de flujo del algoritmo de búsqueda de Cuckoo implementado.

CAPÍTULO V

RESULTADOS Y DISCUSIÓN

5.1 Análisis de Resultados

El proceso de optimización de los parámetros del controlador Fuzzy Logic tomó aproximadamente 960 horas en una computadora Intel(R) Core (TM) i7-4510U CPU(2.00GHz) con el programa Matlab® que ejecutó 300 iteraciones en total para encontrar la solución óptima a la función de costo definida.

Las funciones de pertenencia optimizadas en el presente trabajo mediante el algoritmo de búsqueda de Cuckoo se ilustran superpuestas a su distribución inicial expuesta en la Sección 4.1 y se comparan con las funciones de pertenencia obtenidas mediante algoritmos heurísticos de acuerdo con (Diego Arcos-Aviles, Guinjoan, et al., 2018; Diego Arcos-Aviles et al., 2019), a continuación:

- Entrada: Error de Predicción, P_E .

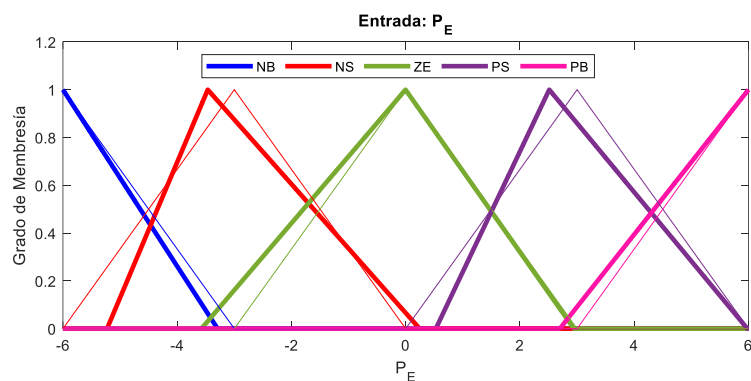


Figura 24. MF optimizadas para la entrada P_E mediante el algoritmo CS.




Figura 25. MF optimizadas para la entrada P_E mediante algoritmos heurísticos.

Fuente: (D. Arcos-Aviles et al., 2016). ©2016 IEEE.

Tabla 8

Comparación de posiciones de MF para la entrada P_E .

	<i>NB</i>			<i>NS</i>			<i>ZE</i>			<i>PS</i>			<i>PB</i>		
Fuzzy EMS-FC	-6	-6	-3	-6	-3	0	-3	0	3	0	3	6	3	6	6
Fuzzy EMS-FC CS	-6	-6	-3.3	-5.3	-3.5	0.2	-3.6	0	2.9	0.5	2.5	5.9	2.9	6	6

➤ Entrada: Estado de Carga de Batería, SOC .

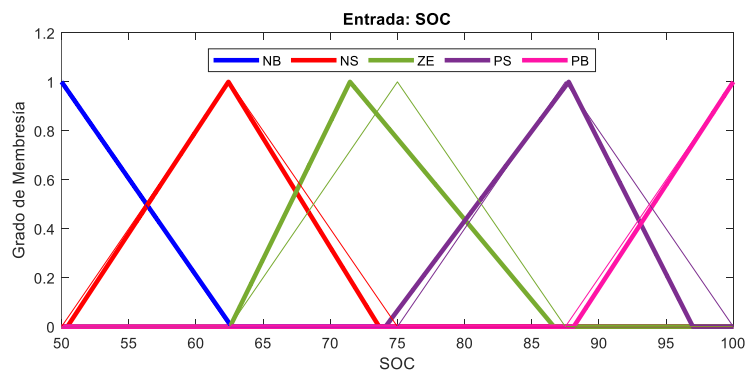


Figura 26. MF optimizadas para la entrada SOC mediante el algoritmo CS.

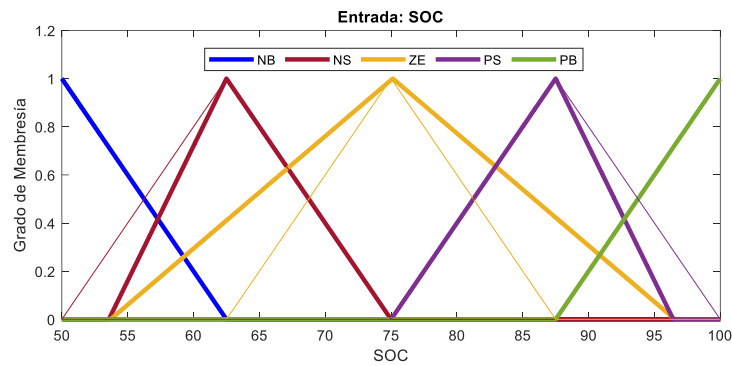


Figura 27. MF optimizadas para la entrada SOC mediante algoritmos heurísticos.

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

Tabla 9

Comparación de posiciones de MF para la entrada SOC .

	<i>NB</i>		<i>NS</i>		<i>ZE</i>		<i>PS</i>		<i>PB</i>						
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 CS	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

➤ Salida: Salida de FLC, P_{FLC} .

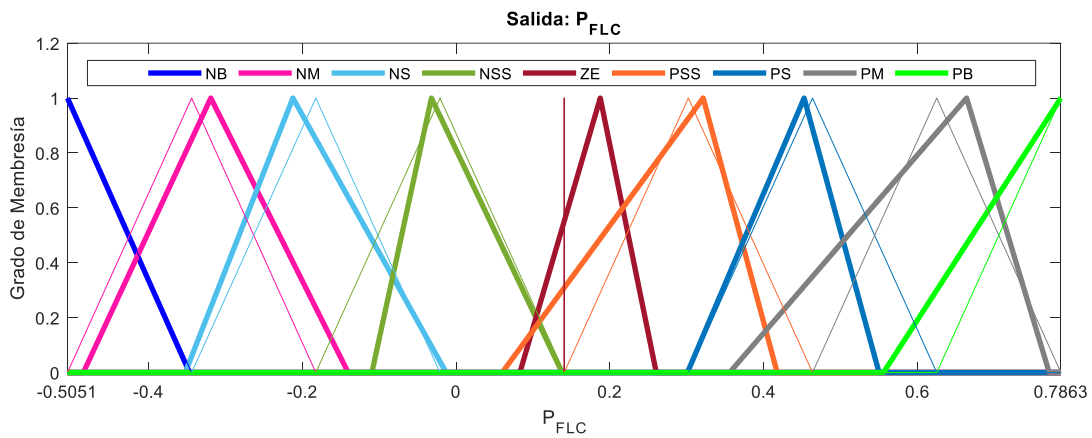


Figura 28. MF optimizadas para la salida P_{FLC} mediante el algoritmo CS.

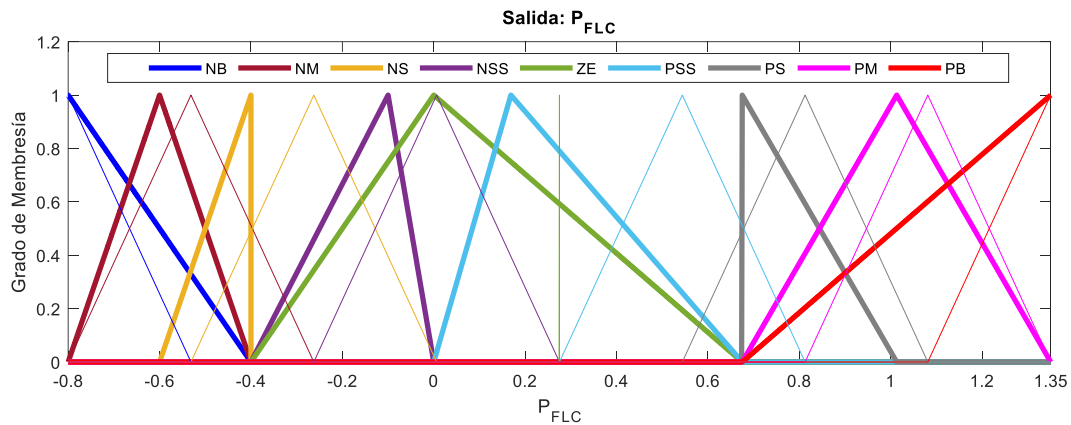


Figura 29. MF optimizadas para la salida P_{FLC} mediante algoritmos heurísticos.

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

Tabla 10

Comparación de posiciones de MF y rango de salida para la variable P_{FLC} .

	<i>NB</i>		<i>NM</i>		<i>NS</i>		<i>NSS</i>		<i>ZE</i>						
Fuzzy	-0.8	-0.8	-0.4	-0.8	-0.6	-0.4	-0.6	-0.4	-0.4	-0.4	-0.1	0	-0.4	0	0.68
EMS-FC	-0.5	-0.5	0.35	0.45	0.32	0.14	0.35	0.21	0	-0.1	0	0.14	0.08	0.19	0.26
Fuzzy	<i>PSS</i>		<i>PS</i>		<i>PM</i>		<i>PB</i>								
EMS-FC	0	0.17	0.68	0.68	0.68	1	0.68	1	1.35	0.68	1.35	1.35			
Fuzzy	0.06	0.32	0.42	0.3	0.45	0.55	0.36	0.66	0.77	0.55	0.78	0.78			
EMS-FC															
CS															

De acuerdo a los resultados obtenidos de la optimización mostrados anteriormente, se puede ver la utilidad de empezar la búsqueda de soluciones aleatorias a partir de una distribución inicial ya que se conserva una simetría y coherencia en la distribución de las funciones de pertenencia; de la misma manera, se observa a continuación la base de reglas del controlador optimizadas mediante

el algoritmo CS que conservan cierta similitud con la distribución inicial expuesta en la Sección 4.1 y que fueron definidas mediante conocimiento heurístico del funcionamiento de la microrred.

Tabla 11

Base de Reglas Estrategia EMS-FC optimizadas mediante el algoritmo CS.

P_{FLC}		$P_E(n)$				
		NB	NS	ZE	PS	PB
$SOC(n)$	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

Tabla 12

Base de Reglas Estrategia EMS-FC optimizadas mediante algoritmos heurísticos

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

Fuente: (Diego Arcos-Aviles, Guinjoan, et al., 2018). ©2018 IEEE.

Para evaluar la optimización de la EMS, se comparan los parámetros de calidad de gestión energética descritos en la Sección 2.3 entre la EMS descrita en (Diego Arcos-Aviles, Guinjoan, et al., 2018; Diego Arcos-Aviles et al., 2019) y la EMS optimizada en el presente trabajo.

En primer lugar, el objetivo de la EMS es mantener el SOC de batería en un rango seguro de operación con el fin de prolongar la vida útil de almacenamiento, $50\% < SOC < 100\%$, y centrada en 75% . En la Figura 30, se muestra el SOC de la EMS optimizada mediante el algoritmo CS sobrepuesta al de la EMS optimizada mediante métodos heurísticos, se puede apreciar el SOC de la EMS optimizada tiene una ligera mayor tendencia a permanecer entre valores cercanos a 75% , de mejor manera se ilustra lo dicho anteriormente en la Figura 31.

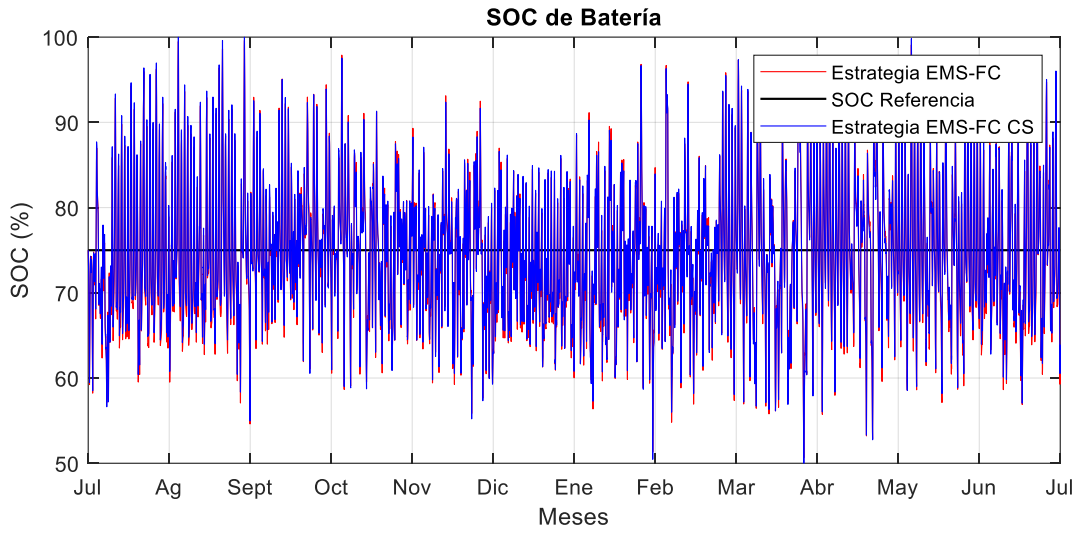


Figura 30. Comparación de SOC de batería.

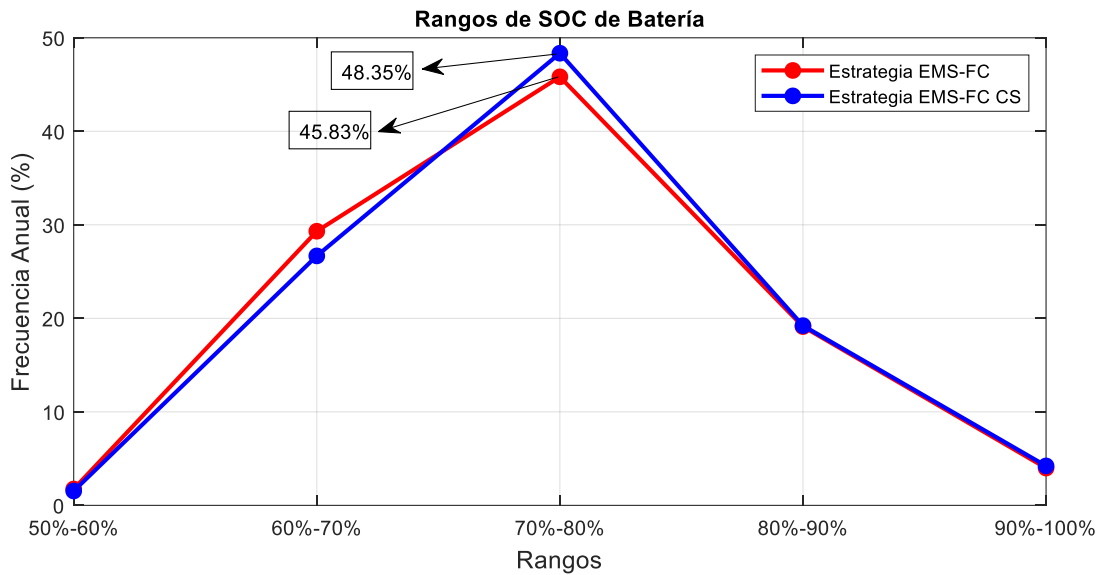


Figura 31. Comparación de rangos de SOC.

De acuerdo a lo mencionado anteriormente, la EMS optimizada mediante el algoritmo CS permite que el SOC permanezca en un rango central (70% – 80%) un mayor porcentaje de tiempo, 48.35% , en comparación con la EMS optimizada mediante métodos heurísticos, 45.83% ,

En segundo lugar, el objetivo de la EMS es minimizar las fluctuaciones perfil de la potencia que la microrred intercambia con la red eléctrica y que están relacionados con los parámetros de calidad de gestión energética. En la Figura 32, se observa el perfil de potencia intercambiado resultante de la EMS optimizada mediante el algoritmo CS sobrepuesta al de la EMS optimizada mediante métodos heurísticos con los parámetros de interés: Pico máximo del perfil de red y pico mínimo del perfil de red. En la Figura 33, se observan las rampas de los perfiles de potencia presentados en la Figura 32 y sus valores máximos.




Figura 32. Comparación de perfiles de potencia intercambiada.

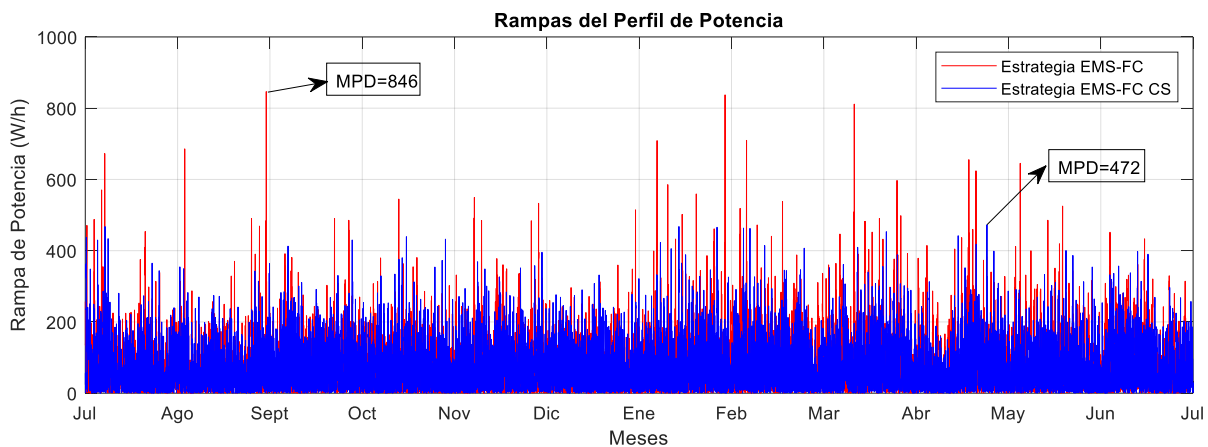


Figura 33. Comparación de rampas de perfil de potencia.

En la siguiente tabla, se resumen los parámetros de calidad de la gestión energética para las EMS optimizada mediante el algoritmo CS y mediante métodos heurísticos. Se puede observar la disminución de los parámetros de calidad lo cual involucra la optimización de la EMS y que era el objetivo principal de realización del presente trabajo.

Tabla 13

Criterios de calidad de la gestión energética Estrategia EMS-FC.

EMS Estrategia	$P_{G,MAX}$ (kW)	$P_{G,MIN}$ (kW)	MPD(W / h)	PVR	APD(W / h)	PPV
Fuzzy EMS-FC (Diego Arcos-Aviles, Guinjoan, et al., 2018)	2.56	-1.89	846	0.34	75	1.26
Fuzzy EMS-FC Optimizada CS	2.51	-1.66	472	0.32	75	1.25

CAPÍTULO VI

CONCLUSIONES Y RECOMENDACIONES

6.1. Conclusiones

El presente trabajo ha permitido demostrar la potencialidad del algoritmo metaheurístico inspirado en la naturaleza de búsqueda de Cuckoo en la optimización de problemas a escala global mediante su aplicación en la optimización de los parámetros del controlador Fuzzy Logic del sistema de gestión energética de una microrred electrotérmica.

Para que la optimización se lleve a cabo de manera correcta para cada uno de los parámetros de calidad de una estrategia de gestión energética fue necesario formular una función de costo que abarque cada uno de estos parámetros; además, fue necesario asignar una ponderación específica a cada uno de estos parámetros (objetivos de optimización) de acuerdo a las necesidades específicas del problema.

La estrategia de gestión energética optimizada cumple con los objetivos de disminuir las fluctuaciones del perfil de potencia intercambiado entre la microrred y la red eléctrica, y mantener el estado de carga del sistema de almacenamiento en un rango seguro, lo cual garantiza el correcto funcionamiento de la microrred. Estos objetivos se plasman en la disminución de los parámetros de calidad de la gestión energética (Tabla 13), por lo que evidencian resultados satisfactorios.

Anteriormente la optimización de cada uno de los parámetros del FLC se realizaba mediante procedimientos heurísticos de prueba y error que condujeron a una solución buena sin ser necesariamente la mejor posible, aunque en un período de tiempo excesivamente grande. En el presente trabajo, al emplear el algoritmo de búsqueda de Cuckoo para optimizar los parámetros del

controlador se tiene certeza de que la solución representa el óptimo global del problema de optimización y con un tiempo de computo menor.

Para la implementación del algoritmo en el ajuste de parámetros del controlador Fuzzy Logic, fue de vital importancia la creación de nuevas soluciones aleatorias a partir de una distribución inicial simétrica y ordenada ya que así el algoritmo no realiza una búsqueda "ciega", con esto se logra que las soluciones sean de la forma deseada y que presenten orden y coherencia.

6.2.Recomendaciones

Emplear una distribución inicial uniforme para el mapeo de funciones de pertenencia y base de reglas para que las soluciones aleatorias generadas sigan un patrón establecido.

Definir correctamente cada una de las ponderaciones para cada uno de los objetivos de optimización de acuerdo con las preferencias de minimización de cada uno de estos y en base a requerimientos específicos de problema, ya que de esto depende el éxito o no de los resultados.

6.3.Trabajos Futuros

En el presente trabajo se realizó un ajuste fuera de línea con datos históricos de consumo y generación; sin embargo, debido a que la estrategia de gestión energética contempla algoritmos de predicción, se puede realizar una optimización en línea para una posterior implementación dentro de una microrred que funciona en tiempo real.

Proponer la realización de un estudio similar empleando otros algoritmos metaheurísticos inspirados en la naturaleza que han mostrado gran potencialidad en optimización de problemas a escala global, tales como: Optimización por Enjambre de Partículas, Algoritmos Genéticos, Evolución Diferencial, entre otros.

BIBLIOGRAFÍA

- 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., Pascual, J., Gispert, F., Marroyo, L., Sanchis, P., & Marietta, M. (2017). Low complexity energy management strategy for grid profile smoothing of a residential grid-connected microgrid using generation and demand forecasting. *Applied Energy*, 205, 69-84. <https://doi.org/10.1016/j.apenergy.2017.07.123>
- 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)*, 742-747. <https://doi.org/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)*, 99-105. <https://doi.org/10.1109/ISIE.2017.8001230>
- Arcos-Aviles, Diego, 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*, 1824-1829. <https://doi.org/10.1109/IECON.2018.8591575>

- Arcos-Aviles, Diego, 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. En E. Motoasca, A. K. Agarwal, & H. Breesch (Eds.), *Energy Sustainability in Built and Urban Environments* (pp. 165-199). https://doi.org/10.1007/978-981-13-3284-5_8
- Arcos-Aviles, Diego, 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>
- Arul, P. G., Ramachandaramurthy, V. K., & Rajkumar, R. K. (2015). Control strategies for a hybrid renewable energy system: A review. *Renewable and Sustainable Energy Reviews*, 42, 597-608. <https://doi.org/10.1016/j.rser.2014.10.062>
- Baker, B. M., & Ayechev, M. A. (2003). A genetic algorithm for the vehicle routing problem. *Computers & Operations Research*, 30(5), 787-800. [https://doi.org/10.1016/S0305-0548\(02\)00051-5](https://doi.org/10.1016/S0305-0548(02)00051-5)
- Balci, H. H., & Valenzuela, J. F. (2004). Scheduling electric power generators using particle swarm optimization combined with the lagrangian relaxation method. *International Journal of Applied Mathematics and Computer Science*, 14(3), 411-421.
- CEPAL. (2015). Agenda 2030 para el Desarrollo Sostenible [Text]. Recuperado 2 de noviembre de 2018, de <https://www.cepal.org/es/temas/agenda-2030-desarrollo-sostenible>
- Chechkin, Aleksei V., Gonchar, V. Y., Klafter, J., & Metzler, R. (2006). Fundamentals of Lévy Flight Processes. En W. T. Coffey & Y. P. Kalmykov (Eds.), *Advances in Chemical Physics* (pp. 439-496). <https://doi.org/10.1002/0470037148.ch9>

- Chechkin, Alexei V., Metzler, R., Klafter, J., & Gonchar, V. Yu. (2008). Introduction to the Theory of Lévy Flights. En R. Klages, G. Radons, & I. M. Sokolov (Eds.), *Anomalous Transport* (pp. 129-162). <https://doi.org/10.1002/9783527622979.ch5>
- Chen, G., & Pham, T. T. (2001). *Introduction to fuzzy sets, fuzzy logic, and fuzzy control systems*. Boca Raton, FL: CRC Press.
- Civicioglu, P., & Besdok, E. (2013). A conceptual comparison of the Cuckoo-search, particle swarm optimization, differential evolution and artificial bee colony algorithms. *Artificial Intelligence Review*, 39(4), 315-346. <https://doi.org/10.1007/s10462-011-9276-0>
- Consejo Nacional de Planificación. (2017). «Plan Nacional de Desarrollo 2017-2021 Toda una Vida» de Ecuador. Recuperado 2 de noviembre de 2018, de <https://observatorioplanificacion.cepal.org/es/planes/plan-nacional-de-desarrollo-2017-2021-toda-una-vida-de-ecuador>
- D'Negri, C. E., & De Vito, E. L. (2006). Introducción al razonamiento aproximado: lógica difusa. *Revista Americana de Medicina Respiratoria*, 6(3). Recuperado de <http://www.redalyc.org/resumen.oa?id=382138367007>
- Gutowski, M. (2001). Lévy flights as an underlying mechanism for global optimization algorithms. *arXiv:math-ph/0106003*. Recuperado de <http://arxiv.org/abs/math-ph/0106003>
- Hatziargyriou, N., Asano, H., Iravani, R., & Marnay, C. (2007). Microgrids. *IEEE Power and Energy Magazine*, 5(4), 78-94. <https://doi.org/10.1109/MPAE.2007.376583>
- Hatziargyriou, Nikos. (2014). *Microgrids: Architectures and Control*. John Wiley & Sons.
- International Energy Agency. (2017a). *CO2 Emissions from Fuel Combustion 2017 - Highlights*. 162.
- International Energy Agency. (2017b). *Key World Energy Statistics 2017*. 1-81.

- International Energy Agency. (2017c). Renewables Information 2017: Overview. Recuperado 19 de agosto de 2018, de IEA webstore website: <https://webstore.iea.org/renewables-information-2017-overview>
- Johnston, R. L. (Ed.). (2004). *Applications of Evolutionary Computation in Chemistry*. Recuperado de [//www.springer.com/la/book/9783540402589](http://www.springer.com/la/book/9783540402589)
- 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*, 58(10), 4583-4592. <https://doi.org/10.1109/TIE.2011.2119451>
- Katiraei, F., Iravani, R., Hatziargyriou, N., & Dimeas, A. (2008). Microgrids management. *IEEE Power and Energy Magazine*, 6(3), 54-65. <https://doi.org/10.1109/MPE.2008.918702>
- Lasseter, B. (2001). Microgrids [distributed power generation]. *2001 IEEE Power Engineering Society Winter Meeting. Conference Proceedings (Cat. No.01CH37194)*, 1, 146-149 vol.1. <https://doi.org/10.1109/PESW.2001.917020>
- Levy, P. (1939). L'addition des variables aléatoires définies sur une circonférence. *Bulletin de la Sociéte mathématique de France*, 2, 1-41. <https://doi.org/10.24033/bsmf.1288>
- Mantegna, R. N. (1994). Fast, accurate algorithm for numerical simulation of Lévy stable stochastic processes. *Physical Review E*, 49(5), 4677-4683. <https://doi.org/10.1103/PhysRevE.49.4677>
- Marler, R. Timothy, & Arora, J. S. (2010). The weighted sum method for multi-objective optimization: new insights. *Structural and Multidisciplinary Optimization*, 41(6), 853-862. <https://doi.org/10.1007/s00158-009-0460-7>

- Marler, R.T., & Arora, J. S. (2004). Survey of multi-objective optimization methods for engineering. *Structural and Multidisciplinary Optimization*, 26(6), 369-395. <https://doi.org/10.1007/s00158-003-0368-6>
- Mehboob, U., Qadir, J., Ali, S., & Vasilakos, A. (2016). Genetic algorithms in wireless networking: techniques, applications, and issues. *Soft Computing*, 20(6), 2467-2501. <https://doi.org/10.1007/s00500-016-2070-9>
- Miramontes, O. (2014). *Física de la movilidad y de las búsquedas*. 6.
- Mohamed, A., & Mohammed, O. (2013). Real-time energy management scheme for hybrid renewable energy systems in smart grid applications. *Electric Power Systems Research*, 96, 133–143. <https://doi.org/10.1016/j.epsr.2012.10.015>
- Muñoz, D. (2006). *Metaheurísticas*. 244.
- Nguyen, H., Prasad, N., Walker, C., & Walker, E. (2002). *A First Course in Fuzzy and Neural Control*. <https://doi.org/10.1201/9781420035520>
- 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(4), 1905-1919. <https://doi.org/10.1109/TSG.2013.2295514>
- 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*. Menlo Park, Calif: Addison-Wesley.

- Rahbar, K., Xu, J., & Zhang, R. (2015). Real-Time Energy Storage Management for Renewable Integration in Microgrid: An Off-Line Optimization Approach. *IEEE Transactions on Smart Grid*, 6(1), 124-134. <https://doi.org/10.1109/TSG.2014.2359004>
- Rani, K. N. A., Hoon, W. F., Malek, M. F. A., Affendi, N. A. M., Mohamed, L., Saudin, N., ... Neoh, S. C. (2012). Modified cuckoo search algorithm in weighted sum optimization for linear antenna array synthesis. *2012 IEEE Symposium on Wireless Technology and Applications (ISWTA)*, 210-215. <https://doi.org/10.1109/ISWTA.2012.6373845>
- Varol, H. A., & Bingul, Z. (2004). A new PID tuning technique using ant algorithm. *Proceedings of the 2004 American Control Conference*, 3, 2154-2159 vol.3. <https://doi.org/10.23919/ACC.2004.1383780>
- Vilches, J. E. F. (2015). *Diseño e Implementación de Algoritmo de Búsqueda Cuckoo para Ajuste de Funciones de Selección*. 50.
- Wang, L., Yin, Y., & Zhong, Y. (2015). Cuckoo search with varied scaling factor. *Frontiers of Computer Science*, 9(4), 623-635. <https://doi.org/10.1007/s11704-015-4178-y>
- Woźniak, M., & Połap, D. (2014). Basic concept of Cuckoo Search Algorithm for 2D images processing with some research results: An idea to apply Cuckoo Search Algorithm in 2D images key-points search. *2014 International Conference on Signal Processing and Multimedia Applications (SIGMAP)*, 157-164.
- Wu, C., Lai, K., & Sun, R. (2008). GA-Based Job Scheduling Strategies for Fault Tolerant Grid Systems. *2008 IEEE Asia-Pacific Services Computing Conference*, 27-32. <https://doi.org/10.1109/APSCC.2008.165>

- Yang, X., & Deb, S. (2009). Cuckoo Search via Lévy flights. *2009 World Congress on Nature Biologically Inspired Computing (NaBIC)*, 210-214.
<https://doi.org/10.1109/NABIC.2009.5393690>
- Yang, X.-S. (2013). Bat Algorithm and Cuckoo Search: A Tutorial. En X.-S. Yang (Ed.), *Artificial Intelligence, Evolutionary Computing and Metaheuristics: In the Footsteps of Alan Turing* (pp. 421-434). https://doi.org/10.1007/978-3-642-29694-9_17
- Yang, X.-S. (2014). *Nature-inspired optimization algorithms* (First edition). Amsterdam ; Boston: Elsevier.
- Yang, X.-S., & Deb, S. (2013). Multiobjective cuckoo search for design optimization. *Computers & Operations Research*, 40(6), 1616-1624. <https://doi.org/10.1016/j.cor.2011.09.026>
- Yazdanian, M., & Mehrizi-Sani, A. (2014). Distributed Control Techniques in Microgrids. *IEEE Transactions on Smart Grid*, 5(6), 2901-2909. <https://doi.org/10.1109/TSG.2014.2337838>
- Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, 8(3), 338-353.
[https://doi.org/10.1016/S0019-9958\(65\)90241-X](https://doi.org/10.1016/S0019-9958(65)90241-X)

ⁱ Reprinted from Nature-Inspired Optimization Algorithms, First edition 2014, Xin-She Yang, Chapter 9 Cuckoo Search, Pages 129-139., Copyright © 2014, with permission from Elsevier.