




Estrategias de Inteligencia Computacional

para la Gestión Óptima de Potencia
Eléctrica en Microrredes

Fabián Andrés Zúñiga Cardona

Ingeniero Electrónico, Universidad del Valle

Danny Mauricio López Santiago

Ingeniero Electrónico, Universidad del Valle

Eduardo Francisco Caicedo Bravo

Ingeniero Electricista, Universidad del Valle



Esta investigación aborda el problema de la gestión óptima de la potencia eléctrica en microrredes, a través de la implementación de estrategias basadas en dos técnicas inteligentes multiobjetivo: MOGA y SPEA2. La optimización se lleva a cabo sobre dos objetivos conflictivos entre sí: los costos operativos de la microrred y las emisiones de gases contaminantes. La investigación incorpora una metodología para la comparación del desempeño obtenido por cada técnica inteligente implementada. Dicho estudio se basa en un análisis de las características de: costos, emisiones y distribución de la energía. La metodología también propone un estudio de los conjuntos solución obtenidos, mediante la aplicación de métricas especializadas, relacionadas con los conceptos de no-dominancia y repetitividad. Los conjuntos solución se obtienen luego de 24 horas de simulación por cada técnica empleada, tanto para los modos de operación aislado, como para el modo de operación conectado a una red pública de

Palabras Clave: Microrredes, Gestión Óptima de Potencia, Inteligencia Computacional

This work addresses optimal microgrid power management problem, through implementation of strategies based on two computational intelligence algorithms: MOGA and SPEA2. Optimization faces two conflictive objectives: operation costs of microgrid and greenhouse emissions, for each technique implemented. The work includes a framework based on costs, emissions and energy share to compare the implemented strategies. The framework also studies the solution sets obtained, through specialized metrics based on non-dominance and repeatability. A 24 hours simulation produces the solution sets for each technique carried up for isolated mode and grid-connected mode.

Keywords: Microgrids, Optimal Power Management, Computational Intelligence

I. Introducción

Debido a una obsoleta arquitectura centralizada, la cual separa, incluso por cientos de kilómetros, los centros de generación de los centros de consumo, las redes eléctricas convencionales hoy día resultan ser insostenibles, pródigas y contaminantes. Las smartgrids, o redes eléctricas inteligentes, comprenden un nuevo concepto del que se espera la capacidad para incrementar la eficiencia y rentabilidad de dichas redes eléctricas convencionales, además de disminuir la contaminación ambiental que ellas producen. Para lograrlo, es necesario integrar las tecnologías de la información y la comunicación a las redes eléctricas, lo cual, entre otras cosas permita una gestión óptima y bidireccional del recurso energético entre proveedores y consumidores, con el ánimo de construir un mercado más participativo y competitivo [1]. En ese sentido, el desarrollo de smartgrids debe proveer las herramientas que permitan llevar a cabo esa gestión óptima y bidireccional, incluso considerando una diversa y amplia incorporación de la generación distribuida (Distributed Generation, DG), basada tanto en fuentes energéticas convencionales (Distributed Energy Resources, DER), como de energías alternativas o no convencionales (Alternative Energy Distributed Generation, AEDG), [2].

No obstante, esa DG puede considerarse como parte integral de una red eléctrica de escala pequeña, autónoma y de medio o bajo voltaje, a la que sea posible añadirle otras características como la escalabilidad, la gestión eficiente de activos y la reducción de la contaminación ambiental, entre otras. La idea general de esta visión es propiciar una evolución de la red eléctrica tradicional hacia la smartgrid, subdividiendo sus problemas para ser abordados a través de redes más pequeñas: las microrredes [3].

Sin embargo, en una microrred las características de heterogeneidad y escalabilidad en las tecnologías de DG proponen un reto complejo: proveer una herramienta capaz de gestionar la potencia generada por esas unidades DG, optimizando tanto los recursos energéticos, como los económicos; al tiempo que se reduce el impacto ambiental negativo, por ejemplo relacionado con las emisiones de gases de efecto invernadero y lluvia ácida [4].

En un contexto computacional, este problema puede modelarse como uno de optimización multiobjetivo con restricciones (MO), tema ya abordado desde varios ángulos por [5], [6], [7], [8] y [9]. No obstante, estas investigaciones proponen esquemas que no hacen parte de una arquitectura jerárquica de control, además de estar orientados a microrredes no adaptadas al contexto colombiano. Por otra parte, dado el costo computacional que un problema MO implica para su solución, por encima de las técnicas de programación matemática tradicionales se prefiere a las de computación evolutiva, las basadas en heurísticas o, en general, las de inteligencia computacional, [10].

En otro sentido, dado que existe una relación natural entre las posibles unidades de generación AEDG en una microrred y el potencial de dichas energías alternativas en la zona, la gestión óptima realizada debe tomar en cuenta esa realidad energética local e incorporarla en el esquema de optimización. Lo anterior implica incluir los modelos que representen la naturaleza de esas AEDG, con base en estudios del potencial energético regional sobre energías alternativas. Para el caso colombiano, son de utilidad los estudios de oportunidad y desarrollo llevados a cabo [11] y [12].

Este trabajo aborda la gestión óptima de la potencia eléctrica en una microrred a través de la implementación de dos estrategias basadas en algoritmos de inteligencia computacional



para solucionar problemas de MO, los cuales han mostrado buen desempeño de optimización para otras áreas no relacionadas con microrredes, ellas son: Multiobjective Optimization Genetic Algorithm, MOGA y Strength Pareto Evolutionary Algorithm, SPEA2. Además, la aproximación se implementa como parte de la estructura jerárquica de control propuesta en [13]. Ambos esquemas de optimización utilizan un modelo de microrred construido con base en tecnologías AEDG consideradas según el potencial de energías renovables en Colombia. La optimización en sí se logra al considerar la minimización de dos objetivos conflictivos entre sí:

- Reducir costos económicos asociados a la operación.
- Reducir las emisiones de NOX, SOX y CO2.

Al conjunto de objetivos se añaden restricciones de equilibrio y límites de potencia en la operación. La simulación se lleva a cabo en un escenario de 24 horas, donde la microrred opera tanto en modo conectado a la grid, como desconectado de ella (modo de emergencia donde no es posible acceder a la potencia de la red pública). En el ejercicio se evalúan 24 horas de operación por cada modo y técnica empleada, con lo cual se obtienen 96 simulaciones en total. La optimización se complementa con la aplicación de reglas que permiten escoger el punto final de operación dentro de los conjuntos solución ofrecidos por las técnicas de MO. Adicional a esto, se presenta una metodología de comparación basada en parámetros tanto eléctricos, como métricas computacionales, la cual busca verificar la prevalencia de una técnica de optimización sobre la otra.

El presente artículo resume los resultados preliminares del proyecto de investigación Estrategias Basadas en Inteligencia Computacional, para la Gestión de la Potencia Eléctrica en Ambientes de Microgrids (Microrredes), desarrollado por los grupos de

investigación Percepción y Sistemas Inteligentes – PSI, Grupo de Investigación en Alta Tensión – GRALTA y Grupo de Estudios Doctorales en Informática – GEDI.

II. Modelo de Microrred.

El modelo de microrred considerado se conforma de un grupo de cargas eléctricas alimentadas por un conjunto de fuentes energéticas distribuidas DG, y conectadas a través de una red o bus de bajo voltaje LV. Ver Fig.1. La Tabla I señala los elementos que hacen parte del modelo, los mismos son descritos a continuación:

A. EMS:

Un controlador central, también llamado sistema de gestión de energía o EMS [14], será encargado de gestionar los estados de operación de los DG así como de tomar las decisiones de importación o exportación de energía desde y hacia la grid principal. Este sistema hace parte de una arquitectura jerárquica de control (ver Fig. 2), cuyas capas pueden citarse como:




Fig. 1. Esquema conceptual general para una microrred eléctrica.

1) Control Primario: control descentralizado usado para ajustar la frecuencia, el voltaje y para intercambiar potencia activa y reactiva entre los generadores, ofreciendo estabilidad y desempeño al conjunto.

2) Control Secundario: corrige el error de estado estacionario introducido por el control primario y de la sincronización con la grid principal antes de establecer una posible conexión, etc.

3) Control Terciario: produce el conjunto de puntos de operación para las unidades DER, tanto en modo aislado, como en modo conectado a la grid principal, y asiste las decisiones globales de importación/exportación de energía, etc. en el modo conectado [13].

Elemento	Descripción
AEDG	Fuente de generación de energía alternativa (renovable)
CB	Interruptor de circuito
EMS	Sistema de administración de energía
DER	Fuente distribuida de energía
DS	Sistema de almacenamiento con baterías
MC	Controlador de la microfuelle o unidad DG
PL	Carga eléctrica
TR	Transformador de distribución

Tabla 1. Convenciones para el esquema general de microrred mostrado en la Fig. 1

El control terciario o sistema de gestión de energía (EMS) requiere para su operación de las variables en tiempo real. Ver Fig. 2:




Fig. 2. Arquitectura jerárquica de control en una microrred.

- Demanda de potencia eléctrica total en la carga

- Oferta disponible de potencia eléctrica en AEDG

- Estado del sistema de almacenamiento distribuido DS

- Precio de importación de la potencia eléctrica

- Precio de exportación de la potencia eléctrica

- Costos externos por emisión de gases

- Costos de operación y mantenimiento de DER

4) DM: este podría ser un agente humano o sistematizado (añadido al EMS) ubicado en la cima del control jerarquizado. En la Fig. 2 se aprecian las acciones ejecutivas que tiene a cargo el DM. Este DM debe tomar las decisiones finales sobre los resultados arrojados por el EMS, con base en información complementaria como el precio actual de la energía, etc. Ver Fig. 3.




Fig. 3. Flujo de información hacia y desde el Sistema de Gestión de Energía EMS.

B. Tecnologías AEDG

Se consideran con prelación en su uso dada la participación de recursos energéticos renovables como los eólicos, de radiación solar o de energía potencial hidráulica:

- 1) Generador Eólico – WT
- 2) Generador Fotovoltaico – PV
- 3) Pequeña Central Hidroeléctrica – SHP
- 4) Sistema de Almacenamiento – DS

C. Tecnologías DER:

Para el grupo de generadores DER se tienen las siguientes tecnologías y consideraciones sobre ellas:

1) Generador Diésel/Biodiésel – DG/BG: Se trata de una tecnología muy difundida en

Colombia, la cual aunque es considerada contaminante, su eficiencia y sus costos de inversión/operación la hacen todavía atractiva. Algunos de estos generadores diésel se certifican hoy día para utilizar combustibles 100% de origen vegetal (B100) [15], con lo cual es posible reducir sus emisiones.




Fig. 4. Representación esquemática general para la grid principal.




Fig. 5. Ejemplo de perfil de carga hora por hora en un día típico de consumo.

2) Microturbina – MT: sus características más atractivas son su bajo costo de inversión, su eficiencia y sus bajas emisiones (<10ppm para NOx).

3) Celda de Combustible – FC: más allá de sus bajas emisiones, por ahora los costos de inversión de esta tecnología siguen siendo altos

4) Costos de Combustible: En general, el grupo DER se distingue del grupo AEDG por sus emisiones de gases de efecto invernadero: dióxido de carbono CO₂, y óxidos de nitrógeno NO_x, de los gases causantes de la lluvia ácida: óxidos de sulfuro SO_x, además por su consumo algún tipo de combustible, valor medido en \$. Ver ecuación 4.

5) Costos de Operación y Mantenimiento – OM: se relacionan con el nivel de potencia generado por los DER y se expresan mediante una simplificación adaptada al contexto eléctrico, ver ecuación 4.

6) Externalidades debido a Emisiones: en [16] se expone una síntesis de este tipo de costo de la cual se deriva la ecuación 21. Es posible encontrar tablas sobre tasas comparativas acerca de costos de emisión para cada una de las tecnologías de producción de energía DER de manera aislada. Ver ecuación 4.

D. Main Grid

Una red pública de energía eléctrica se modela a través del circuito mostrado en la Fig. 4. Esta red se basa en la generación de una central térmica, la cual entrega energía relativamente barata, pero con altas emisiones de gases contaminantes. De igual manera, para los ejercicios de simulación se consideran las pérdidas técnicas relacionadas con la distancia.

E. Carga Eléctrica – PL

El perfil de carga mostrado en la Fig. 5 se usa para llevar a cabo la optimización. Puede verse la evolución de los requerimientos de potencia lo cual crea una curva de demanda con horas pico y horas valle escalada para la operación de una microgrid en 24h.

III. Optimización

A. Optimización Multiobjetivo:

La forma general de un problema MO es la siguiente:

Minimizar:

$$F(x) = [F_1(x), F_2(x), \dots, F_k(x)]^T \quad (1)$$

Sujeta a:

$$g_j(x) \leq 0, j = 1, 2, \dots, m \quad (2)$$

$$h_l(x) = 0, l = 1, 2, \dots, e \quad (3)$$

Donde k es el número de funciones objetivo, m es el número de restricciones de desigualdad, y e es el número de restricciones de igualdad.

$x \in E^n$ es un vector de variables de decisión (conocidas también como variables de diseño), donde n es el número de variables independientes x_i . $F(x) \in E^k$ es un vector de funciones objetivo $F_i(x): E^n \rightarrow E^1$. $F_i(x)$ también son llamados objetivos, criterios, valores o funciones de costo. El gradiente de $F_i(x)$ con respecto a x se describe como $\nabla_x F_i(x)$ es el punto que minimiza la función objetivo.

B. Modelo de Optimización

1) Objetivo de Costos: A partir del modelo de microrred, presentado anteriormente, se agregan los costos económicos: por combustibles, por OM, por perjuicios de emisiones y de importación/exportación en una única función objetivo sintetizada en la ecuación 4.

Donde $CF(P)$ es el costo de operación de la microrred, medido en \$/h. C_i es el costo de combustible del generador i . $F_i(P_i)$ es la tasa de consumo de combustible del generador i . $OM_i(P_i)$ es el costo de operación y mantenimiento del generador i . P_i es la variable de decisión de la potencia de salida del generador i . $P = (P_1, P_2, \dots, P_N)$ es el vector de N variables de decisión. α_k es el costo externo para la emisión tipo k es el factor de emisión tipo k en la unidad j . M es el tipo de emisión (NOx, SOx y CO2) y N es el número de generadores DER de la microrred.

$$CF(P) = \sum_{i=1}^N (C_i \times F_i(P_i) + OM_i(P_i) + CEI - CEE) + \sum_{j=1}^N \sum_{k=1}^M \alpha_k (EF_{jk} P_j)$$

2) Objetivo de Emisiones: Es importante considerar las emisiones de aquellos gases conocidos por sus nocivos efectos sobre la lluvia ácida y el calentamiento global: óxidos de sulfuro (SOx), óxidos de nitrógeno (NOx) y dióxido de carbono (CO2), las cuales pueden modelarse a través de la ecuación 5 [17].

$$E(P_i) = \sum_{i=1}^N 10^{-2} (\alpha_i + \beta_i P_i + \gamma_i P_i^2) + \zeta_i \exp(\lambda_i P_i) \quad (5)$$

Donde $E(P_i)$ es la cantidad de emisiones de gases NOx, SOx y CO2 arrojados a la atmósfera como una función de la potencia de operación (medido en $\alpha_i, \beta_i, \gamma_i, \zeta_i$ y λ_i son coeficientes no negativos de las características de emisiones del generador i -ésimo.

3) Algoritmo MOGA: a continuación se presenta el pseudocódigo del algoritmo MOGA. Ver Fig. 6.

Entradas:	
N	(Tamaño de la Población)
T	(Número Máximo de Generaciones)
Pc	(Probabilidad de Cruce)
Salida:	
A	(Soluciones No Dominadas)
Inicialización:	
Genera una población inicial P_0 de manera aleatoria. Establece $t = 0$.	
Evalúa la Población Inicial:	
Calcula el valor que toman las funciones objetivo para todos los individuos en P_0 .	
Establece los rangos:	
Identifica los rangos de los individuos en P_0 de acuerdo al concepto de Dominancia de Pareto. Se asigna un valor de aptitud (<i>fitness</i>) a cada individuo.	
Formación de Nichos:	
Realiza el cómputo de los nichos de acuerdo al valor de las funciones objetivo.	
Iteraciones:	
While $t < T$	
{	
Selecciona los cromosomas con los mejores valores de aptitud, para su posterior reproducción.	
Aplica los operadores de cruce y de mutación a los individuos seleccionados.	
Evalúa la nueva población P_t .	
Establece los nuevos rangos de P_t .	
Realiza el cómputo de los nichos de acuerdo al valor de las funciones objetivo.	
Incrementa el contador de generaciones $t=t+1$.	
}	
Terminación:	
Si $t \geq T$ o algún otro criterio de parada se cumple entonces fija A con el conjunto de vectores de decisión representados por los individuos no Dominados en $P_t + 1$. Para el Proceso.	

Fig. 6. Pseudocódigo del algoritmo MOGA.

4) Algoritmo SPEA2: el pseudocódigo del algoritmo SPEA2 se presenta en la Fig. 7.

5) Estrategia de Gestión:

a) Al inicio de la hora calcular la potencia eléctrica de las fuentes AEDG: WT, FC y SHP. Obtener los precios de compra y venta de la energía a la grid principal.

b) Calcular la potencia eléctrica en el sistema DS, ya sea positiva (generador) o negativa (carga).



c) Las AEDG tienen prelación de uso, por tanto calcular la demanda neta de potencia por parte de la carga, luego de suministrar la potencia en AEDG.

d) Correr el algoritmo MOGA (Estrategia MOGA) o SPEA2 (Estrategia SPEA2), sobre los objetivos de costos y emisiones de las ecuaciones 4 y 5, y obtener de él un conjunto de soluciones, los cuales se refieren únicamente a una combinación de fuentes DER.

e) Escoger del conjunto anterior un punto de operación combinado ya sea por las fuentes DER únicamente o con ayuda de la grid principal, con base en la aplicación de un criterio fundado en las siguientes reglas (únicamente en modo conectado):

i. Calcular el costo económico de importar toda la energía deficitaria para cuando la potencia de salida en los DER es igual a cero, llamada aquí Estrategia Full Grid.

ii. Seleccionar del repositorio el primer elemento cuyo valor de costo económico sea menor (o mayor más cercano) que el valor calculado en i.

f) Fijar el punto de operación a los DER.

g) Repetir el procedimiento para la siguiente hora.

Para el modo aislado el paso f, relacionado con la selección final que hace el DM sobre el punto de operación a ser aplicado, las reglas de escogencia varían de acuerdo a una ecuación de pesos complementarios a partir de la

Entradas:	
N	(Tamaño de la Población)
$\bar{N}$	(Tamaño del Archivo)
T	(Número Máximo de Generaciones)
Pc	(Probabilidad de Cruce)
Salida:	
A	(Grupo No Dominado)
Inicialización: Genera una población inicial P_0 de manera aleatoria y crea el archivo vacío (Archivo externo) $\bar{P}_0 = \emptyset$. Establece $t = 0$.	
Asignación de fitness: Calcula el valor de <i>fitness</i> de los individuos en P_t y $\bar{P}_t$.	
Selección de ingreso al archivo: Copia todos los individuos no dominados en P_t y $\bar{P}_t$ a $\bar{P}_{t+1}$. Si el tamaño de $\bar{P}_{t+1}$ excede $\bar{N}$ entonces se reduce $\bar{P}_{t+1}$ por medio del Operador de Truncamiento, por otra parte si el tamaño de $\bar{P}_{t+1}$ es menor que $\bar{N}$ entonces se completa $\bar{P}_{t+1}$ con los mejores individuos dominados en P_t y $\bar{P}_t$.	
Terminación: Si $t \geq T$ o algún otro criterio de parada se cumple entonces fija A con el Conjunto de vectores de decisión representados por los individuos no Dominados en $\bar{P}_{t+1}$. Para el proceso.	
Selección de apareamiento: Realiza la selección a través de un torneo binario con el Repositorio de $\bar{P}_{t+1}$ con el fin de obtener los individuos para el apareamiento.	
Variación: Aplica los operadores de cruce y mutación a los individuos seleccionados y Establece en P_{t+1} la población resultante. Incrementa el contador de generaciones ($t = t + 1$) y vuelve a asignar <i>fitness</i> .	

Fig. 7. Pseudocódigo del algoritmo SPEA2.

C. Resultados de la Optimización:

Los resultados de la optimización son analizados y comparados bajo dos enfoques fundamentales: el desempeño en la operación de la microrred, basado en los costos económicos, las emisiones y la participación de la energía, y el desempeño computacional, basado en la no-dominancia, la repetibilidad y los tiempos de ejecución.

1) Costos económicos: Ver Fig. 8.




Fig. 8. Curvas de comparación de costos debido a la operación de la microrred en modo conectado (izquierda) y aislado (derecha) para las estrategias MOGA y SPEA2.

2) Emisiones: Ver Fig. 9.

3) Participación de la energía: Ver Fig. 10.

4) No-Dominancia: El esquema de clasificación consiste en tomar una solución, obtenida con alguna de las técnicas, y compararla con su símil de la técnica enfrentada. El rango de una solución será determinado en función del número de soluciones por las cuales es dominada. Ver Fig. 11.




Fig. 9. Comparación de costos debido a emisiones de la microrred en modo conectado (izquierda) y aislado (derecha) para las estrategias MOGA y SPEA2.




Fig. 10. Comparación de participación de la energía en la microgrid en modo conectado (izquierda) y aislado (derecha) para las estrategias MOGA y SPEA2.




Fig. 11. Comparación porcentual de la cantidad de soluciones clasificadas por rangos de No-dominancia, para las técnicas a) SPEA2, b) MOGA.




Fig. 12. Muestras de la hora 16 de simulación, ofrecidas por las técnicas a) SPEA2, b) MOGA.

5) Repetibilidad: Al comparar tres muestras de la frontera de Pareto, se consideran dos objetivos: primero, descubrir las irregularidades que puedan existir en los conjuntos obtenidos, y segundo, cuantificar estas irregularidades a través de un valor para establecer la medida en que los datos se concentran o se dispersan alrededor de un valor típico. Ver Fig. 12.

6) Tiempo de ejecución: Los resultados que ofrecen las técnicas de gestión SPEA2, MOGA se obtienen de simulaciones con lapsos de una hora en un horizonte de 24 horas. Los tiempos de ejecución se resumen en la Fig. 13. En ella se observa que el promedio de tiempos de ejecución de MOGA son aproximadamente 4 veces menores en comparación a los tiempos de ejecución de SPEA2.




Fig. 13. Comparación de los tiempos promedio de ejecución de las técnicas SPEA2 y MOGA

IV. Conclusiones

El índice de costos indica una ventaja económica de SPEA2 sobre MOGA de 5,8 % en modo conectado de 4,6%, en el modo aislado. La técnica SPEA2 ofrece una reducción por concepto de emisiones, en comparación a la técnica MOGA. Para el modo conectado de 10,2% y para el modo aislado de 16,4%. La distribución de la energía muestra tanto en el modo aislado como en el modo conectado, como la técnica SPEA2 favorece una mayor participación de las tecnologías DER menos contaminantes, tales como las microturbinas y las celdas de combustible. El esquema de clasificación por no-dominancia, muestra cómo la técnica SPEA2 ofrece más soluciones no-dominadas que las estrategias MOGA. En términos absolutos resulta evidente que hay mayor dispersión o variabilidad entre cada



muestra de los conjuntos solución ofrecidos por las técnicas MOGA, en comparación con SPEA2; ya que el CV es mayor al CV de SPEA2.

En síntesis puede observarse que la capacidad de SPEA2 para ofrecer elitismo al proceso de reclasificación iterativa permite una mejor depuración de los individuos de bajo fitness, lo que al final se manifiesta en mejores conjuntos solución. No obstante, la técnica MOGA ofrece menores tiempos de ejecución que SPEA2, lo cual en una implementación donde el tiempo real sea una exigencia, dicha técnica MOGA podría tener una viabilidad mayor.

Resulta conveniente desarrollar nuevos estudios que permitan la comparación de otras técnicas de MO bajo los mismos parámetros del presente estudio. Incluso, llevar a cabo esos estudios con base en los criterios de desempeño aquí mostrados y otros nuevos que se propongan.

V. Referencias.

- [1] R. Zhang and Y. Du, "New challenges to power system planning and operation of smart grid development in China," *Power Syst. Technol.*, pp. 1–8, 2010.
- [2] K. Moslehi and R. Kumar, "A Reliability Perspective of the Smart Grid," *Smart Grid, IEEE Trans.*, vol. 1, no. 1, pp. 57–64, 2010.
- [3] M. Erol-Kantarci, B. Kantarci, and H. Mouftah, "Reliable overlay topology design for the smart microgrid network," *Network, IEEE*, vol. 25, no. October, pp. 38–43, 2011.
- [4] C. M. Colson and M. H. Nehrir, "A review of challenges to real-time power management of microgrids," 2009 IEEE Power Energy Soc. Gen. Meet., pp. 1–8, Jul. 2009.
- [5] M. Ding, Y. Zhang, M. Mao, W. Yang, and X. Liu, "Operation optimization for microgrids under centralized control," in *Power Electronics for Distributed Generation Systems (PEDG), 2010 2nd IEEE International Symposium on*, 2010, no. 2007, pp. 984–987.
- [6] C. M. Colson, M. H. Nehrir, and C. Wang, "Ant colony optimization for microgrid multi-objective power management," 2009 IEEE/PES Power Syst. Conf. Expo., pp. 1–7, Mar. 2009.
- [7] M. Faisal, "Microgrid modelling and online management," Helsinki University of Technology, 2008.
- [8] N. Bazmohammadi, "Optimal operation management of a microgrid based on MOPSO and Differential Evolution algorithms," in *Smart Grids (ICSG), ...*, 2012.
- [9] N. Pindoriya and S. Singh, "MOPSO based day-ahead optimal self-scheduling of generators under electricity price forecast uncertainty," *Power Energy Soc. Gen. ...*, pp. 1–8, 2009.
- [10] C. M. Colson, M. H. Nehrir, and S. A. Pourmousavi, "Towards real-time microgrid power management using computational intelligence methods," in *Power and Energy Society General Meeting, 2010 IEEE*, 2010, pp. 1–8.
- [11] G. D. M. Jannuzzi, O. de B. Rodríguez, J. Gorenstein, L. Goncalves, R. Dourado, and J. Navarro, "Energías Renovables para Generación de Electricidad en América Latina: mercado , tecnologías y perspectivas," 2010.
- [12] C. Carpio and M. F. Coviello, "Situación y perspectivas de la eficiencia energéticas en América Latina y El Caribe," Santiago de Chile, 2009.

[13] J. Guerrero and J. Vasquez, "Hierarchical control of droop-controlled AC and DC microgrids—a general approach toward standardization," *Ind. Electron. ...*, pp. 4305 – 4310, 2011.

[14] Y. Zhang, M. Mao, M. Ding, L. Chang, and S. Member, "Study of energy management system for distributed generation systems," in 2008 Third International Conference on Electric Utility Deregulation and Restructuring and Power Technologies, 2008, no. April, pp. 2465–2469.

[15] A. Rojas-González, O. Chaparro-Anaya, and C. Ospina, "Evaluación de mezclas biodiésel-diésel en la generación de energía eléctrica," *Ing. y Univ.*, vol. 15, no. 2, pp. 319–336, 2011.

[16] M. Pipattanasomporn, "Implications of on-site distributed generation for commercial/industrial facilities," *Power Syst. IEEE ...*, vol. 20, no. 1, pp. 206–212, 2005.

[17] M. A. Abido, "Environmental/economic power dispatch using multiobjective evolutionary algorithms: a comparative study," in 2003 IEEE Power Engineering Society General ..., 2003, pp. 920–925.

VI. Reseña Autores

Fabián Andrés Zúñiga Cardona: Ingeniero Electrónico de la Universidad del Valle, 2014. Sus áreas de interés son la inteligencia computacional y las smartgrids. Email: fabian.zuniga@correounivalle.edu.co.

Danny Mauricio López Santiago: Ingeniero electrónico de la Universidad del Valle, 2005. Obtuvo su título de magíster en ingeniería de sistemas y computación en 2013. Actualmente cursa estudios de doctorado en ingeniería eléctrica y electrónica en la misma universidad. Sus áreas de interés son la inteligencia computacional, la optimización y las smartgrids. Email: danny.lopez@correounivalle.edu.co.

Eduardo Francisco Caicedo Bravo: Ingeniero electricista de la Universidad del Valle, 1984. Obtuvo su título de magíster en tecnologías de la informática industrial en la Universidad Politécnica de Madrid en 1993, y su título de doctor en computación industrial en 1996 en la misma universidad. Sus áreas de interés son la inteligencia computacional y la robótica. Email: eduardo.caicedo@correounivalle.edu.co.

CIDET CERTIFICACIÓN

- Certificación de Productos •
- Inspección de Instalaciones •
- Sistemas de Gestión Especializados •



Sede Medellín
Carrera 46 56-11, piso 13 y 16 (Av. Oriental)
PBX: (574) 444 12 11
Correo electrónico: cidet@cidet.org.co

www.cidet.org.co