UNIVERSIDAD NACIONAL DE ASUNCIÓN

Facultad de Ingeniería
Ingeniería Electromecánica

Compensación de Potencia Reactiva en un contexto multiobjetivo mediante algoritmo de Colonia de Hormigas

Pedro Esteban Gardel Sotomayor

Campus Universitario - San Lorenzo, Paraguay

Mayo 2006

Este trabajo esta dedicado a mi madre, merced a su esfuerzo y amor he podido llevar a buen término las metas que me he propuesto al iniciar mis estudios en esta casa de enseñanza.

Agradecimientos:

Al profesor Benjamín Barán, excelente profesional y persona. Sin su invalorable apoyo y guía constante no hubiera podido concluir satisfactoriamente este proyecto. Su excepcional capacidad de superación frente a los problemas inyecta dinamismo al quehacer diario de las personas que tenemos el orgullo de formar parte de su grupo de investigación.

A la Lic. Blanca Troche de Trevisán, ex Directora del Centro Nacional de Computación, por haber hecho posible que en dicha institución puedan ser llevados a cabo trabajos de investigación de esta naturaleza. Al Lic. Jorge Cabañas, Director del Centro Nacional de Computación, por continuar la labor al frente de esta prestigiosa institución.

A los queridos compañeros del Centro Nacional de Computación, Ing. Diego Pinto, M. Sc. Osvaldo Gómez, Ing. José Fernandez, M. Sc. Rodrigo Ramos, M. S. E. Ubaldo Fernández, M. Sc. José Vallejos, Lic. Marcos Villagra, Lic. Ramón González, Ing. Maria Elena García e Ing. Jorge Crichigno. Deseo agradecerles especialmente por su constante apoyo y colaboración en las diferentes instancias del desarrollo del presente trabajo, así también por el excelente ambiente de trabajo del que me han permitido ser parte.

Finalmente una mención a mis profesores, compañeros y amigos de la facultad de ingeniería, con quienes he compartido estos años de formación

Índice General: ii

Índice de Tablas:---------- iv
Índice de Figuras---------- v

1 Conceptos Básicos e introducción al Flujo de Potencia Óptimo….. 1
1.1 Generación de Energía Eléctrica en el Paraguay…… 1
1.2 Estudio de Sistemas Eléctricos de Potencia. …… 2
1.3 Estructura funcional de los Sistemas Eléctricos de Potencia……. 4
1.4 Planificación y operación de los Sistemas Eléctricos de Potencia….. 5
1.5 Flujo de Potencia. ……... 7
1.5.1. Modelo matemático de la red. …… 8
1.5.2. Definición analítica del problema de Flujo de Potencia. …… 11
1.5.3. Métodos de solución. …… 13
1.6 Flujo de Potencia Óptimo. …… 14
1.6.1. Aplicaciones. …… 14
1.6.2. Formulación matemática. …… 15
1.7 Objetivos del trabajo. …… 19
1.8 Organización del trabajo. …… 20

2 Optimización con Múltiples Objetivos…….. 22
2.1 Principios básicos y terminologías…… 22
2.2 Búsqueda y toma de decisiones. …….. 29
2.2.1. El Método de Suma con Pesos. …… 32
2.2.2. El Método del Orden Lexicográfito. …… 35
2.2.3. Computación Evolutiva. …… 35
2.2.4. Optimización basada en Colonia de Hormigas. …… 39
2.3 Formulación Matemática del Problema de Compensación de Potencia Reactiva. …… 40
2.3.1. Minimización de la inversión en dispositivos de compensación de potencia reactiva. …… 43
2.3.2. Minimización de la desviación promedio de voltaje. …… 43
2.4 Formulación como problema multiobjetivo. …… 44

3 Métodos de Optimización aplicados a los Sistemas Eléctricos de Potencia…… 47
3.1 Métodos Analíticos. …… 48
3.2 Métodos de Programación Numérica. ……... 50
3.3 Métodos Heurísticos. …… 55
3.4 Métodos basados en Inteligencia Artificial. …… 56
3.4.1. Sistemas Expertos. ……... 57
3.4.2. Redes Neuronales. ……... 58
3.4.3. Teoría de Conjuntos Difusos. …….. 61
3.4.4. Templado Simulado. …… 63
3.4.5. Búsqueda Tabú. …… 64
3.4.6. Optimización por Colonia de Hormigas. …… 65
3.4.7. Optimización por Enjambre de Partículas. …… 66
3.4.8. Algoritmos Genéticos. …….. 67
3.4.9. Técnicas híbridas de Inteligencia Artificial. ……... 69

4 Aplicación del SPEA al Problema de Compensación de Potencia Reactiva…… 71
4.1 Algoritmos Genéticos…….. 71
4.1.1. Representación Cromosómica Allele. …… 72
4.1.2. Evaluación y adecuabilidad. ……..... 73
4.1.3. Ciclo de Trabajo. ……..…… 74
4.1.4. Inicialización……..…… 74
4.1.5. Selección. ……..…… 75
4.1.6. Cruzamiento. ……..…….. 75
4.1.7. Mutación. ……..…… 75
4.1.8. Condiciones de Término…….... 76
4.2 SPEA……..……..... 76
4.2.1. .Procedimiento para asignar fitness a los individuos. …….. 78
4.2.2. Reducción del conjunto Pareto-óptimo utilizando un proceso agrupador……..……. 80
4.2.3. Procedimiento ALM……..... 81
4.2.4. Generación heurística de la población inicial. …….. 82
4.2.5. Dos poblaciones externas. ……..... 83
4.2.6. Operadores genéticos. ……..... 84
4.2.7. Optimizador local. ……..…….. 85
4.2.8. Enfriado. ……..…….. 86
4.2.9. Verificación de factibilidad. ……..... 86
4.2.10. Criterio de Parada. ……..... 86
4.2.11. Resumen……..…….. 87

5 Colonia de Hormigas…….. 89
5.1 Comportamiento de búsqueda de alimentos de las hormigas reales.. 89
5.2 Optimización por Colonia de Hormigas…… 92
5.3 Enfoque típico de ACO…… 94
5.4 Ómicron ACO……..…. 97
5.5 Ómicron Eléctrico OE……..…… 99

6 Estudios Experimentales…… 115
6.1 Diseño de experimentos. ……..…… 115
6.2 Objetivo del experimento. ……..……. 116
6.3 Elección de métrica comparativa. ……..... 116
6.4 Diseño y ejecución de los experimentos. …… 118
6.4.1. Problema de referencia. ……..... 118
6.4.2. Plataforma computacional. ……..... 119
6.4.3. Metodología Experimental. ……..... 119
6.5 Resultados experimentales y análisis de datos……..... 122
6.6 Selección de una solución. ……..... 126

7 Conclusiones…… 130
7.1 Reporte de los experimentos. ……..... 130
7.2 Conclusiones finales. ……..... 131
7.3 Trabajos futuros. ……..……... 133

Apéndices: ……..... 134
A- Lista de Acrónimos. ……..…… 135
B- Lista de Símbolos. ……..…….. 137

Bibliografía……..…….. 142

Índice de Tablas:

3.1 Aplicación de técnicas híbridas de Inteligencia Artificial a los *EPSs*..…..… 70
5.1 Matriz de feromonas del ejemplo 5.1…….. 102
5.2 Asignación de probabilidades de visibilidad de la función η_1 para el ejemplo 5.2……... 106
5.3 Asignación de probabilidades de visibilidad de la función η_2 para el ejemplo 5.2……..... 107
5.4 Ejemplo de asignación de deseabilidad de la función compuesta η para la primera iteración de una generación,…..……. 108
5.5 Ejemplo de asignación de deseabilidad de la función compuesta η para una iteración intermedia de la generación…….....…… 108
5.6 Ejemplos de asignación deseabilidad de la función compuesta η para la última iteración de la generación ……..……. 109
5.7 Asignación de probabilidades Pr_{ij}, para la iteración inicial del ejemplo 5.3.. 112
5.8 Asignación de probabilidades Pr_{ij}, para la iteración final del ejemplo 5.3..... 113
6.1 Valores de *cobertura* del SPEA sobre el *OE* $\mathbb{C}$ (FP^{SPEA}, FP^{OE})…….. 122
6.2 Valores de *cobertura* del *OE* sobre el SPEA, $\mathbb{C}$ (FP^{OE} , FP^{SPEA})…….... 123
6.3 Soluciones halladas por el SPEA y el *OE* que consiguen un desvío promedio de 1% de tensión con la menor cantidad de compensación posible…….. 128

Índice de figuras:

1.1 Oferta y demanda de potencia eléctrica histórica y proyectada del Paraguay…… 3
1.2 Estructura funcional de los *EPSs*…… 4
2.1 Ejemplo de la optimalidad Pareto en el espacio objetivo…… 25
2.2 Valores de f_1 y f_2 en función de $x \in X_f = (-\infty, \infty)$ para el ejemplo 2.1…… 28
2.3 Frente Pareto del ejemplo 2.1…… 29
2.4 Componentes de un algoritmo general de búsqueda estocástica…… 36
2.5 Contorno de un algoritmo evolutivo general para un problema con variable de decisión de cuatro bits…… 38
2.6 Ejemplo de distribución de bancos *shunt* en un *EPS*…… 46
4.1 Diagrama de flujo del *SPEA* con las modificaciones hechas por Barán et al. …… 87
5.1 Comportamiento de las hormigas en la búsqueda de su alimento entre el nido y su fuente de alimentación…… 92
5.2 Visualización gráfica de la asignación de deseabilidad de la función η_1…… 106
5.3 Visualización gráfica de la asignación de deseabilidad de la función η_2…… 107
5.4 Visualización gráfica de la asignación de deseabilidad de la función compuesta η para tres iteraciones distintas…… 109
6.1 Cálculo de $\mathbb{C}(C_1, C_2)$ dados dos conjunto de soluciones, C_1 y C_2…… 117
6.2 Cálculo de $\mathbb{C}(C_2, C_1)$ dados dos conjunto de soluciones, C_2 y C_1…… 118
6.3 Sistema eléctrico de potencia estandarizado IEEE de 118 barras…… 121
6.4 Ómicron Eléctrico vs SPEA para el conjunto de 8 horas de corrida…… 124
6.5 Ómicron Eléctrico vs SPEA para el conjunto de 16 horas de corrida…… 125
6.6 Ómicron Eléctrico vs SPEA para todos los conjuntos de corridas…… 127

Capítulo 1

Conceptos básicos e introducción al Flujo de Potencia Óptimo.

Introducción.

La búsqueda de la optimización en la generación, transmisión y utilización de la energía debería ser uno de los paradigmas de toda nación para lograr un desarrollo tecnológico, económico e industrial sustentable que no degrade al medio ambiente. En el caso de Paraguay esta consigna es de mayor importancia aún debido a que los recursos hidroeléctricos constituyen una de las mayores riquezas del país. A consecuencia de esto, los sistemas de Generación, Transmisión y Distribución de Energía Eléctrica, también llamados Sistemas Eléctricos de Potencia (*EPSs* - *Electric Power Systems*), cumplen un rol fundamental en el desarrollo de la nación, constituyéndose en la base del sistema energético nacional e inclusive mundial.

1.1 Generación de Energía Eléctrica en el Paraguay.

El Paraguay es desde hace algún tiempo el país con mayor producción de energía eléctrica con relación a su capacidad de consumo. Cuenta con tres hidroeléctricas operativas: Itaipú, Yacyreta y Acaray. De estas, Itaipú es la de mayor generación de energía eléctrica en el mundo, superando cada año sus propios récords de producción. Itaipú cuenta actualmente con 18 unidades generadoras, cada una con una capacidad nominal de 700 MW (9 pertenecen al Paraguay y las otras 9 al Brasil). Su potencia disponible es de 6300 MW para

el Paraguay. Yacyreta cuenta con 20 generadores, cada uno con una capacidad nominal de 175 MW (10 de estos pertenecen al Paraguay y los otros 10 a la Argentina). Su potencia disponible es de 1750 MW para el Paraguay. Por último, Acaray cuenta con 4 generadores, cada uno con una capacidad nominal de 50 MW. La potencia disponible de 200 MW es del Paraguay al ser Acaray propiedad de la ANDE (Administración Nacional de Electricidad) [AND06]. Además existen los siguientes grupos de generación térmica:

- San Carlos (0,08 MW)
- Bahía Negra (0,28 MW)
- La Patria (0,28 MW)
- Mariscal. Estigarribia (1,36 MW)
- Pedro J. Caballero (2,8 MW)
- Sajonia (33,7 MW)

La gran cantidad de electricidad producida supera con mucho la demanda interna del país, véase figura 1.1 [AND06], con lo que su comercialización al exterior es una opción incuestionable para generar grandes ingresos económicos al país. Para esto es necesario operar de forma eficiente el sistema eléctrico paraguayo a fin de optimizar los beneficios posibles.

1.2 Estudio de Sistemas Eléctricos de Potencia

Un *EPS* es un conjunto integral de elementos que sirven para convertir y transportar energía eléctrica, desempeñando un papel importante en la búsqueda de medios eficientes de utilización de los recursos energéticos [STE88].

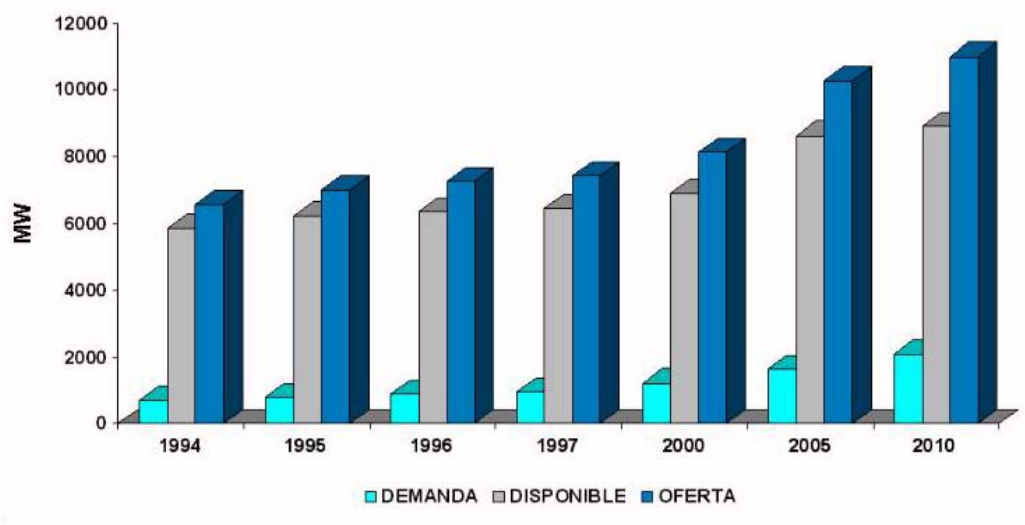

Figura 1.1 Oferta y demanda de potencia eléctrica histórica y proyectada del Paraguay.

En la actualidad, las técnicas de diseño, construcción y operación de los *EPSs* se enfrentan a grandes desafíos relacionados con el rápido crecimiento demográfico e industrial, así como con una legislación cada vez más rigurosa y factores económicos que restringen las posibilidades de expansión de los mismos [PIN01].

Un aspecto fundamental del diseño y operación de los *EPSs* es el problema de la Compensación de Potencia Reactiva (*RPC* - *Reactive Power Compensation*) [KUN93], que consiste básicamente en la determinación de una configuración del sistema que optimice los recursos disponibles para la inversión en dispositivos de compensación, aumentando al mismo tiempo la eficiencia del *EPS* y la confiabilidad del sistema.

Teniendo en cuenta esta situación, el presente trabajo de investigación plantea una nueva propuesta de resolución del RPC mediante la aplicación de nuevas técnicas computacionales, conocidas como Optimización por Colonia de Hormigas (ACO - *Ant Colony Optimización*).

1.3 Estructura funcional de los Sistemas Eléctricos de Potencia

Desde el punto de vista funcional, los *EPSs* presentan una estructura representada en la Figura 1.2 [FAL98] que muestra sus principales componentes [VAL02]:

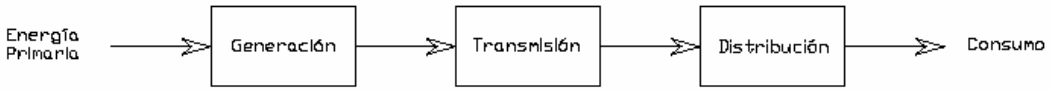

Figura 1.2 Estructura funcional de los EPSs.

*Generación***:** Compuesta por las usinas o centrales generadoras. Las centrales generadoras más utilizadas en la actualidad son del tipo hidroeléctrica y térmica *i.e.* a carbón, fuel oil, gas natural, etc. Las centrales hidroeléctricas, en general, están localizadas en puntos distantes a los centros de consumo, exigiendo sistemas de transmisión complejos y de tensión elevada. Las centrales térmicas generalmente están ubicadas cerca de lo centros de consumo, debido a su rápida puesta en marcha y tamaño de las instalaciones menor que en las hidroeléctricas; normalmente son utilizadas para suplir energía de punta. Otros tipos de centrales, pueden ser del tipo eólico, solar, mareomotriz, etc. y su descripción escapa a la finalidad de este trabajo.

*Transmisión***:** Compuesta por las líneas de transmisión y equipos auxiliares necesarios para transmitir la energía producida en los puntos de generación hasta los centros de consumo. Estas líneas pueden ser de corriente alterna (CA) o de corriente continua (CC), siendo estas últimas

utilizadas para la transmisión de grandes cantidades de energía a distancias elevadas.

Distribución: Compuesta por las subestaciones y alimentadores responsables de la distribución de la energía eléctrica a los consumidores industriales, comerciales y residenciales. Incluye los sistemas de media y baja tensión.

Surge la necesidad de realizar los correspondientes estudios de diseño, expansión y operación de los EPSs así descritos para lograr un adecuado desempeño de los mismos. En la siguiente sección se presentan resumidamente dichos estudios.

1.4 Planificación y operación de los Sistemas Eléctricos de Potencia

Las actividades de ingeniería de planificación y operación de los EPSs pueden ser clasificadas en tres categorías principales, diferenciadas según el horizonte de análisis considerado y la naturaleza de los estudios realizados [VAL02]:

*Planificación de la Expansión***:** Tiene como objetivo determinar, dentro de un horizonte de largo plazo (hasta 30 años), los nuevos elementos a ser incluidos en el sistema para atender un aumento previsto en la demanda de energía eléctrica.

*Planificación de la Operación***:** Tiene como objetivo establecer una estrategia de operación, incluyendo planes de emergencia, para un horizonte de mediano plazo (hasta algunos años). Normalmente se subdivide en:

1) planificación de la operación energética, donde se analiza la mejor estrategia para la utilización de recursos energéticos, por ejemplo: agua disponible y prevista en los reservorios de las represas hidroeléctricas versus uso de combustible en usinas térmicas;

2) la planificación de la operación eléctrica, donde se analiza el impacto de las decisiones energéticas en diversos factores tales como: las actividades del programa de mantenimiento, condiciones climáticas, etc., en el desempeño del *EPS* para garantizar un nivel adecuado de confiabilidad.

Operación en Tiempo-Real: Tiene como objetivo atender la demanda de energía instantánea del sistema, procurando minimizar los desvíos con respecto a las directivas de Planificación de Operación. Esto típicamente se realiza en centros de operación de sistemas que cuentan con sistemas de adquisición remota de datos (*SCADA Supervisory Control and Data Acquisition*) y sistemas computacionales capaces de ofrecer a los operadores condiciones adecuadas para la toma de decisiones y acciones de control.

En cada una de estas instancias es de esencial importancia el contar con herramientas de análisis adecuadas a fin de determinar las condiciones de

operación de todos los puntos del *EPS* conocidos algunos parámetros del mismo, como ser las características topológicas y eléctricas de la red así como la distribución de las cargas y dispositivos de compensación entre otros. La herramienta que resuelve dicho problema es conocida como Flujo de Potencia (*LF - Load flow*)

1.5 Flujo de Potencia.

Bajo condiciones normales de funcionamiento, los sistemas eléctricos de transmisión, operan en estado estable y el cálculo básico que se requiere para determinar las características de este estado es llamado flujo de potencia [SCH95]. El objetivo del flujo de potencia es determinar las características de estado estable de operación del sistema de generación y transmisión de potencia, para un determinado conjunto de cargas en las barras [ARR83]. La solución provee información de módulo y fase de las tensiones, flujo de potencia activa y reactiva en las líneas de transmisión, pérdidas y la potencia reactiva generada o absorbida en las barras controladoras de tensión [SCH95].

El problema del flujo de potencia puede ser formulado analíticamente con la red representada por parámetros lineales y concentrados. Sin embargo, las restricciones de potencia y tensión hacen al problema no lineal. Por consiguiente, se recurre a métodos numéricos de naturaleza iterativa para su solución.

1.5.1 Modelo matemático de la red

El primer paso en cualquier análisis de un sistema de energía eléctrica debe ser la formulación de un modelo adecuado para la red. Tal modelo debe relacionar las tensiones de la red con las corrientes o potencias de la misma.

Existe, de hecho, abundante bibliografía sobre formulación de redes. Véase en [STE88] dos formas de representar las mismas: ecuaciones de nudos y ecuaciones de lazos.

En el método de los nudos [ARR83], las variables son las tensiones complejas (módulo y fase) en los nudos y las corrientes. Deben ser designados valores de referencia para los módulos y fases de las tensiones. Generalmente para los módulos la referencia es la tierra; mientras que para las fases se tomo como referencia la de uno de los nudos o barras, asignándole el valor cero.

En la figura 2.1 se puede observar una red sencilla mostrando las corrientes nodales, tensiones y potencias.

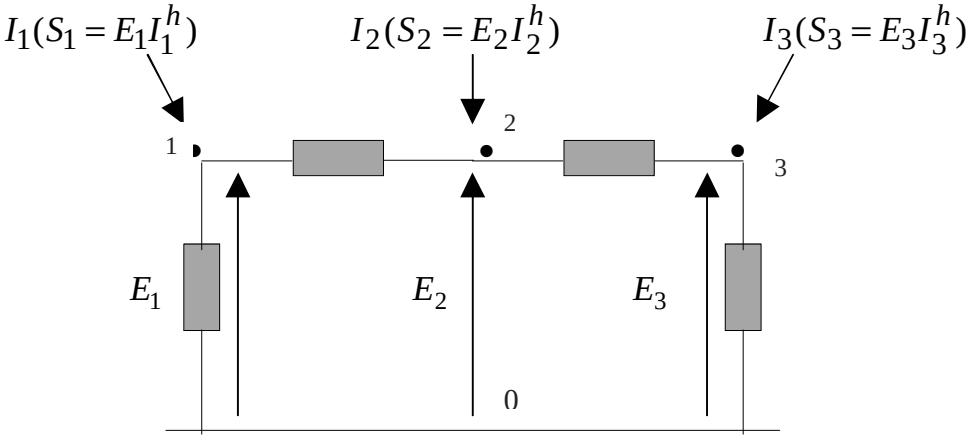

Figura 2.1 Red sencilla mostrando variables nodales

Una corriente nodal es aquélla que entra a la red por un determinado nudo, proveniente de una fuente y/o de una carga externa a la red. A partir de esta definición, la corriente que entra a la red (desde una fuente) se considera que

es positiva, mientras que la que sale de la red (hacia una carga) tiene signo negativo, y la corriente nodal inyectada neta es la suma algebraica de las dos. Asimismo, se puede hablar de una potencia nodal inyectada

$$S_k = P_k + \boldsymbol{j}Q_k. \tag{1.1}$$

donde: S_k es las potencia aparente neta en la barra *k.*

P_k es las potencia activa neta en la barra *k.*

Q_k es la potencia reactiva neta en la barra *k*.

j es la unidad imaginaria $\sqrt{-1}$.

En el método de los nudos, es conveniente usar admitancias de rama en lugar de impedancias. Designando a las tensiones de los nudos *k* y *m* como E_k y E_m respectivamente, y a las admitancias de la rama entre ellos como y_{km}, se tiene que la corriente que fluye en esta rama desde el nudo *k* hacia el nudo *m*, está dada por:

$$I_{km} = y_{km}(E_k - E_m) \tag{1.2}$$

Se enumeran 0, 1...n los nudos de la red, donde 0 designa el nudo de referencia para los módulos de tensión (tierra). Según la ley de corrientes de Kirchhoff, la corriente I_k inyectada en el nudo *k*, debe ser igual a la suma de las corrientes que salen del mismo, por consiguiente:

$$I_k = \sum_{m=0\neq k}^{n} I_{km} = \sum_{m=0\neq k}^{n} y_{km}(E_k - E_m) \tag{1.3}$$

Habiéndose elegido $E_0 = 0$, y si el sistema es lineal:

$$I_k = \sum_{m=0\neq k}^{n} y_{km}E_k - \sum_{m=1\neq k}^{n} y_{km}E_m \tag{1.4}$$

Si esta ecuación se escribe para todos los nudos, excepto para el de referencia, es decir, para todas las barras en el caso de un sistema de potencia, entonces el conjunto completo de ecuaciones que definen la red se puede expresar en forma matricial como:

$$\begin{bmatrix} I_1 \\ I_2 \\ \vdots \\ I_n \end{bmatrix} = \begin{bmatrix} Y_{11} & Y_{12} & \cdots & Y_{1n} \\ Y_{21} & Y_{22} & \cdots & Y_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ Y_{n1} & Y_{n2} & \cdots & Y_{nn} \end{bmatrix} \cdot \begin{bmatrix} E_1 \\ E_2 \\ \vdots \\ E_n \end{bmatrix} \tag{1.5}$$

donde

$$Y_{kk} = \sum_{m=0 \neq k}^{n} y_{km} = \text{ admitancia propia del nudo } k$$

$$Y_{km} = -y_{km} = \text{ admitancia mutua entre los nudos } k \text{ y } m$$

Podemos escribir la ecuación (1.5) en forma vectorial como:

$$I_k = \sum_{m=1}^{N} Y_{km} E_m \quad \forall k \in \{1, \ldots, n\} \tag{1.6}$$

La potencia que entra en una barra está dada por [STE88]:

$$S_k = P_k + jQ_k = E_k I_k^h = E_k \sum_{m=1}^{n} Y_{km}^h E_m^h \tag{1.7}$$

donde: I_k^h = Complejo conjugado de I_k

Y_k^h = Complejo conjugado de Y_k

E_k^h = Complejo conjugado de E_k

Desarrollando la ecuación (1.7) en coordenadas polares y separando las partes real e imaginaria tendremos:

$$P_k = \sum_{m=1}^{N} V_k V_m (G_{km} \cos \theta_{km} + \sigma_{km} sen\ \theta_{km}) \quad (1.8)$$

$$Q_k = \sum_{m=1}^{N} V_k V_m (G_{km}\ sen\ \theta_{km} - \sigma_{km} \cos \theta_{km}) \quad (1.9)$$

donde

V_k módulo de la tensión E_k

θ_k fase de la tensión E_k

$\theta_{km} = \theta_k - \theta_m$, diferencia de fase entre nodos *k* y *m*.

G_{km} = conductancia entre las barras *k* y *m*

σ_{km} = susceptancia entre las barras *k* y *m*

$Y_{km} = G_{km} + j\sigma_{km}$

Con estos conceptos básicos en mente se puede dar una definición analítica al problema del flujo de potencia [SCH95].

1.5.2 Definición analítica del problema del Flujo de Potencia

La completa definición del flujo de carga o flujo de potencia requiere el conocimiento de cuatro variables en cada barra *k* del sistema [ARR83]:

P_k potencia activa

Q_k potencia reactiva

V_k módulo de la tensión E_k

θ_k fase de la tensión E_k

Solo son conocidas *a priori* dos variables en cada barra, y la finalidad del estudio del flujo de carga es resolver las ecuaciones para las dos variables restantes en cada barra.

Se define a continuación una clasificación de las barras en base al tipo de especificación de las mismas, es decir, cuales variables son conocidas de antemano:

Barra PV o de tensión controlada. La potencia activa total inyectada P_k es especificada, y la magnitud de la tensión es mantenida a un valor determinado mediante la inyección de potencia reactiva. Este tipo de barra generalmente corresponde a un generador, donde P_k es fijada por los reguladores de caudal turbinado, y V_k es fijada por los reguladores automáticos de tensión actuando en la excitación de la máquina; o bien a una barra donde la magnitud de la tensión es fijada por inyección de potencia reactiva mediante capacitores estáticos o compensadores rotativos síncronos, por ejemplo, una sub-estación.

Barra PQ o de tensión no controlada. La potencia total inyectada, $P_k + \boldsymbol{j}\, Q_k$, es especificada en esta barra. En un sistema de potencia corresponde a un centro de consumo de carga, como una ciudad o una industria, donde la potencia demandada está determinada por los requerimientos de los consumidores. Tanto P_k como Q_k se suponen invariables con pequeñas alteraciones de la tensión en la barra.

Barra Slack o barra oscilante. Es necesaria para el estudio del flujo de cargas, a raíz de que las pérdidas en el sistema son desconocidas de antemano. Por consiguiente, la potencia inyectada no puede ser especificada en todas las barras. Es usual elegir una de las barras PV disponibles como *slack*, y considerar su potencia activa como desconocida. A la fase de la

barra *slack* usualmente se la designa como de referencia del sistema. En la práctica, corresponde a una estación generadora que tiene la responsabilidad de controlar la frecuencia de la red.

1.5.3 Métodos de solución

La complejidad que presenta la obtención de una solución formal del problema de las cargas en una red de energía, radica en las diferencias en el tipo de datos especificados para las distintas barras del sistema. Aunque no es difícil la formulación del número suficiente de ecuaciones, no es práctico obtener una solución analítica. La resolución de los problemas de carga por métodos numéricos sigue un proceso iterativo, asignando valores estimados en las barras a las tensiones desconocidas, y recalculando las tensiones en cada una de las barras a partir de los valores estimados en las otras y de las potencias real y reactiva [SCH95].

De esta manera, se obtiene un nuevo conjunto de tensiones en las barras, que se emplea para calcular otro, y así sucesivamente; cada cálculo de un nuevo conjunto de tensiones se llama iteración. El proceso iterativo se repite hasta que los cambios en cada barra sean menores que un valor mínimo especificado [STE88].

Existen varios métodos iterativos que pueden ser aplicados a la resolución del flujo de potencia, entre los cuales se puede citar:

- Método Gauss-Seidel
- Método de Newton-Raphson
- Métodos desacoplados derivados del método de Newton-Raphson

El desarrollo acabado de cada método de solución del *flujo de potencia* escapa al alcance del presente trabajo habiendo abundante bibliografía sobre el tema [STE88].

1.6 Flujo de Potencia Óptimo

El Flujo de Potencia Óptimo (*OPF - Optimal Power Flow*) tiene como objetivo la optimización de la condición estática de operación de un *EPS*. Se usa el término optimización en el sentido de maximizar o minimizar un determinado objetivo, sujeto a algunas restricciones [STE88].

En comparación con el Flujo de Potencia, el *OPF* es una herramienta de síntesis mientras que el *LF* se utiliza en el análisis [FAL98]. Como ya se ha explicado el flujo de potencia es la herramienta que da la solución de la red eléctrica para una determinada condición de operación, mientras que con el *OPF* se escoge, entre las infinitas condiciones de operación posibles para atender la demanda, una que optimice el objetivo seleccionado, siendo algunos de ellos: desvío mínimo del punto de operación, minimización de pérdidas de energía y mínimo corte de carga.

1.6.1 Aplicaciones

El *OPF* tiene aplicación en varios problemas de planificación de expansión, operación y operación en tiempo-real, tales como [STE88]:

- Despacho económico y seguro (operación en tiempo-real, simulación del despacho en estudios de planificación de expansión);
- Redespacho preventivo y correctivo (operación en tiempo-real);

- Minimización de pérdidas;
- Ubicación de fuentes de potencia reactiva (planificación de expansión del soporte de reactivos);
- Evaluación de la confiabilidad de sistemas compuestos de generación-transmisión;
- Planificación de la expansión de sistemas de transmisión;
- Tarifación de servicios de transmisión.

1.6.2 Formulación matemática

La naturaleza del problema *OPF* se basa en que la demanda es, en general, considerada conocida y constante. La mejor manera de atender esa demanda se obtiene al resolver el problema de *OPF*.

El *OPF* es formulado como un problema de Programación No-Lineal, de acuerdo con el siguiente formato patrón:

$$\text{minimizar } f(\mathbf{x}) \tag{1.10}$$

$$\text{sujeto a: } e(\mathbf{x}) \leq 0 \tag{1.11}$$

donde:

$x \in \Re^n$ es la variable de control o independiente;

$f : \Re^n \rightarrow \Re$ s la función objetivo;

$e : \Re^n \rightarrow \Re^m$ son las restricciones de desigualdad;

A continuación se da una definición detallada de las variables dependientes, variables independientes o de control, restricciones y funciones objetivo típicas de un problema *OPF*.

Variables dependientes: Las variables dependientes o de estado son un conjunto mínimo de variables capaces de caracterizar completamente al estado de operación de la red. Corresponden a las variables que definen analíticamente al flujo de potencia en un estado dado de la red, véase la sección 1.5.2.

Variables independientes: Las variables independientes o de control (**x**) son las variables que llevan al proceso de *OPF* a una solución óptima. Físicamente, corresponden a dispositivos o procesos de control presentes en la red eléctrica. Las variables normalmente utilizadas son [VAL02]:

- Flujo de Potencia Activa:
  - potencia activa generada;
  - ángulo de fase de transformadores desfasadores;
  - potencia transmitida en los alimentadores DC;
  - flujo de intercambio entre áreas (subestaciones).

- Flujo de Potencia Reactiva:
  - módulo de la tensión en barras de generación;
  - potencia reactiva generada o ubicada;
  - posición de los *tap* (derivaciones del bobinado) de transformadores;
  - susceptancia *shunt* (en derivación) de bancos de reactores (capacitores o inductores).

En el caso de una barra de generación, la variable de control asociada al flujo de potencia reactiva puede ser tanto el módulo de la tensión como la inyección de potencia reactiva. La selección de uno u otro depende del dispositivo de control presente en la barra y del método de solución adoptado. Algunas variables de control solamente pueden asumir valores discretos, como los *taps* de transformadores, susceptancias *shunt* de bancos de reactores, etc.

Cuando la variable de control utilizada en el *OPF* son las susceptancias *shunt* de bancos de reactores, el problema se conoce como *RPC* (Reactive Power Compensation) en *EPSs*.

Restricciones de igualdad: La solución del *OPF* corresponde a una solución del flujo de potencia. Es decir, debe satisfacer las ecuaciones que gobiernan el flujo de potencia ecuación 1.7 o las 1.8 y 1.9.

Restricciones de desigualdad: Son inecuaciones que representan límites físicos relacionados con la capacidad térmica de transmisión de potencia de los componentes de la red o límites operacionales relacionados con aspectos de seguridad de operación del sistema de potencia. Las variables generalmente asociadas a esos límites, agrupadas de acuerdo a su mayor influencia en el flujo de potencia activa o reactiva, son listadas a continuación:

- - Potencia activa generada;
  - ángulo de fase de transformadores desfasadores;
  - potencia transmitida en los alimentadores DC;
  - flujo de intercambio entre áreas (subestaciones).

- Flujo de Potencia Reactiva:
  - módulo de la tensión en barras de generación;
  - potencia reactiva generada o ubicada;
  - posición de los *tap* de transformadores;
  - susceptancia *shunt* de reactores.

Funciones objetivo: Se conocen como funciones objetivo a las características de los EPSs que se desean mejorar. Entre otras, estas características pueden ser:

- *Pérdidas Mínimas*: esta función puede ser representada como la inyección de potencia activa en la barra *slack*, o como la sumatoria de las pérdidas activas de todas las ramas de la red. Esta función representa las pérdidas por efecto *Joule* que tienen las líneas de transmisión y distribución de energía eléctrica.

- *Mínimo coste* de ubicación de fuentes de reactivos: Función objetivo utilizada para la planificación de la instalación de nuevas fuentes de potencia reactiva. El objetivo del problema es determinar la capacidad y lugar de ubicación de nuevas fuentes que cumplan con las restricciones de tensión del sistema con un mínimo costo.

- *Mínimo Corte de Carga*: Esta función objetivo se utiliza para resolver situaciones de emergencia en las cuales el corte de suministro de energía a una parte de la carga es la única solución posible para aliviar sobrecargas y evitar tensiones fuera del límite. Sin embargo el corte de carga debe ser mínimo y ponderado por la importancia de las cargas.

- *Desvío Mínimo del Punto de Operación*: Función que tiene por objetivo obtener una solución lo más próxima posible a un punto de operación previamente establecido por otro estudio como ser el de optimización energética.

- *Desvío Promedio del Punto de Operación*: Función que tiene por objetivo obtener una solución donde cada uno de los parámetros esté lo más próximo posible al punto de operación previamente establecido.

1.7 Objetivos del trabajo

El presente trabajo tiene como principal objetivo el abordar desde una nueva perspectiva el Problema de Compensación de Potencia Reactiva *RPC*, un problema tradicional en el estudio de los Sistemas Eléctricos de Potencia. EL *RPC* puede considerarse un sub-problema del *OPF*.

Se desarrolló una herramienta computacional consistente en la aplicación de un nuevo paradigma de computación, conocido como Optimización por Colonia de Hormigas (ACO - *Ant Colony Optimization*) [DOR96], al problema de Compensación de Potencia Reactiva, en un contexto multiobjetivo. El

método desarrollado, denominado *Ómicron Eléctrico* (*OE*), ofrece al ingeniero encargado de tomar decisiones en el *EPS* una gran variedad de posibles soluciones al problema antes de determinar cual solución será la utilizada finalmente.

Para validar los resultados presentados en este trabajo se comparó el desempeño del algoritmo propuesto, OE, con los obtenidos por el algoritmo presentado por Barán et. al. [BAR01a], [BAR01b], [BAR01c] y por el ingeniero José Vallejos en su Proyecto Final de Grado, PFG. El algoritmo propuesto por Barán et al. es una variación del *SPEA* (*Strength Pareto Evolutionary Algorithm*) [ZIZ99]. El *SPEA* ha sido elegido como algoritmo de prueba del OE por ser este el de mejor desempeño para el problema [BAR01a], [BAR01a] y [BAR01c].

1.8 Organización del trabajo

En el Capítulo 1 se da una introducción general acerca de los Sistemas Eléctricos de Potencia, el problema del flujo de potencia, los estudios relacionados con los mismos y a manera de introducción general, el Flujo Óptimo de Potencia.

En el Capítulo 2 se define formalmente la optimización multiobjetivo y se da la formulación matemática del Problema de la Compensación de Potencia Reactiva en EPSs, así como las consideraciones hechas en el presente trabajo para su resolución.

Un panorama general sobre el estado del arte de las técnicas computacionales aplicadas a los *EPSs*, especialmente a la resolución del *RPC*,

se expone en el capítulo 3. En el mismo capítulo se hace especial énfasis en las aplicaciones de Inteligencia Artificial (*AI - Artificial Intelligence*) a los *EPSs*

En el capítulo 4 se hace una descripción más extensa de los algoritmos genéticos así como de la aplicación del *SPEA* hecha por Barán et. al. para resolver el *RPC.*

El método propuesto por este trabajo, así como las adaptaciones necesarias para resolver el *RPC*, son presentados en el capítulo 5.

En el capítulo 6 se presentan los resultados experimentales de la comparación del método aquí propuesto, *OE*, con el *SPEA.* Dichos resultados experimentales muestran el mejor desempeño del *OE* en las condiciones consideradas en el presente estudio.

Finalmente, en el capítulo 7 se presentan las conclusiones del trabajo realizado así como las sugerencias para los posibles trabajos futuros relacionados con el tema.

Capítulo 2

Optimización con Múltiples Objetivos

Introducción.

El problema de compensación de potencia reactiva es considerado en este trabajo como un Problema de Optimización Multiobjetivo (*MOP- Muli-Objective Problem*) con las siguientes funciones objetivos a optimizar:

1- Inversión en bancos de compensación de potencia reactiva

2- Desviación promedio de tensión.

De manera a abordar el *MOP.* a continuación se presenta la definición general de un problema multiobjetivo. Posteriormente se formula matemáticamente el problema de Compensación de Potencia Reactiva como un *MOP*.

2.1 Principios básicos y terminologías

A continuación se da la definición formal de un *MOP* adoptada en este trabajo [VAN99] y [ZIT99].

Definición 1: *Problema de Optimización Multiobjetivo (Multiobjective Optimization Problem: MOP).* Un *MOP* general incluye un conjunto de ***n*** parámetros (variables de decisión), un conjunto de ***k*** funciones objetivo, y un conjunto de ***m*** restricciones. Las funciones objetivo y las restricciones son funciones de las variables de decisión. Luego, el MOP puede expresarse como:

$$\begin{aligned} &\textit{Optimizar} && \boldsymbol{y} = f(\boldsymbol{x}) = (f_1(\boldsymbol{x}), f_2(\boldsymbol{x}), \ldots , f_k(\boldsymbol{x})) \\ &\textit{sujeto a} && e(\boldsymbol{x}) = (e_1(\boldsymbol{x}), e_2(\boldsymbol{x}), \ldots , e_m(\boldsymbol{x})) \geq 0 \\ &\textit{donde} && \boldsymbol{x} = (x_1, x_2, \ldots , x_n) \in \boldsymbol{X} \\ & && \boldsymbol{y} = (y_1, y_2, \ldots , y_k) \in \boldsymbol{Y} \end{aligned} \tag{2.1}$$

siendo $\boldsymbol{x}$ el vector de decisión e $\boldsymbol{y}$ el vector objetivo. El espacio de decisión se denota por $\boldsymbol{X}$, y el espacio objetivo por $\boldsymbol{Y}$. Optimizar, dependiendo del problema, puede significar igualmente, minimizar o maximizar. El conjunto de restricciones $e(\boldsymbol{x}) \geq 0$ determina el conjunto de soluciones factibles $\boldsymbol{X}_f$ y su correspondiente conjunto de vectores objetivo factibles $\boldsymbol{Y}_f$.

Definición 2: *Conjunto de soluciones factibles***.** El conjunto de soluciones factibles $\boldsymbol{X}_f$ se define como el conjunto de vectores de decisión $\boldsymbol{x}$ que satisface $\boldsymbol{e(x)} \geq \boldsymbol{0}$**:**

$$\boldsymbol{X}_f = \{\boldsymbol{x} \in \boldsymbol{X} \mid e(\boldsymbol{x}) \geq \boldsymbol{0}\} \tag{2.2}$$

La imagen de $\boldsymbol{X}_f$, es decir, la región factible del espacio objetivo, se denota por

$$\boldsymbol{Y}_f = f(\boldsymbol{X}_f) = \{\boldsymbol{y} = f(\boldsymbol{x}) \mid \forall x \in X_f\} \tag{2.3}$$

De estas definiciones se tiene que cada solución del MOP en cuestión consiste de una **n**-tupla $\boldsymbol{x} = (x_1, x_2, \ldots, x_n)$, que conduce a, o determina, un vector objetivo $\boldsymbol{y} = (f_1(\boldsymbol{x}), f_2(\boldsymbol{x}), \ldots, f_k(\boldsymbol{x}))$, donde cada $\boldsymbol{x}$ debe cumplir con el conjunto de restricciones $\boldsymbol{e}(\boldsymbol{x}) \geq 0$. El problema de optimización mono-objetivo consiste en hallar la solución $\boldsymbol{x}$ que tenga el "mejor valor" de $f(\boldsymbol{x})$, pero en un contexto multiobjetivo no existe un único mejor valor, sino un conjunto de "mejores soluciones". Entre éstas, ninguna solución se puede considerar mejor que las demás si se tienen en cuenta todos los objetivos simultáneamente. De

este hecho se deriva que pueden existir –y generalmente existen– conflictos entre los diferentes objetivos que componen al problema, *i.e.*, la optimización de algún objetivo implica la degradación de algún otro objetivo. Por ende, al tratar con *MOPs* se precisa de un nuevo concepto de "óptimo".

En la optimización de un solo objetivo el conjunto de variables de decisión factibles está completamente ordenado mediante una función objetivo *f*. Es decir, dadas dos soluciones $\boldsymbol{u}, \boldsymbol{v} \in \boldsymbol{X}_f$, se cumple una sola de las siguientes proposiciones: $f(\boldsymbol{u}) > f(\boldsymbol{v})$, $f(\boldsymbol{u}) = f(\boldsymbol{v})$ o $f(\boldsymbol{v}) > f(\boldsymbol{u})$. El objetivo de la optimización consiste en hallar la solución (o soluciones) que tengan los valores óptimos (máximos o mínimos) de $f(x)$. Cuando se trata de varios objetivos, sin embargo, la situación cambia. $\boldsymbol{X}_f$, en general, no está totalmente ordenada por los objetivos. El orden que se da generalmente es parcial (*i.e.* pueden existir dos vectores de decisión diferentes $\boldsymbol{u}$ y $\boldsymbol{v}$ tal que $f(\boldsymbol{u})$ no puede considerarse mejor que $f(\boldsymbol{v})$ ni $f(\boldsymbol{v})$ puede considerarse mejor que $f(\boldsymbol{u})$).

Para ilustrar este concepto se presenta el gráfico de la figura 2.1 que muestra la relación entre dos funciones f_1 y f_2. La función f_1 representa el costo de los dispositivos de seguridad de un sistema, mientras que f_2 representa el índice de ocurrencia de accidentes. Nótese que es un problema de minimización, pues se desea que ambos objetivos disminuyan su valor simultáneamente, de ser posible.

La solución representada por el punto **B** es mejor que la representada por el punto **C**, debido a que provee de una mayor seguridad a un costo menor. La solución **B** sería también la escogida en el caso de estar realizando la optimización de un solo objetivo. Más aún, todas las soluciones que se

encuentran en el rectángulo delimitado por el origen de coordenadas y la solución **C** y por encima de la curva, son mejores a **C**. En la comparación entre **C** y **A,** se obtiene que, disminuyendo mucho los costos, el nivel de seguridad provisto por A es solo ligeramente peor, aunque **C** y **A** son no comparables entre ellos porque no se podría argumentar que uno es mejor que otro al considerar todos los objetivos. Si comparamos a la solución **A** con la **B** tampoco podríamos establecer que alguna de las dos sea mejor, si se considera que ambos objetivos son igualmente importantes y no se introduce alguna consideración de índole subjetiva. Sin embargo, **B** es claramente superior a **C** en ambos objetivos.

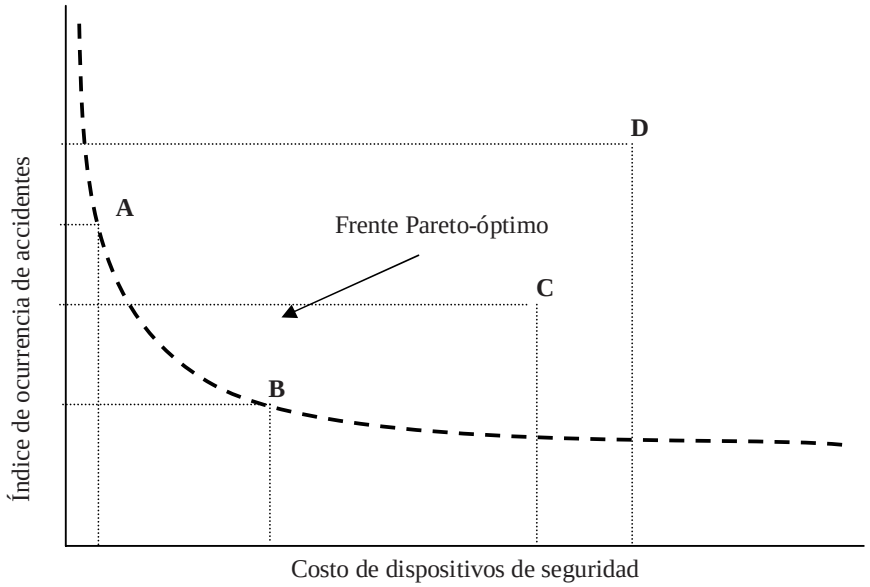

Figura 2.1. Ejemplo de la optimalidad Pareto en el espacio objetivo.

Para expresar esta situación matemáticamente, las relaciones =, ≤ y ≥ se deben extender. Esto se puede realizar de la siguiente manera:

Definición 3: *Extensión de las relaciones =, ≤ y ≥ a MOPs*. Dados 2 vectores de decisión $\boldsymbol{u}, \boldsymbol{v} \in \boldsymbol{X}$,

$$\begin{aligned} f(\boldsymbol{u}) = f(\boldsymbol{v}) \quad & \text{si y solo si} \quad f_i(\boldsymbol{u}) = f_i(\boldsymbol{v}) \quad \forall i \in \{1, 2, \dots, \boldsymbol{k}\} \\ f(\boldsymbol{u}) \leq f(\boldsymbol{v}) \quad & \text{si y solo si} \quad f_i(\boldsymbol{u}) \leq f_i(\boldsymbol{v}) \quad \forall i \in \{1, 2, \dots, \boldsymbol{k}\} \\ f(\boldsymbol{u}) < f(\boldsymbol{v}) \quad & \text{si y solo si} \quad f(\boldsymbol{u}) \leq f(\boldsymbol{v}) \wedge f(\boldsymbol{u}) \neq f(\boldsymbol{v}) \end{aligned} \tag{2.4}$$

Las relaciones ≥ y > se definen de manera similar utilizando ≤ y < en vez de ≥ y >

Definición 4: *Dominancia Pareto en un contexto de minimización***.** Para dos vectores de decisión $\boldsymbol{u}$ y $\boldsymbol{v} \in \boldsymbol{X}$,

$$\begin{aligned} \boldsymbol{u} \succ \boldsymbol{v} \ (\boldsymbol{u} \text{ domina a } \boldsymbol{v}) \quad & \text{si y solo si} \quad f(\boldsymbol{u}) < f(\boldsymbol{v}) \\ \boldsymbol{v} \succ \boldsymbol{u} \ (\boldsymbol{v} \text{ domina a } \boldsymbol{u}) \quad & \text{si y solo si} \quad f(\boldsymbol{v}) < f(\boldsymbol{u}) \\ \boldsymbol{u} \sim \boldsymbol{v} \ (\boldsymbol{u} \text{ y } \boldsymbol{v} \text{ no son comparables}) \quad & \text{si y solo si} \quad f(\boldsymbol{u}) \not< f(\boldsymbol{v}) \wedge f(\boldsymbol{v}) \not< f(\boldsymbol{u}) \end{aligned} \tag{2.5}$$

Definición 5: *Dominancia Pareto en un contexto de maximización***.** Para dos vectores de decisión $\boldsymbol{u}$ y $\boldsymbol{v} \in \boldsymbol{X}$,

$$\begin{aligned} \boldsymbol{u} \succ \boldsymbol{v} \ (\boldsymbol{u} \text{ domina a } \boldsymbol{v}) \quad & \text{si y solo si} \quad f(\boldsymbol{u}) > f(\boldsymbol{v}) \\ \boldsymbol{v} \succ \boldsymbol{u} \ (\boldsymbol{v} \text{ domina a } \boldsymbol{u}) \quad & \text{si y solo si} \quad f(\boldsymbol{v}) > f(\boldsymbol{u}) \\ \boldsymbol{u} \sim \boldsymbol{v} \ (\boldsymbol{u} \text{ y } \boldsymbol{v} \text{ no son comparables}) \quad & \text{si y solo si} \quad f(\boldsymbol{u}) \not> f(\boldsymbol{v}) \wedge f(\boldsymbol{v}) \not> f(\boldsymbol{u}) \end{aligned} \tag{2.6}$$

Nótese que una solución $\boldsymbol{v}$ domina a otra $\boldsymbol{u}$ en un contexto multiobjetivo solamente si $\boldsymbol{v}$ es mejor o a lo sumo igual en todos los objetivos considerados y es estrictamente mejor en al menos un objetivo.

Alternativamente, $\boldsymbol{u} \rhd \boldsymbol{v}$ denota que $\boldsymbol{u}$ domina o es no comparable con $\boldsymbol{v}$.

Luego, de aquí en adelante, ya no será necesario diferenciar el tipo de optimización a realizar (minimización o maximización), al punto que un objetivo puede ser maximizado, mientras que otro puede ser minimizado.

Definido el concepto de dominancia Pareto, puede ser introducido el criterio de optimalidad Pareto de la siguiente manera:

Definición 6: *Optimalidad Pareto***.** Dado un vector de decisión $\boldsymbol{x} \in \boldsymbol{X}_f$, se dice que $\boldsymbol{x}$ es no dominado respecto a un conjunto $\boldsymbol{Q} \subseteq \boldsymbol{X}_f$ si y solo si

$$\forall\ \boldsymbol{v} \in \boldsymbol{Q} : (\boldsymbol{x} \rhd \boldsymbol{v}) \qquad (2.7)$$

En caso que $\boldsymbol{x}$ sea no dominado respecto a todo el conjunto $\boldsymbol{X}_f$, y solo en ese caso, se dice que $\boldsymbol{x}$ es una solución Pareto-óptima. Por lo tanto, el conjunto Pareto-óptimo CP_{true} puede ser definido formalmente a continuación.

Definición 7: *Conjunto Pareto-óptimo* CP_{true}**.** Dado el conjunto de vectores de decisión factibles $\boldsymbol{X}_f$, se denomina conjunto Pareto-óptimo CP_{true} al conjunto de vectores de decisión no dominados que pertenecen a $\boldsymbol{X}_f$, es decir:

$$CP_{true} = \{\ \boldsymbol{x} \in \boldsymbol{X}_f \mid \boldsymbol{x} \text{ es no dominado con respecto a } \boldsymbol{X}_f\ \} \qquad (2.8)$$

El correspondiente conjunto de vectores objetivos $FP_{true} = f(CP_{true})$ constituye el frente Pareto-óptimo**.**

Para ilustrar los conceptos recién presentados, se discutirá a continuación un problema multiobjetivo específico, usado anteriormente para idénticos propósitos en [SHA84]. Este *MOP.*, que denominaremos como ejemplo 2.1,

cuenta con una sola variable de decisión (***n*** = 1), dos funciones objetivo (***k*** = 2) y sin restricciones (***m*** = 0), dicho problema puede ser definido como:

$$\begin{aligned} &\text{Minimizar:} && f(x) = (f_1(x), f_2(x)), \\ &\text{donde} && f_1(x) = x^2, \\ & && f_2(x) = (x - 2)^2 \end{aligned} \qquad (2.9)$$

Este *MOP* ha sido estudiado previamente no solo en [SHA84], sino también en [COE96], [FON95a], [HOR94] y en muchos otros trabajos, siendo utilizado como un paradigma para la presentación de los principales conceptos de la optimización multiobjetivo.

La figura 2.2 presenta la gráfica de ambas funciones en función de *x*. La misma sugiere que el conjunto Pareto-óptimo es $\{ x \mid x \geq 0 \text{ y } x \leq 2 \}$. Esto es: $CP_{true} = \{x \in \Re \mid 0 \leq x \leq 2\}$. La solución $x = 0$ es óptima respecto a f_1 pero no respecto a f_2. Cualquier solución que no se encuentre en el rango [0, 2] no es miembro del conjunto Pareto-óptimo, puesto que en dicho rango (CP_{true}) existe siempre una solución mejor que la domina.

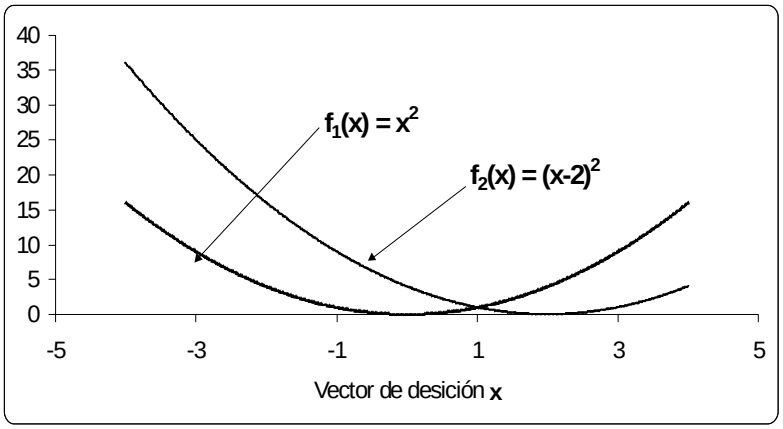

Figura. 2.2. Valores de f_1 y f_2 en función de $x \in X_f = (-\infty, \infty)$ para el ejemplo 2.1.

La diferencia esencial entre la figura 2.2 y la figura 2.3 es que la primera representa los valores de las funciones f_1 y f_2 para diferentes valores de la

variable independiente *x*. Mientras que la segunda representa los valores de la función f_1 graficados contra la función f_2, para el mismo valor de la variable independiente. Es decir, la figura 2.3 es una gráfica del frente Pareto en el espacio objetivo ***Y***, que muestra los vectores del *MOP* como puntos. Los vectores no dominados (que se muestran como puntos), representan el frente Pareto del *MOP*, por encima de la curva, se encuentra el espacio objetivo factible $\boldsymbol{Y}_f$.

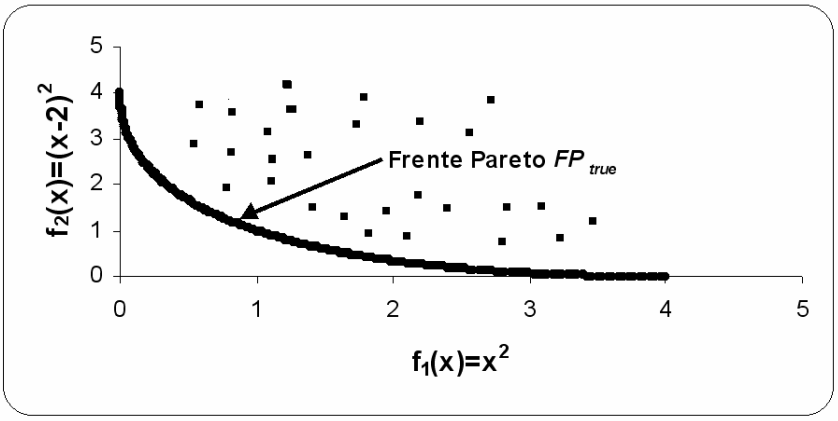

Figura:. 2.3. Frente Pareto del ejemplo 2.1.

2.2 Búsqueda y toma de decisiones

Se pueden distinguir 2 niveles de dificultad al resolver un problema de optimización multiobjetivo: la búsqueda y la toma de decisiones [HOR97]. El primer aspecto se refiere al proceso de optimización, durante el cual se explora el espacio de soluciones factibles buscando las soluciones Pareto-óptimas. En esta fase, como ocurre en la optimización de objetivo único, el espacio de búsqueda puede ser lo suficientemente grande y complejo como para impedir el uso de técnicas de optimización que den resultados exactos [STE86]. El segundo aspecto es equivalente a seleccionar un conjunto o una única solución

de compromiso del conjunto Pareto-óptimo ya encontrado. Este paso generalmente tiene que ver con cuestiones inherentes a las condiciones del problema y los recursos disponibles.

Los métodos de optimización multiobjetivo pueden clasificarse así en tres categorías diferentes dependiendo de la manera en que se combinan ambas fases [COH78], [HWA79]:

- Toma de decisión previa a la búsqueda (decidir, luego buscar): los objetivos del MOP se combinan en un único objetivo que implícitamente incluye información de preferencia obtenida del responsable de la toma de decisiones. Estos son métodos de toma de decisión *a priori*, tales como la suma con pesos, orden lexicográfico, etc. Gran parte de las técnicas tradicionales para resolución de *MOPs* utilizan esta estrategia [COH78] y [STE86].

- Búsqueda previa a la toma de decisión (buscar, luego decidir): se realiza la optimización sin incluir información de preferencia. El responsable de la toma de decisiones escoge del conjunto de soluciones obtenidas (que idealmente son todas del conjunto Pareto-óptimo). A éstos se conoce como métodos de toma de decisión *a posteriori*,

- Toma de decisión durante la búsqueda (decidir mientras se busca): esto permite que quien toma las decisiones pueda establecer preferencias durante un proceso de optimización interactivo. Luego de llevarse a cabo

cada paso del proceso de optimización, se presenta al responsable de decisiones los conflictos existentes y se le permite especificar sus preferencias o compromisos. De esta manera se desarrolla una búsqueda guiada. Estos métodos reciben el nombre de *progresivos* o *interactivos*.

Combinar múltiples objetivos en un único objetivo a optimizar, posee la ventaja de que a la función resultante se puede aplicar cualquiera de los métodos de optimización de un único objetivo, ya disponibles en la literatura [COH78], [STE86], sin mayores modificaciones. No obstante, tal combinación requiere conocimiento del dominio del problema que no siempre está disponible. En los problemas de diseño de diversas áreas de ingeniería, se realiza la búsqueda justamente para tener un mejor conocimiento del espacio de búsqueda del problema y las soluciones alternativas. Al realizar la búsqueda antes de la toma de decisión no se requiere este conocimiento, pero se impide que quien toma la decisión exprese previamente sus preferencias, lo que probablemente conduce a una reducción de la complejidad del espacio de búsqueda. Un problema con las técnicas de toma de decisión interactivas o *a posteriori* es la dificultad de presentar al responsable de la toma de decisiones las diferencias entre las soluciones de un MOP de muchas dimensiones. Aún así, la integración de la búsqueda y la toma de decisiones que proponen las técnicas interactivas parece una alternativa promisoria para aprovechar las ventajas de los dos primeros tipos de técnicas.

El presente trabajo está enfocado en técnicas que han demostrado ser capaces de explorar espacios de búsquedas muy grandes y altamente complejos y generar aproximaciones al conjunto Pareto-óptimo.

2.2.1 El Método de Suma con Pesos

Tradicionalmente la resolución de los *MOPs* se ha basada en esquemas que optimizan una sola métrica. Solo recientemente se han propuestos nuevos esquemas y algoritmos que consideran más de una métrica a optimizar. El método generalmente utilizado es el de la suma ponderada utilizando pesos [COH78]. Este método combina las diferentes funciones objetivo en una sola función *F*, de la siguiente manera:

Optimizar $$F = \sum_{j=1}^{k} w_j f_j(\boldsymbol{x}) \qquad (2.10)$$

donde:

$\boldsymbol{x} \in \boldsymbol{X_f}$, y w_j es el peso usado para ponderar la *j*-ésima función objetivo.

Usualmente, y sin pérdida de generalidad, se escogen pesos fraccionarios y diferentes de cero, de manera a cumplir la condición de normalización [DON04]:

$$\sum_{j=1}^{k} w_j = 1,\ w_j > 0$$

El procedimiento es el siguiente: se escoge una combinación de pesos y se optimiza la función *F* para obtener una solución óptima. Otras soluciones surgen a partir de optimizaciones realizadas sobre una combinación diferente de pesos [DON04].

En el presente contexto, optimizar implica maximizar todas las funciones objetivo, o minimizarlas. Esto es, o se maximiza o se minimiza todas las funciones $f_i(\boldsymbol{x})$; no se admite la maximización de algunos objetivos y la minimización de otros.

En [DEB99a] se demuestra que, si se utiliza un algoritmo de optimización que obtiene resultados exactos siempre y los pesos escogidos son siempre positivos, el método genera soluciones que siempre pertenecen al conjunto Pareto-óptimo. La interpretación de este método es la siguiente. Alterar el vector de pesos y optimizar la ecuación implica encontrar un hiperplano (una línea para el caso en que se tengan dos objetivos) con una orientación fija en el espacio de la función. La solución óptima es el punto donde un hiperplano con esta orientación tiene una tangente común con el espacio de búsqueda factible. De aquí deducimos que este método no puede usarse para encontrar soluciones Pareto-óptimas en problemas de optimización multicriterio que tienen un frente Pareto-óptimo cóncavo. Para una discusión más detallada de esta característica se refiere al lector a [DEB99a].

Si bien no se adecuan a la naturaleza del problema, la ventaja principal del método de suma con pesos es que permite la utilización de algoritmos desarrollados para la resolución de problemas de optimización mono-objetivos (*SOP - Single Objective Problems*) bien conocidos y de probada eficacia, aún cuando se trate de problemas reales, de gran tamaño. Para problemas de gran escala, muy pocas técnicas de optimización multiobjetivo reales se han presentado [HOR97], a diferencia de técnicas de optimización de un solo objetivo que han existido desde hace bastante tiempo y han sido probadas en

diferentes situaciones. Sin embargo, este método cuenta con las siguientes limitaciones [DEB99a]:

- El algoritmo de optimización se debe aplicar varias veces para encontrar las múltiples soluciones Pareto-óptimas. Como cada corrida es independiente de las demás, generalmente no se obtiene un efecto sinérgico. Por tanto, delinear el frente Pareto-óptimo resulta computacionalmente muy caro.

- Requiere conocimiento previo del problema a resolver y es sensible a los pesos utilizados.

- Algunos algoritmos son sensibles a la forma del frente Pareto (problemas con curvas no convexas).

- La variación entre las diferentes soluciones encontradas depende de la eficiencia del optimizador de un solo objetivo. Podría darse el caso de encontrar siempre la misma solución o soluciones muy parecidas, en corridas múltiples.

- Como los optimizadores de un solo objetivo no son eficientes en búsquedas de universos discretos [DEB99], tampoco serán eficientes para optimizaciones multiobjetivo en espacios discretos.

2.2.2 El Método del Orden Lexicográfico.

El método de Orden Lexicográfico se basa en la asignación de prioridades *a priori* a cada uno de los Objetivos a optimizar. El objetivo que posee la mayor prioridad es utilizado para realizar el orden, si ocurre un empate el siguiente objetivo de mayor prioridad es comparado, y así sucesivamente. Todos los objetivos $f_1,\ldots,f_k$ son ordenados en orden creciente de prioridad. Esta técnica es recomendable cuando se conoce perfectamente el orden de importancia de los objetivos, porque el desempeño del algoritmo depende en gran medida de dicho ordenamiento [LAN02].

2.2.3 Computación Evolutiva

La generación del conjunto Pareto-óptimo puede ser computacionalmente muy cara y hasta a menudo no factible, porque la complejidad de la aplicación subyacente impide a los métodos exactos ser aplicables [ZIT99]. Por esta razón, varias estrategias de búsqueda estocásticas como son los algoritmos evolutivos (*EA Evolutionary Algorithms*), búsqueda tabú, el templado simulado y optimización por colonia de hormigas fueron desarrolladas. Estos métodos usualmente no garantizan la identificación de las soluciones óptimas pero tratan de hallar una buena aproximación, *i.e.*, un conjunto entero de vectores soluciones objetivos que no están demasiados lejos del vector objetivo óptimo.

En general, un algoritmo de búsqueda estocástica consiste de tres partes:

- una *memoria activa* que contiene la solución actual considerada,
- un *módulo de selección*,
- un *módulo de variación*,

estos tres módulos son presentado en la Figura 2.4.

Acerca de la *selección*, puede distinguirse entre selección de *pares* y *medioambiental*. La selección de pares apunta a escoger las soluciones prometedoras para la variación y normalmente se realiza en una forma aleatoria. En contraste, la selección medioambiental determina cuál de las previas soluciones guardadas y las nuevamente creadas son guardadas en la memoria interna. El *módulo de variación* toma un conjunto de soluciones y sistemáticamente o aleatoriamente modifica estas soluciones en orden a generar potencialmente mejores soluciones. En resumen, una iteración de un optimizador estocástico incluye los consecutivos pasos: selección de soluciones, variación, y selección medioambiental; este ciclo puede ser repetido hasta que un cierto criterio de parada sea satisfecho.

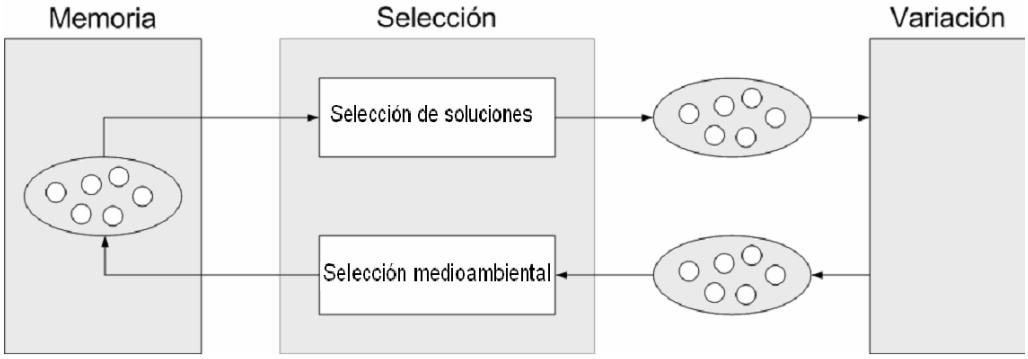

Figura 2.4. Componentes de un algoritmo general de búsqueda estocástica.

Muchas estrategias de búsqueda estocástica han sido desarrolladas originalmente para optimización de un solo objetivo y por lo tanto consideran solo una solución en un momento, *i.e.*, la memoria activa contiene solo una solución. Como consecuencia, la selección por pareja no es necesaria y la variación es hecha por modificación de la solución candidata actual.

En contraste, un algoritmo evolutivo es caracterizado por tres rasgos:

- un conjunto de soluciones candidatos es mantenido,
- un proceso de selección de pares es hecho sobre este conjunto,
- varias soluciones pueden ser combinadas en términos de recombinación para generar nuevas soluciones.

Por analogía a la evolución natural, la soluciones candidatas son llamadas *individuos* y el conjunto de soluciones candidatas es llamado *población*. Cada individuo representa una posible solución, *i.e.*, un vector de decisión, sin embargo, un individuo *no es* un vector de decisión sino es el código que lo representa.

El proceso de selección de pares usualmente consiste de dos estados: asignación de *fitness* o aptitud y muestreo. En el primer estado, los individuos en la población actual son evaluados en el espacio objetivo y entonces se les asigna un valor escalar, el *fitness*, que refleja su calidad. Luego, un conjunto de pares es creado por muestreo estocástico de la población de acuerdo a los valores de *fitness*. Por ejemplo, dos individuos son aleatoriamente elegidos desde la población, y aquel con mejor valor de *fitness* es copiado al conjunto de pares. Este proceso es repetido hasta que el conjunto de pares sea completado.

Cuando el conjunto de pares es obtenido, los operadores de variación son aplicados a dicho conjunto. Con *EA*, normalmente existen dos operadores de variación, a saber, el operador de cruce y de mutación. El operador de cruce toma un cierto número de padres y crea un número predefinido de hijos por combinación de partes de los padres. Para imitar la naturaleza estocástica de la evolución, una probabilidad de cruce es asociado con este operador. En

contraste, el operador de mutación modifica individuos por cambios de pequeñas partes en el vector asociado de acuerdo a una tasa de mutación dada. Note que debido a los efectos aleatorios algunos individuos en el conjunto de pares pueden no ser afectados por la variación y por lo tanto simplemente representa una copia de la previa generación de soluciones.

Basado en estos conceptos, la evolución natural es simulada por un proceso computacional iterativo como es mostrado en la Figura 2.5.

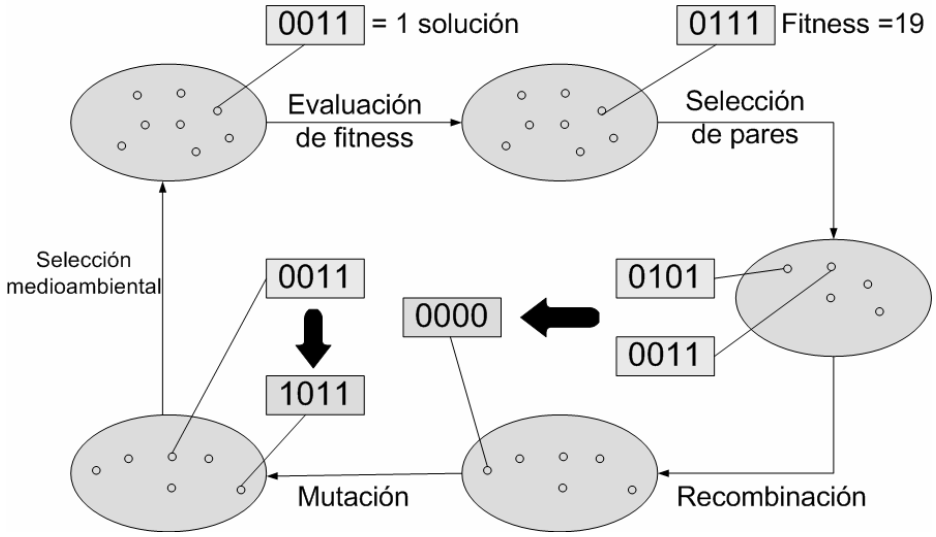

Figura 2.5 Contorno de un algoritmo evolutivo general para un problema con variable de decisión de cuatro bits.

Primeramente, una población inicial es creada aleatoriamente (o de acuerdo a un esquema predefinido), el cuál es el punto de partida del proceso de evolución. Entonces un ciclo consistente en pasos de evaluación (asignación de *fitness*), selección, recombinación, y/o mutación es ejecutado un cierto número de iteraciones. Cada iteración de ciclo es llamada *generación*, y a menudo un número máximo predefinido de generaciones sirve como criterio de finalización del ciclo. Pero también otras condiciones, *como ser,* el estancamiento en la población o existencia de un individuo con suficiente

calidad, pueden ser usadas para detener la simulación. Al final del ciclo, los mejores individuos en la población final representan el resultado del *EA* [ZIT99].

Dada esta introducción de los conceptos claves de los *EAs*, se procede a presentar en la siguiente sección una breve descripción de los algoritmos de optimización basados en colonias de hormigas, por este algoritmo la base del presente trabajo.

2.2.4 Optimización basada en Colonia de Hormigas

En la década de los 90 surgió un nuevo método computacional, conocido como Optimización por Colonia de Hormigas o *Ant Colony Optimization* (*ACO*), exitosamente utilizado en la resolución de varios problemas combinacionales mono-objetivo. *ACO* es una metaheurística basada en el comportamiento de búsqueda de alimentos de las colonias de hormigas reales [DOR96]. Ya en años más recientes se han dado los primeros pasos en la resolución de problemas multiobjetivo (*MOPs*) basados con estos conceptos, las cuáles tuvieron gran éxito en varios problemas combinatorios como es el caso del Problema de Cajero Viajante Biobjetivo [GAR04].

Debido al reciente desarrollo de *ACO*, no existe en la literatura un gran desarrollo teórico sobre el éxito de ésta metaheurística, como es reconocido por Dorigo y Stützle [DOR01] y [STÜ02], *i.e.*, aunque *ACO* ha mostrado experimentalmente ser altamente efectivo, sólo limitado conocimiento está disponible para explicar por qué la metaheurística *ACO* es tan exitosa [DOR01]. Recién en el 2004 Gómez y Barán realizaron uno de los primeros estudios teóricos basados en pruebas experimentales y dan las razones del éxito de

Optimización por Colonias de Hormigas en el Problema del Cajero Viajante en un contexto mono-objetivo [GOM04a].

Es importante destacar que en el presente estado del arte, la resolución del problema de Compensación de Potencia Reactiva multiobjetiva aplicando *ACO* no ha sido tratada aún. Solo existen algunos trabajos que proponen la resolución del RPC mono-objetivo sujeto a restricciones y aplicado solamente a instancias pequeñas de 30 o menos barras [LIN03] .

Debido a lo mencionado, este trabajo tiene un aporte significativo al estado del arte al proponer por primera vez la resolución del problema de Compensación de Potencia Reactiva en un contexto multiobjetivo aplicando *ACO*. Además, cada objetivo es optimizado simultáneamente, *i.e.* no se utiliza los métodos de suma de pesos ni orden lexicográfico.

Por otra parte en este Capítulo no es dado mayores detalles sobre *ACO* considerando que será tratado en un capítulo posterior por ser uno de los temas de mayor interés de este trabajo, teniendo en cuenta que la propuesta de solución del problema de compensación de potencia reactiva multiobjetivo es basada en *ACO*.

2.3 Formulación Matemática del Problema de Compensación de Potencia Reactiva.

El estudio del sub-problema de *OPF* llamado Compensación de Potencia Reactiva, *RPC*, cumple un papel muy importante en la planificación de la expansión y operación de *EPS* Los estudios indican que, en promedio, más del 13% de la energía total producida es consumida por las pérdidas I^2R en la

zona de distribución [BUN82], siendo que las corrientes reactivas son responsables por parte de esas pérdidas. Por este motivo, bancos de capacitores y/o reactores *shunt* son comúnmente instalados en las adyacencias de los alimentadores en redes de transmisión y distribución para proveer así potencia reactiva en los puntos en que es necesaria, disminuyendo la necesidad de transportarlas a través de la red eléctrica. Esto resulta en varias ventajas como [ABB05], [KUN93]:

- reducción de las pérdidas de transmisión;
- mejora del factor de potencia;
- incremento de la capacidad de transmisión;
- mejor control de voltaje;
- mejora de la calidad del servicio.

La concreción de estas metas depende de la adecuada ubicación y dimensionamiento de bancos de capacitores y/o reactores *shunt*. Expuesto de esta forma, el problema de RPC en EPS puede ser formulado como la determinación de la ubicación y capacidad eléctrica de las fuentes de potencia reactiva, buscando además [KUN93]:

Minimización de las pérdidas de transmisión: las pérdidas de potencia activa en la transmisión pueden traducirse directamente en costos monetarios, ya que consiste en la diferencia entre la potencia generada y la potencia servida.

Minimización de cantidad y capacidad de fuentes de reactivos instaladas: aunque que la instalación de bancos de capacitores y/o reactores *shunt* provee la más forma económica de generar potencia reactiva para controlar el voltaje, el exceso de la utilización de estos dispositivos conduce a la reducción de la estabilidad del sistema y a una pobre regulación del perfil de tensiones, además del costo que implican los dispositivos en si y su instalación;

*Buen perfil de tensiones***:** la calidad de la potencia servida está relacionada directamente por la diferencia entre la tensión efectiva y la tensión nominal de los alimentadores.

Para la formulación matemática del problema se hicieron las siguientes consideraciones:

- se analizó solamente el valor pico de potencia demandada;
- se consideró el tamaño de los bancos de reactores como variables discretas debido a que solo se fabrican bancos de potencia normalizados por la industria [ABB05];
- se consideró el costo de los bancos como unitario e independiente de la ubicación;
- se limitó el valor de los bancos de reactivos, tanto para el caso capacitivo como inductivo.

En base a estos puntos se identificaron dos funciones objetivos a ser minimizadas: un objetivo f_1 relacionado al aspecto económico de la inversión en los dispositivos de compensación y el segundo objetivo f_2 relativo a la calidad

del servicio que normalmente es tratado como una restricción operativa de los *EPSs*. Así, las funciones objetivo consideradas son:

2.3.1 Minimización de la inversión en dispositivos de compensación de potencia reactiva.

Función objetivo utilizada para la planificación de la instalación de nuevas fuentes de potencia reactiva. Su formulación es la siguiente:

$$min \quad f_1 = \sum_{i=1}^{n} |B_i| \tag{2.11}$$

Sujeto a las siguientes restricciones $\begin{cases} f_1 \leq f_1^m \\ |b_i| \leq |b_i^m| \end{cases}$

donde f_1 es la inversión total requerida; f_1^m es la máxima inversión disponible para todo el sistema; $|b_i|$ es la compensación en la barra *i* medida en MVA; $|b_i^m|$ es el máximo valor absoluto de compensación reactiva posible para dicha barra del sistema y *n* es el número de barras en el sistema. Conocido el costo de las fuentes de reactivos por MVA de potencia, esta función objetivo se puede interpretar fácilmente como el costo financiero de inversiones en fuentes de reactivos.

2.3.2 Minimización de la desviación promedio de voltaje.

El objetivo de esta función es obtener una solución donde las tensiones de barras estén lo más próximo posible a la tensión de operación ideal previamente establecida. Puede ser definida de la siguiente manera:

$$min \quad f_2 = \frac{\sum_{i=1}^{n} \left| V_i^* - V_i \right|}{n} \tag{2.12}$$

donde f_2 es el promedio de la desviación de voltaje, V_i el voltaje efectivo obtenido en la barra *i* y V_i^* el voltaje deseado en dicha barra. Esta segunda función puede ser considerada como un objetivo técnico que mide la calidad de una solución, es decir, que tan conveniente seria ubicar una determinada distribución de reactivos en la red.

2.4 Formulación como problema multiobjetivo.

Se define a la variable de decisión como el vector de ubicación de fuentes de reactivos en cada barra según:

$$B = [b_1, b_2, b_3, \ldots\ldots, b_n] \tag{2.14}$$

donde cada b_i representa la compensación en MVA ubicada en la barra *i*. El valor de b_i, está limitado por los valores máximos de compensación tanto inductiva como capacitiva. Esto puede expresarse como:

$$b_{iI}^m \leq b_i \leq b_{iC}^m \tag{2.15}$$

donde b_{iI}^m y b_{iC}^m corresponden a los máximos valores de compensación inductiva y capacitiva respectivamente. Por convención los bancos de características inductivas tienen valores negativos y los de características capacitivas valores positivos. Para el presente trabajo se consideró el mismo valor absoluto para la máxima compensación capacitiva e inductiva para todas las barras; en futuros trabajos podrían fijarse valores diferentes para distintas barras de acuerdo a las características de tensión o carga de las mismas. Por lo tanto, la cantidad de posibles compensaciones consideradas, denotado por *c*, para cada barra es la misma. Este valor *c* depende del valor de la máxima

compensación admisible y del nivel de discretización usado, es decir, de la cantidad de valores diferentes que se considera para compensar una barra determinada. Como ya se expresó, se consideró el nivel de discretización unitario, o sea, que los bancos pueden tomar todos los valores enteros entre - b_{iI}^{m} y b_{iC}^{m}.

El problema hasta aquí descrito formalmente se formula como un *MOP* así:

$$min \;\; F(B) = [f_1 \quad f_2] \tag{2.14}$$

Las restricciones corresponden a las propias del flujo de potencia de acuerdo a las ecuaciones 1.7, 1.8 y a las restricciones impuestas al primer objetivo de minimización de la inversión y pueden ser formuladas así:

Sujeto a las siguientes restricciones:

$$\begin{cases} P_k = \sum_{m=1}^{n} V_k V_m (G_{km}\cos\theta_{km} + \sigma_{km} sen\theta_{km}) \\ Q_k = \sum_{m=1}^{n} V_k V_m (G_{km} sen\theta_{km} - \sigma_{km}\cos\theta_{km}) \\ f_1 \leq f_1^{m} \\ |b_i| \leq |b_i^{m}| \end{cases}$$

Nótese que como las funciones objetivo tienen unidades de medidas muy diferentes, *i.e.* f_1 se mide en MVAr y f_2 en pu. , resulta muy difícil en la práctica hacer una combinación lineal de ambos para combinarlos en un solo objetivo. Este inconveniente no se presenta en la optimización multiobjetivo pues ambos objetivos son optimizados simultáneamente.

Para concluir se muestra en la figura 2.4 un ejemplo de una solución al *RPC*, o distribución de bancos de reactivos, para una red de cuatro barras. El vector de decisión que corresponde al ejemplo es B = [3,-4,5,0]. Como se

observa en el grafico este vector indica que la primera barra tiene un banco de capacitores de 3 MVAr, la segunda barra un reactor de 4 MVAr, la tercera un banco de capacitores de 5 MVAr y la última barra no esta compensada.

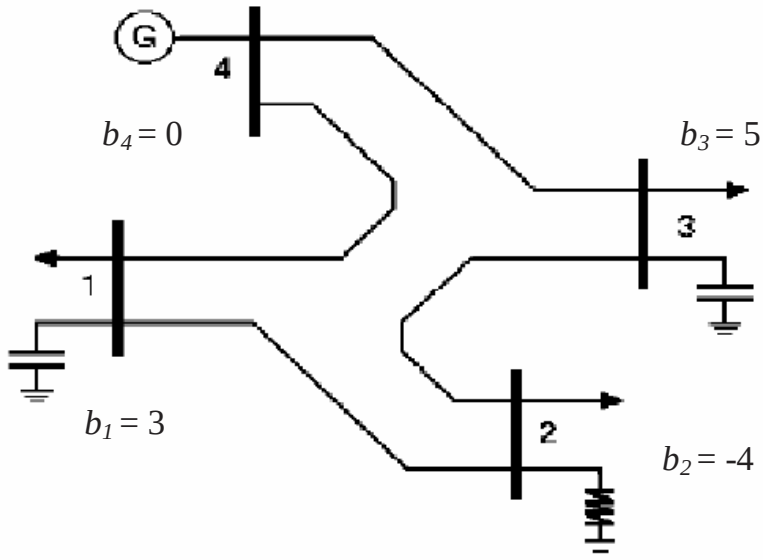

Figura 2.6: Ejemplo de distribución de bancos *shunt* en un EPS.

Capítulo 3

Métodos de Optimización aplicados a los Sistemas Eléctricos de Potencia.

A través de los años diversos métodos de optimización matemática han sido utilizados para resolver distintos problemas de planificación, operación y control de *EPSs*. Formulaciones matemáticas de problemas de tamaño real se simplifican utilizando ciertas acepciones pero aún con estas simplificaciones resolver problemas relacionados con los *EPSs* de gran escala resulta una tarea extremadamente compleja. Por otro lado, existen ciertas incertidumbres con respecto a los *EPSs* debido a que los sistemas eléctricos son grandes, complejos y geográficamente muy extensos [BAN05]. Varias técnicas de optimización han sido aplicadas a resolver problemas relacionados con los *EPSs* y una gran cantidad de literatura especializada ha sido publicada sobre este tema desde la década del 50 [BAN05]. Reseñas acerca de algunas de estas aplicaciones han sido presentadas por Kothari et al. [KOT88], [AHM98], [SEN98], Momoh et al. [MAM99a], [MAM99b], Sachdev et al. [SAC77], Happ [HAP77], Quintanna et al. [QUI00], Gonen et al. [GON83], Rahman [RAH93], Huneault [HUN91] y comités de la *IEEE* (*Institute of Electrical and Electronics Engineers*) [IEE80], [IEE81].

Con respecto al problema de compensación de potencia reactiva, la literatura que describe los algoritmos para resolver el *RPC* es abundante. El Subcomité de Capacitores del Comité de Transmisión y Distribución de la *IEEE* ha publicado diez revisiones bibliográficas sobre Capacitores de Potencia

desde 1950 hasta 1980 [IEE83]. Además, la Gerencia del Grupo de Trabajo sobre VAR (Potencia Reactiva) del Subcomité de Sistemas de Control de la IEEE ha publicado una revisión bibliográfica sobre Potencia Reactiva y Control de Tensión en *EPSs* [IEE97]. El total de las publicaciones listadas en dichas revisiones es superior a 400 siendo muchas de ellas investigaciones específicas sobre *RPC*. Hacer una revisión bibliográfica de todos los trabajos publicados sobre *RPC* es una tarea que escapa a la finalidad de este trabajo; sin embargo, se pretende dar a continuación una idea del estado del arte y una clasificación de las técnicas actualmente empleadas para la resolución del problema *RPC*. Las técnicas aplicadas para la resolución del *RPC* pueden ser clasificadas en cuatro metodologías según Ng et al. [NG00]: Analítica, Programación Numérica, Heurística e Inteligencia Artificial.

3.1 Métodos Analíticos

Los primeros trabajos sobre *RPC* utilizaban métodos analíticos. Dichos algoritmos eran desechados cuando los recursos computacionales eran insuficientes o muy caros. Los métodos analíticos utilizan el cálculo diferencial e integral para maximizar una función de *Ahorro con Capacitores* ***S*****,** la cual puede es formulada de la siguiente forma:

$$S = E_a + PP - \sum CC_B \qquad (3.1)$$

donde E_a y *PP* representan la energía ahorrada y la potencia pico disminuida por medio de la ubicación de capacitores respectivamente y CC_B es el costo de la instalación de los capacitores. Los pioneros de la ubicación óptima de

capacitores, Neagle y Samson [NEA56], Cook [COO59], [COO61], Schmill [SCH65], Chang [CHA69a], [CHA69b] Bae [BAE78], utilizaron aproximaciones analíticas para maximizar alguna de las formas de (3.1). A pesar de encontrar soluciones sencillas y restringidas, estos métodos estaban basados en acepciones irrealistas, tales como: el alimentador con carga uniforme y un tamaño fijo del conductor. A consecuencia de estos estudios la famosa regla dos tercios fue formulada. La regla de los dos tercios [DWY92] establece que para tener mínimas pérdidas, el capacitor debe tener una potencia equivalente a dos tercios de la energía reactiva pico requerida y debe estar instalado a dos tercios del final de la línea del alimentador.

Estos primeros métodos analíticos son fáciles de entender e implementar. A pesar de las acepciones irrealistas que fundamentan la ley de dos tercios, algunas aplicaciones utilitarias todavía se basan en esta regla [DWY92] y algunos fabricantes de capacitores de potencia listan esta regla en sus guías de aplicación [MAR91].

Para encontrar mejores soluciones, el modelado de los alimentadores fue mejorado. Grainger et al. [GRA81], [LEE81] y Salama et al. [SAL85a], [SAL85b], formularon equivalentes normalizados de alimentadores que incluían consideraciones acerca de diferentes tamaños de conductores y carga no uniforme. Grainger et al. también incluyeron la planificación de conmutación de los capacitores en sus algoritmos y posteriormente mejoraron su propuesta al incorporar la ubicación de reguladores [CIV85a], [CIV85b], [GRA85]. Estos últimos métodos analíticos proveen un modelado realista en *EPSs* con alimentadores radiales, y consideran la variación de la carga.

Para demostrar la importancia del correcto modelado de los alimentadores de distribución y la variación de la carga, Grainger et al. indicaron con un ejemplo en [LEE81] como la regla dos tercios puede tener errores gruesos que pueden resultar en ahorros negativos o pérdidas.

Otro de los inconvenientes de los métodos analíticos es el modelado de la ubicación y tamaño de los bancos de capacitores en forma continua. Con esta aproximación, el tamaño calculado de los bancos puede no existir entre los tamaños estandarizados por la industria y su ubicación física puede resultar impracticable al no coincidir con la ubicación física de las barras. Los resultados necesitan ser redondeados por exceso o por defecto a valores estándar, pudiendo resultar esto en sobretensiones de barra o menores reducciones de costos en ***S*** que las calculadas en un principio. Para sistemas de alimentadores simples con variaciones definidas de carga, estos primeros métodos proveen una regla empírica para la solución del *RPC*. Los más recientes métodos analíticos son mucho más precisos y efectivos en *EPSs* de gran porte, pero requieren de una información muy detallada de los *EPSs* y un tiempo de implementación elevado.

3.2 Métodos de Programación Numérica

Con el aumento de la velocidad de proceso de las computadoras y la sensible reducción de los costos de memoria y hardware en general, los métodos de programación numérica fueron utilizados para resolver problemas de optimización. Los métodos de programación numérica son técnicas iterativas utilizadas para maximizar (o minimizar) una función objetivo con las

variables de decisión. El valor de las variables de decisión debe satisfacer además un conjunto de restricciones.

Existen una amplia variedad de técnicas de programación matemáticas bien elaboradas y estudiadas como son: programación lineal *LP* (*lineal programming*), método de las variaciones locales o método del punto interior *IP* (*interior point method*), programación cuadrática *QP* (*quadratic programming*), programación no lineal *NLP* (*nonlinear programming*), técnicas de descomposición, programación entera y programación entera mixta, programación dinámica *DP* (*dynamic programming*), etc. [BAN05].

Programación lineal y cuadrática: Cuando las funciones objetivos y las restricciones son funciones lineales se puede utilizar la *LP* [SCO79], [ALS90], [HEG83]. Los métodos de *LP* pueden ser divididos básicamente en dos categorías: métodos *simplex* e *IP* como puede ser visto en los siguientes trabajos: [IRR98], [VAR93], [GRA94], [RAM96], [CHR96], [MEL97], [PAN92] y [SHE94b]. Estos métodos son capaces de resolver problemas con miles de variables y restricciones aún utilizando computadoras económicas [BAN05]. Su mayor desventaja es que el número de iteraciones crece exponencialmente con el tamaño del problema. Esta desventaja puede ser superada con los métodos *IP*. A diferencia de los métodos *simples*, los *IP* realizan su búsqueda en el interior de una región restringida y se mueven progresivamente al punto óptimo. Una gran variedad de algoritmos *IP* han sido aplicados a diversos problemas relacionados a los *EPSs*, como ser despacho económico, optimización de potencia reactiva, planeamiento de expansión etc. Ambos

métodos, el *IP* y el *simplex* pueden ser extendidos para ser utilizados también con objetivos lineales y cuadráticos cuando las restricciones son lineales. Estos métodos son llamados *QP* [MOM94] y [NAN89]. Los métodos *LP* han sido aplicados a varios problemas relativos a los *EPSs* incluyendo *OPF* [ALS90], flujo de potencia [HEG83], planeamiento de potencia reactiva [OPO90], despacho de potencia activa y reactiva [CHE95a] y [CHE95b].

*Programación no lineal***:** Cuando las funciones objetivo o las restricciones son no lineales se utiliza la programación no lineal *NLP*. La diferencia entre la *NPL* y la *PL* es análoga a la diferencia entre resolver un conjunto de ecuaciones lineales y otro de ecuaciones no lineales. La mayoría de los métodos de *NLP* inician haciendo una suposición inicial acerca de la solución para luego hallar una dirección de aproximación, con la que el algoritmo intentará acercarse iterativamente a la solución verdadera [BAN05], [IRV00] y [TIN67]. Los métodos *NPL* han sido aplicados al flujo de potencia óptimo [SUN84], planeamiento hidrotérmico [KOT89], etc.

*Programación entera y entera mixta***:** En muchos problemas de optimización las variables independientes solo pueden tomar valores enteros, estos problemas dan origen a la programación entera. Cuando algunas de las variables son discretas y otras continuas se tiene un problema de programación entera mixta [BAN05]. Mayormente dos aproximaciones han sido utilizadas para resolver problemas de programación lineal usando técnicas de programación matemáticas: ramificación y acotación (*branch and bound*) y

planos de corte (*cutting plane*) [IRV00]. Técnicas de descomposición para convertir problemas de variables continuas en problemas de programación entera o mixta han sido usados en [ALG00], [DEE90], [GEO72], [PER85], [GRA88] y [MAD96]. Estas técnicas de programación han sido exitosamente aplicadas a: planeamiento de potencia reactiva [AOK88], planeamiento de *EPSs* [ADA73], [GON81], asignación de unidades (*unit commitment*) [DIL78], programación de generación [DAP75], etc.

*Programación dinámica***:** Esta técnica ha probado ser muy poderosa cuando es aplicable pero sufre de serios problemas al aumentar la dimensión del problema volviéndose impracticable para problemas grandes [SON99a]. *DP* ha sido exitosamente utilizado para resolver el problema de control de potencia reactiva [LU95], planeamiento de transmisión [PAR90], asignación de unidades [HOB88], etc.

*Métodos de Programación Numérica aplicados al problema de compensación de potencia reactiva***:** Para el *RPC*, la función ***S*** (3.1) es conocida como función objetivo mientras que las ubicaciones, tamaños y números de bancos de reactores, así como también las tensiones y corrientes de barras, pueden ser variables de decisión que deben satisfacer ciertas restricciones. La función objetivo puede considerar todas las restricciones de tensión y corrientes del *EPS*, tamaño discreto de los bancos de capacitores y la ubicación física de las barras. Utilizando métodos de programación numérica, el *RPC* puede formularse como max (***S***) (3.1), sujeto a $\Delta V < \Delta V^m$ donde

ΔV es la desviación de tensión que no debe exceder la máxima desviación de tensión admisible ΔV^m.

Duran [DUR68] fue el primero en utilizar aproximaciones por programación dinámica para resolver el *RPC*. La formulación en [DUR68] es simple y solo considera el costo de la reducción de la energía perdida considerando capacitores de tamaños discretos. Fawzi et al. [FAW83] continuaron el trabajo de Duran pero incluyeron el ahorro de la energía reactiva en la función de ahorro, Ponnavaikko y Rao [PON83] expandieron la formulación del *RPC* incluyendo los efectos de la carga de tierra, conmutación de capacitores y carga con variaciones, utilizando el método de las variaciones locales. De forma similar Barán y Wu [BAR89a], [BAR89b] formularon el *RPC* utilizando programación entera mixta. Baldick y Wu [BAL90] continuaron la investigación aplicando programación cuadrática con enteros para coordinar la óptima operación de los capacitores y reguladores en los *EPSs*. Por inspección de todos los métodos numéricos, uno puede observar que el nivel de sofisticación y complejidad de los modelos se incrementa con el orden cronológico de las publicaciones.

Esta progresión ocurre con el incremento de la capacidad de las computadoras. En el presente, computadoras de mucha capacidad son relativamente económicas y muchos paquetes de optimización numérica están disponibles para implementar los algoritmos expuestos líneas arriba. Algunos de los métodos de programación numérica consideran la ubicación de las barras de los alimentadores y el tamaño de los capacitores como variables discretas siendo esta una ventaja apreciable sobre los métodos analíticos. En

contrapartida, la preparación de los datos del *EPS* y el desarrollo de la interfase para la aplicación de los métodos numéricos lleva mas tiempo que para los métodos analíticos. También se debe determinar la convexidad del *RPC* para poder determinar si la solución encontrada por el método numérico es un óptimo local o global. Más aún, en formulaciones que incluyen los beneficios de la energía aparente liberada y la consideración de los efectos de la carga de tierra, se hace muy difícil asignar valores económicos para algunas cantidades consideradas [VAL02].

3.3 Métodos Heurísticos

Los métodos conocidos como heurísticas consisten en un conjunto de reglas empíricas desarrolladas por intuición, experiencia y juicios. Estos conjuntos de reglas heurísticas dan como resultado estrategias de búsqueda más rápidas y prácticas que aquellas basadas en la búsqueda exhaustiva y pueden llegar a obtener soluciones , si bien no óptimas globales, muy próximas a las óptimas con un alto nivel de confianza. A finales de los 80s métodos basados en técnicas heurísticas de búsqueda fueron introducidas para reducir las pérdidas de distribución por reconfiguración [CIV88], [TAY90]. Abdel-Salam et al. [ABD94] propusieron una técnica heurística basadas en ideas de [CIV88], [TAY90] para identificar una sección del sistema de distribución con mayores pérdidas y con las mayores corrientes reactivas, identificando en esta sección, por análisis de sensibilidad, cuales son las barras candidatas a recibir carga reactiva, produciendo la compensación una considerable disminución de las pérdidas del sistema. El tamaño de los bancos es determinado por la

maximización del ahorro de energía tomando como variable de decisión el tamaño de los bancos. Mejoras a este trabajo fueron introducidas por Chis et al. en [CHI97], determinando las barras candidatas para compensación que producían directamente el mayor impacto en ahorro de energía de todo el sistema y por la optimización de los tamaños de los bancos basados en la maximización del ahorro de energía y el ahorro de energía pico. En adición, el método de [CHI97] también sirve para carga variable en el *EPS* considerado.

Más recientemente Carlisle y El-Keib [CAR00] encararon el problema por el método de la búsqueda en grafos utilizando (3.1), incluyendo en su formulación: costo y tamaño exacto de los capacitores, conmutación de capacitores y tamaño de los alimentadores. El método [CAR00] presenta la siguiente ventaja: El tiempo de conmutación de los capacitores puede ser diferente para cada capacitor de un mismo banco y es determinado por el mismo algoritmo y trabaja con valores discretos estándar. En contrapartida, por su alto costo de procesamiento, solo es aplicable a *EPSs* muy pequeños.

Por lo expuesto, los métodos heurísticos son intuitivos, fáciles de entender y de implementación simple al compararlos con métodos analíticos y numéricos. Sin embargo, el resultado obtenido con métodos heurísticos no tiene garantía de ser el óptimo global.

3.4 Métodos basados en Inteligencia Artificial

A pesar del éxito de los algoritmos descriptos en las secciones previas, una gran cantidad de problemas relativos a los *EPSs* aun permanecen sin poder ser resueltos completamente, en un sentido convencional. Debido a esto muchos

investigadores han volcado su atención a las nuevas técnicas basadas en la Inteligencia Artificial y han desarrollado sus aplicaciones en ingeniería de potencia. En particular: Sistemas Expertos (*KBS - Knowledge-Based Systems*), Templado Simulado (SA - *Simulated Annealing*), Redes Neuronales (*ANN - Artificial Neural Networks*), Teoría de Conjuntos Difusos (FST - *Fuzzy Set Theory*) y Algoritmos Genéticos (*GA - Genetic Algorithms*.) han sido implementados para resolver diversos problemas relativos a los *EPSs*.

3.4.1 Sistemas Expertos

La primera ves que los sistemas expertos fueron ampliamente estudiados fue a principios de la década de 1970 por Feigenbaum et al. [BUC78], [DIL90]. Los Sistemas Expertos consisten en una serie de reglas, hechos (conocimientos) y un motor de inferencia para simular el razonamiento lógico para resolver problemas que son tan complejos que requieren la pericia humana para su resolución. Las mayores ventajas de los *ES* [WAR97] son: a) son consistentes y estables; b) pueden ser fácilmente transformados o reproducidos y c) pueden ser fácilmente documentados. Su mayor desventaja es su dependencia del conocimiento previo sufriendo de inhabilidad para aprender o adaptarse a nuevas situaciones. En los pasados veinte años una gran cantidad de aplicaciones de *ES* han sido desarrolladas para ayudar a planear, analizar, manejar, controlar y operar varios aspectos de la generación, transmisión y distribución en los *EPSs* [BAN05]. Revisiones de las aplicaciones de los *ES* han sido presentadas en [ZHA89], [BAL92] y [CIG91]. Liu et al. han hecho considerable trabajo en la aplicación de los *ES* a los sistemas de

potencia [LIU93], [LIU94]. Un estudio reciente presentado en [BAN03b] indica que *ES* han sido aplicados a variadas áreas de los *EPSs*, incluyendo: sistemas de protección, control de voltaje y potencia, diagnóstico de fallas, estudios de planificación y calendarización [LIU92].

Salama et al. [LAF95], [SAL85a] desarrollaron un Sistema Experto que contenía Literatura Experta Técnica (*TLE* - *Technical Literature Expert*) y conocimientos de Expertos Humanos (*HE* - *Human Expert*) para el control de potencia reactiva en *EPSs*. El método *TLE* incluye la ubicación de capacitores de [SAL85a], [SAL85b] para el máximo ahorro de energía y energía pico. El *HE* componente de la base de datos contenía información que guiaba al usuario a conformar la solución del *RPC*, tanto en operación como en planificación.

3.4.2 Redes Neuronales

Una red neuronal esta constituida por neuronas artificiales interconectadas simulando el sistema nervioso del cerebro humano. Las *ANN* fueron utilizadas para mapear relaciones no lineales entre entradas y salidas de un sistema. El punto de partida de las *ANN* fue el algoritmo de entrenamiento propuesto por Hebb en 1949, el que demostró como una red de neuronas artificiales puede exhibir comportamiento de aprendizaje [WAS89]. Una *ANN* típica consiste en un árbol compuesto por niveles: el nivel de entrada, uno o más niveles medios y el nivel de salida. La *ANN* acepta datos de entrada conocidos y minimiza la diferencia entre los datos de salida generados y los datos de salida conocidos. Las relaciones entre los datos de entrada y salida son establecidas mediante parámetros en el nivel medio. Datos correctos de salida pueden ser generados

por una *ANN* provista de suficientes niveles medios y neuronas que permitan relacionar y codificar las relaciones entre los datos de entrada y salida y una base de conocimientos suficientes que permitan entrenarla. Una vez entrenada, la *ANN* puede generar muy rápidamente resultados partiendo de un conjunto de datos de entrada.

Las mayores ventajas de las *ANN* son [NIE96], [AGG97b], [AGG98a], [AGG98b]:

- su velocidad;
- habilidad de aprendizaje;
- adaptabilidad a los datos;
- su robustez;
- son apropiadas para modelos no lineales;

A pesar de sus apreciables ventajas sus desventajas son:

- gran dimensionalidad;
- dificultad en la selecciones de la configuración óptima;
- se debe elegir el método de entrenamiento;
- por su configuración de “caja negra” no hay explicaciones para los resultados.
- los resultados son siempre generados aún cuando los datos de entrada sea ilógicos.

Vankayala et al. [VAN93] han presentado una revisión bibliográfica de las redes neuronales y de sus aplicaciones a los *EPSs*. Las *ANN* han sido

aplicadas mayormente a las siguientes áreas de los sistemas de transmisión de potencia:

Planeamiento: previsión de carga a largo plazo [HIG93] y [PAR91], ubicación de capacitores y control de voltaje [SAN90], [SHO94], [SON97a], [ROY96] y [GU96].

Operación: despacho económico, asignación de unidades [KUM95], [DJU96], [FUK94], [SU97], [WAL97] y [KUL99] [KUL00].previsión a coro tiempo de carga [SIN01], [MOR01], [HIP01], [KRU00], [HSU91], [LAM96], [HO92], [PEN92], [CHA00a], [RAN95], y [SAF95], diagnostico de fallos [TAW01], [DAR01], [CHE00b], [SON97e] y [EBR90], flujo de potencia [CHA00b], asistencia para seguridad estática y dinámica [SOB89a], [GHO98], [SOB89b] y [NIB92], programación hídrica [NAR00], [MA96] , [LIA94] y [HSU95], estabilidad transitoria [DAI99], [LIU99a], [LIU99b], [HIY97], [KAR97], [ABO97], [CHA95], [MIR95], [MAR94] y [SHA94a].

Análisis: estabilización de *EPSs* [SHA00], [MAD00] y [MOG00].

Específicamente, para el *RCP* Santoso y Tan [SAN90] utilizaron *ANNs* para el control óptimo de conmutación de capacitores. En su trabajo, dos *ANNs* fueron utilizadas. Una para predecir el perfil de las carga desde un conjunto de valores de carga obtenidos de mediciones directas en varias barras y la segunda para seleccionar la óptima ubicación de los tap de los capacitores basándose en el perfil de las carga obtenido en la primera *ANN*. La primera *ANN* es entrenada con un conjunto de perfiles de carga pregravadas y la segunda es entrenada para maximizar la función de energía perdida para un nivel dado de carga. Una vez que ambas *ANN* son entrenadas, los cálculos

iterativos requeridos son cortos y soluciones rápidas son obtenidas para un conjunto de datos de entrada suministrados.

El algoritmo propuesto en [SAN90] fue probado con el Sistema Eléctrico de Potencia de Pruebas *IEEE* de 30 Barras (*IEEE 30 Bus Test System*) [CHR00] Para reducir la complejidad del entrenamiento, el sistema de prueba es dividido en seis subsistemas. Así, seis pares de *ANNs* fueron entrenadas dando soluciones satisfactorias. A pesar de que este método fuera aplicable a *EPSs* pequeños en tiempo-real, no es apropiado para *EPSs* de gran porte, debido a que se necesitaría particionarlos en numerosos subsistemas y el tiempo requerido para entrenamiento sería inmenso, según experiencias de los mismos autores. Gu y Rizy [GU96] siguiendo el método de [SAN90] incluyeron la función de control del regulador.

3.4.3 Teoría de Conjuntos Difusos

El concepto de *FST* fue introducido por Zadeh [ZAD65] en 1965 como una herramienta formal para lidiar con la incertidumbre y el error introducido en el modelado de sistemas y fue utilizado para resolver problemas relativos a los *EPSs* en 1979 [BAN05]. Las variables difusas son generadas por una función de membresía que asigna grados de membresía a un conjunto dado. Usualmente, los grados de membresía varían desde el cero (no miembro) hasta el uno (miembro).

Las ventajas de la teoría de conjuntos difusa son: a) representación más precisa de las restricciones en los *EPSs*, b) las restricciones de la teoría de lógica difusa son menos estrictas que las tradicionales [ZAD65] y [PAL91]. Una

introducción detallada al *FST* y a sus aplicaciones a los *EPSs* ha sido presentada en [SON97d], [SON98a] y [SON99B]. Momoh et al. hicieron una recopilación literaria de *FST* en [MOM95]. Una reseña más actual fue presentada en [BAN03a].

Con respecto a las aplicaciones del *FST* para el *RPC* se puede citar a Chin [CHI95a], quien utilizó *FST* asignando tres funciones de membresía para describir la potencia perdida, desviación de tensión en barras y distorsión armónica. La variable de decisión que determina las barras candidatas a recibir bancos de capacitores es calculada por la intersección de las tres funciones de membresía para cada barra del *EPS*. Las barras con valores de membresía mayores son seleccionadas para la instalación de bancos de capacitores. El trabajo [CHI95a] no explica formalmente cual es el método empleado para calcular el tamaño óptimo de los bancos asignados a las barras seleccionadas. Ng et al. [NG00] también aplicaron *FST* en el problema *RPC*, utilizando razonamiento difuso de aproximación. Tensiones y Pérdidas de Energía en barras son modelados por funciones de membresía, un Sistema Experto Difuso (*FES - Fuzzy Expert System*) contiene heurísticas que infieren en la determinación de un rango para las barras candidatas a compensación. Las barras con mayor rango son compensadas. Más recientemente, Vankatesh et al. en [VAN00] proponen resolver el problema de maximización del margen de estabilidad de tensión del *EPS* y la minimización de las pérdidas, como un enfoque multiobjetivo , sin embargo combinan ambos objetivos en una sola función objetivo por medio de la operación *unión* de la teoría de los conjuntos difusos [ZIM94] equivalente al operador lógico "*or*" .

Por lo expuesto, la gran ventaja de los métodos basados en *FST* radica en que pueden salvar incertezas contenidas en los datos suministrados del *EPS*.

3.4.4 Templado Simulado

El Templado Simulado es un algoritmo iterativo de optimización que se basa en el proceso de templado. Cuando un material se templa, es calentado hasta que alcanza una alta temperatura y luego es enfriado lentamente de acuerdo a un proceso de enfriamiento predefinido que permite obtener una configuración cristalina que cumple con determinados requisitos. Con elevadas temperaturas, las moléculas de los materiales se ubican en formaciones aleatorias. Cuando el material se enfría, las moléculas se organizan en formaciones que corresponden a estados de mínima energía interna. El *SA* ha sido utilizado en varias aplicaciones a los *EPSs*, por ejemplo, planeamiento de la expansión de las redes de transmisión [GAL97] y [ROM96], asignación de unidades [*ANN*95], [MEN98] y [YAN97], calendarización de trabajos de mantenimiento [SAT91], etc.

En el *RPC*, la función global de costos es formulada de modo a buscar el costo mínimo, de forma análoga a la función de energía que gobierna el proceso de templado, Ananthapadmanabha et al. [ANA96] utilizaron *SA* para minimizar la función de costos, S_{loss}, dada por:

$$S_{loss} = E_{pp} + E_p + CC_B \qquad (3.2)$$

donde E_{pp} es el costo de la energía pico pérdida, E_p es el costo de la energía perdida y CC_B es el costo de la instalación de bancos de capacitores.

3.4.5 Búsqueda Tabú.

La búsqueda Tabú (*TS - Tabú Search*) es un procedimiento de mejora iterativa que empieza con una solución inicial e intenta determinar una mejor solución en el vecindario factible de la solución inicial. La búsqueda tabú, incluye7 una memoria que almacena los últimos movimientos realizados, y que se usa para no volver a caer en los mismos mínimos locales, a esta memoria se le denomina lista tabú. Pero también tiene un método que permite escapar de los máximos locales, que se denomina nivel de aspiración; consiste en un criterio para aceptar movimientos incluidos en la lista tabú. Aparte de esa memoria, que se podría llamar a corto plazo, diversas variantes de la búsqueda tabú incluyen memorias a medio plazo, registrando los atributos más comunes de un conjunto de soluciones, para poder explotar esa zona del espacio de búsqueda, y a largo plazo, que diversifica la búsqueda sobre regiones que no se han explorado con anterioridad [GLO97] y [GLO93].

La búsqueda tabú ha sido usada en diferentes aplicaciones, y tiene diferentes variantes: por ejemplo, en la denominada búsqueda tabú con umbral se sigue primero una fase de intensificación (que correspondería a la explotación del espacio de soluciones), en la que solo se aceptan soluciones que aumentan el valor de la solución objetivo, seguida por una fase de diversificación (exploración), en la que se aceptan cualquier tipo de movimientos con el objetivo de escapar de los mínimos locales [GLO89] y [GLO90].

LA *TS* ha sido utilizada en varias aplicaciones a los *EPSs* como ser: planeación de transmisión [WEN97a], optima ubicación de capacitores [HUA96], [YAN95] y [GAN95a], asignación de unidades [MOR96], programación hidrotérmica [BAI96], diagnostico de fallas y procesamiento de alarmas [WEN97c] y [WEN97d], planeación de potencia reactiva [GAN95b], etc.

3.4.6 Optimización por Colonia de Hormigas (*ACO*)

Dorigo introdujo este algoritmo de optimización conocido inicialmente como *ACS* (*Ant Colony System*) [DOR92]. Estas técnicas toman su inspiración del comportamiento de búsqueda de alimentos de las hormigas reales, para resolver complejos problemas combinacionales. Algunas de sus principales características son el refuerzo positivo de las buenas soluciones y su alta capacidad de paralelización. A pesar de que este paradigma ha mostrado muy buenos resultados resolviendo problemas de alta complejidad [ALO04] en otras áreas son pocas las aplicaciones a los *EPSs* que se encuentran en la literatura técnica [BAN05]. Entre estas pocas aplicaciones se pueden encontrar: hallar la menor ruta para redes de transmisión [DOR96] y [SON98b], despacho económico de carga [YUN02], programación de generación a corto plazo [LIB04], flujo optimo de potencia [BOU05]. Específicamente, el *RPC* ha sido tratado en [LIN03] y en [GAR05] y [GAR06].

Debido a que el aporte de esta tesis consiste en una aplicación de este tipo de algoritmo al *RPC* una descripción detallada de la Optimización por Colonia de Hormiga se deja para el próximo capítulo, así como la correspondiente explicación del método propuesto.

3.4.7 Optimización por enjambres de partículas

Otra técnica que está inspirada en las reglas que siguen las manadas de animales, o las bandadas de pájaros es la llamada optimización por enjambres de partículas o *PSO* (*Particle Swarm Optimization*). Fue desarrollada por el Dr. Eberhart y Dr. Kennedy en 1995 [EBE95].

Esta técnica trata de representar las diferentes soluciones a un problema mediante "individuos" de una manada. Cada individuo tiene unas coordenadas en el espacio del problema, así como un valor de evaluación. Las partículas, tomando diferentes caminos, tratan de dirigirse hacia la mejor partícula del grupo, teniendo también en cuenta el mejor valor obtenido por las partículas en la vecindad de cada una. En el movimiento puede considerarse también una aceleración, que es un parámetro del método. Esta parece una técnica interesante para abordar problemas cuyos entornos que varíen en el tiempo, dado que la bandada puede adaptarse con facilidad a condiciones de entorno cambiantes (igual que, por ejemplo, una bandada se adapta a un obstáculo que encuentre por el camino).

Tampoco existen muchas referencias en la literatura técnica de aplicaciones de este algoritmo a los *EPSs*, esto puede deberse a la reciente creación del mismo. Algunas aplicaciones de *PSO* a los *EPSs* pueden ser encontradas en [ESM05] y [DUR05].

3.4.8 Algoritmos Genéticos

Los *GA* son técnicas inspiradas en la evolución biológica creadas para intentar descubrir una serie de puntos del espacio de búsqueda muy próximos

al óptimo. Son algoritmos de optimización de propósito general que se distinguen de las técnicas de optimización tradicionales por el uso del concepto de población genética para guiar el proceso de optimización. En lugar de la búsqueda de punto a punto de las técnicas tradicionales los *GA* realizan la búsqueda de población a población. Las ventajas de los *GA* sobre los algoritmos tradicionales son [BAN05]:

- solo necesita información de cómo evaluar la función objetivo en si y no presenta restricciones con respecto a la diferenciabilidad de la función objetivo.
- el método trabaja con un conjunto de soluciones en una generación para hallar el siguiente conjunto de soluciones y no con una única solución teniendo más habilidad para evitar estancarse en óptimos locales.
- debido al uso de la probabilidad como herramienta de búsqueda la elección de la población inicial influye pero no determina el resultado de la búsqueda.

Boone y Chiang [BOO93] desarrollaron un *GA* para determinar la ubicación y el tamaño óptimo de capacitores. El tamaño y la ubicación de los capacitores era codificado en cadenas binarias y la operación de cruzamiento generaba una nueva generación. Su formulación solo incluía el costo de los capacitores y la reducción de la energía pico pérdida. Sundhararajan y Pahwa [SUN94] también utilizaron un *GA* para la óptima selección de capacitores en sistemas de distribución. Sin embargo su trabajo difiere de [BOO93] en que utilizan una

estrategia elitista; no pasando por cruzamiento y mutación los parámetros elegidos en forma elitista. Además, su formulación incluye la reducción de la energía perdida omitida en [BOO93]. Miu et al. [MIU97] revisaron la formulación de [BOO93] e incluyeron además funciones de reemplazo y control de capacitores para sistemas desbalanceados. Wu y Ma [WU95] plantean resolver el despacho óptimo de potencia reactiva (*ORDP* - *Optimal Reactive Power Dispatch*). Ma y Lai [MA95] resuelven el ORDP tomando la carga y la tensión en el *EPS* estáticos en un intervalo de tiempo, siendo sus formulación similar a [BOO93], incluyendo además el control de los taps de los transformadores, la tensión de las barras de generación y la conmutación de los bancos de capacitores. Levitin et al. [LEV00] calcularon la energía perdida total por medio de estudios estadísticos de las curvas diarias de carga, considerándolas, a diferencia de los trabajos anteriores, como curvas estadísticas y no como funciones lineales. Delfanti et al. [DEL00] combinaron técnicas determinísticas con *GA* tomando como variables continuas las tensiones de barra, los taps de los transformadores y la generación de potencia reactiva en las barras PQ y como variables discretas la ubicación y tamaño de los capacitores, siendo su formulación similar a la de Boone y Chiang [BOO93]. La combinación de métodos determinísticos con *GA* reduce el tiempo necesario para hallar soluciones próximas a la óptima global. Barán et al. [BAR01a], [BAR01b] y [BAR01c] utilizando la formulación de [SUN94] plantean el *RPC* como un problema multiobjetivo, minimizando en forma simultánea la energía pico pérdida, el costo de los capacitores, el desvío promedio de tensión y el desvío máximo de tensión como funciones objetivo independientes. Como ya se

explicó en el capítulo anterior esto da como resultado con conjunto de soluciones de compromiso, donde ninguna solución es mejor que las demás.

Alander presenta en [ALA96] una bibliografía de las aplicaciones de los *GA* a los sistemas eléctricos de potencia. Entre estas aplicaciones se pueden citar:

- En la etapa de planeamiento: planeamiento de la expansión de transmisión [SIL00], [HUG96], [YEH96], [PAR00], [NAR91] y [MIR94], ubicación de capacitores [DEL00] y [SUN94].

- En la etapa de operación: control de voltaje y potencia reactiva [HAI91], [YOK93] y [IBA94] asignación de unidades y despacho económico [KAZ96], [SON97b], [CHE00a], [RIC00], [ALD01] y [VEN01], programación hidrotérmica [CHA96], [ORE96] y [ORE98].

3.5 Técnicas híbridas de Inteligencia Artificial.

Los verdaderos problemas de los *EPSs* pueden ser demasiado complejos para un paradigma en particular, debido a esto muchos investigadores han decidido integrar dos o más técnicas para lidiar con esta complejidad [WAR97]. Con la utilización de estas técnicas híbridas se espera que las ventajas de unos métodos solucionen las debilidades de los otros. La tabla 3.1 resume algunas aplicaciones de estos métodos híbridos a los *EPSs*:

Técnica Híbrida:	**Área de aplicación a los *EPSs***
Lógica difusa y sistemas de redes neurales	Generación y distribución [AGG97c], diagnostico de fallas [AGG97a], previsión de carga [SRI94] y [BAK95], control de potencia reactiva [LIU98] y [ELI00], programación de mantenimiento de generadores [WAN92].
Lógica difusa y algoritmos genéticos	Estabilidad [LAK88], control [WEN97b] y [CHA98], despacho económico de carga [SON97c].
Lógica difusa y sistemas expertos	Planeación [DAV91].
Lógica difusa con sistemas neuronales y expertos y algoritmos genéticos	Previsión de carga [DAS96] y [KIM95], planeación de la expansión de generación [PAR97], estabilización de sistemas eléctricos de potencia [AFZ00].
Templado simulado con lógica difusa, algoritmos genéticos y sistemas expertos	Planeamiento de potencia reactiva [JWO95], programación de mantenimiento de generadores [WON96], [WON97] y [KIM94].
Algoritmos genéticos con templado simulado, y optimización local	Compensación de Potencia Reactiva [BAR01a], [BAR01b], [BAR01c].

Tabla 3.1: Resumen de aplicaciones de métodos híbridos de *AI* a los *EPSs*.

Capitulo 4

Aplicación del SPEA al RPC

El término Algoritmo Evolutivo *EA* (*Evolutionary Algorithm*) se refiere a técnicas de búsqueda y optimización inspiradas en el modelo de la evolución propuesto por Charles Darwin [DAR85].

Los *EAs* son particularmente prácticos para resolver *MOPs*, debido a que lidian simultáneamente con un conjunto de posibles soluciones, comúnmente llamadas población *Pop*. Por este motivo permiten hallar varias soluciones miembros de P_{true} en una sola corrida del algoritmo, en vez de tener que correr tantas veces el algoritmo como soluciones de P_{true} se quieran obtener, como es el caso de las tradicionales técnicas matemáticas de programación [COE99]. Adicionalmente, los *EA* son menos susceptibles a posibles discontinuidades o concavidades que se puedan presentar en los distintos P_{true}. Incluso, algunos investigadores han sugerido que los *EA* se comportarían mejor que otras técnicas de búsqueda ciega [FON95a] y [FON95b].

4.1 Algoritmos Genéticos

Aproximadamente desde mediados de la década del 70, en el ámbito de los *EA*, se han introducido numerosos algoritmos que se pueden clasificar principalmente como Algoritmos Genéticos *GA*, Programación Evolutiva *EP* (*Evolutionary Programming*) , Estrategias de Evolución *EvS* (*Evolutionary Strategy*), Sistemas Clasificadores *CS* (*Classificatory System*) y Programación Genética *GP* (*Genetic Programming*) [HEI00]. A pesar de que el principio que

los soporta es, en apariencia, muy simple, estos algoritmos han probado ser herramientas generales, robustas y potentes [HEI00].

Los *GAs* son métodos computacionales de búsqueda basados en los mecanismos de la evolución natural y en la genética [GOL89]. De manera general la evolución natural implementa mecanismos adaptativos de evolución que, lejos de ser una búsqueda aleatoria, utilizan la aleatoriedad como herramienta de búsqueda, lo cual no significa que sea una búsqueda no dirigida.

A finales del siglo XIX, Charles Darwin ya tenía formulada la Teoría de la Evolución de las Especies [DAR85], pero solo a partir de la década de los 60 John Holland, sus colegas y estudiantes de la Universidad de Michigan comenzaron a definir las bases de los algoritmos de optimización de inspiración evolutiva genética en [HOL75], y es así que en los *GAs*, una población de posibles soluciones para un problema en cuestión evoluciona según operadores probabilística concebidos a partir de metáforas biológicas, de modo que, en promedio, los individuos tiendan a representar soluciones cada vez mejores en la medida que el proceso de evolución continúa.

4.1.1 Representación Cromosómica (Allele)

El primer paso para la aplicación de los *GAs* a un problema consiste en representar cada posible solución del espacio de búsqueda como una secuencia de símbolos *sym*, generados a partir de un alfabeto finito A_f [TAN95]. En el caso más simple, se utiliza el alfabeto binario $A_b = \{0,1\}$

Usando algunas de las metáforas extremadamente simplistas, cada secuencia *sym* corresponde a un cromosoma o allele y cada elemento de *sym* es equivalente a un gen. Como cada gen puede asumir cualquier valor del alfabeto A_f, cada elemento de A_f constituye un alelo, o sea un posible valor de un gen. La posición de un gen en el allele, el índice dentro de la secuencia, corresponde a un locus genético.

Además, en la generalidad de los *GAs*, se asume que cada individuo está constituido por un allele. También se utiliza una población de número fijo de individuos, con alleles de tamaño constante.

A pesar de que se han realizado numerosas investigaciones [HEI00] sobre codificación usando cadenas de longitud variable y aún otras estructuras, gran parte del trabajo con algoritmos genéticos se enfoca en cadenas de bits de longitud fija. Justamente el hecho de utilizar cadenas de longitud fija y la necesidad que existe de codificar las posibles soluciones son las dos características cruciales que diferencian a los algoritmos genéticos de la programación genética, que no posee representación de longitud fija y que normalmente no utiliza una codificación del problema y sus soluciones.

4.1.2 Evaluación y adecuabilidad

Los *GAs* necesitan información sobre el valor de una función objetivo para cada miembro de la población, que debe ser un valor positivo. En los casos más simples, se utiliza el valor de la función que se optimiza. La función objetivo da para cada individuo, una buena medida de su adaptación al ambiente en el que se encuentra, en el caso de la maximización de una función

objetivo, cuanto mayor es el valor de la función objetivo, mayores son las oportunidades del individuo de sobrevivir en el ambiente y reproducirse, pasando parte de su material genético a generaciones posteriores [TAN95].

La evaluación de cada individuo se conoce como *fitness* o adecuabilidad y representa que tan bien adaptado a su medio está el individuo.

4.1.3 Ciclo de Trabajo

El ciclo de trabajo de un *GA* (también conocido como ciclo generacional) consiste generalmente en: calcular el *fitness* de los individuos en la población; crear una nueva población mediante selección, cruzamiento y mutación; y, finalmente, descartar la población vieja y seguir iterando utilizando la población recién creada. A cada iteración de este ciclo se la conoce como una generación.

4.1.4 Inicialización

Normalmente la población inicial de *N* individuos es generada en forma aleatoria, o por medio de algún proceso heurístico. [TAN95].

Como en el caso biológico, no hay evolución sin variedad, ya que la selección natural o ley del más fuerte exige que los individuos tengan diferentes grados de adaptación al ambiente en que viven, por eso es importante que la población inicial cubra la mayor área posible del espacio de búsqueda.

4.1.5 Selección

El mecanismo de selección en los *GAs* emula los procesos de reproducción asexuada y selección natural. En general, se genera una población temporal de *N* individuos con probabilidad de selección proporcional a la adecuabilidad relativa de cada individuo en la población y viene dada por:

$$p_{sel} = \frac{a(S)}{\sum_{i=1}^{N} a(S_i)} \tag{4.1}$$

donde *a* es la función de adecuabilidad.

Utilizando la probabilidad P_{sel}, se seleccionan *N* individuos. En este proceso, individuos con bajo *fitness* tendrán elevada probabilidad de ser extintos de la población, a la vez que individuos de elevado *fitness* tendrán gran probabilidad de sobrevivir. Este método es conocido normalmente como la *Ruleta* [TAN95].

4.1.6 Cruzamiento

El proceso de cruzamiento es sexuado, o sea que, envuelve a más de un individuo emulando el fenómeno de cruzamiento, que realiza el intercambio de fragmentos entre pares de cromosomas En la forma más simple, se trata de un proceso aleatorio que ocurre con una probabilidad fija P_c, especificada por el programador.

4.1.7 Mutación

El proceso de mutación en *GA* es equivalente a una búsqueda aleatoria. Básicamente, se selecciona una posición en un cromosoma y se cambia el valor del gen correspondiente aleatoriamente para otro alelo posible. El

proceso es generalmente controlado por un parámetro fijo P_m que indica la probabilidad que tiene un gen de sufrir mutación [GOL89] y [TAN95].

4.1.8 Condiciones de Término

Tratándose de problemas de optimización, lo ideal sería que el algoritmo termine su ejecución una vez que encuentre el punto óptimo. En el caso de funciones multimodales, un punto óptimo puede ser suficiente, toda vez que sea uno de los óptimos globales [TAN95]. En la práctica el algoritmo termina su ciclo de trabajo cuando se cumple algún criterio conmensurable como ser el número máximo de ciclos generacionales o número máximo de ciclos sin mejora del frente Pareto.

4.2 SPEA

El Algoritmo Evolutivo de la Fuerza Pareto *SPEA* (*Strength Pareto Evolutionary Algorithm*) propuesto por Zitzler et al. en [ZIT99] representa uno de los *MOEAs* (*Multiobjective Evolutionary Algorithms*) más promisorios, ya que su planteamiento cumple con la hipótesis del *Teorema de Convergencia* de *MOEAs* presentado por Van Veldhuizen en [VAN97].

A pesar de su novedad, Zitzler et al. han identificado algunos puntos débiles en su formulación, presentando una segunda versión del mismo llamado *SPEA*2 [ZIT01b]. Sin embargo esta segunda versión aún no ha sido implementada al *RPC* por lo que se optó por utilizar al *SPEA* como algoritmo de prueba del método propuesto en el presente trabajo.

EL *SPEA* usa una mezcla de técnicas previamente usadas y otras recién establecidas para encontrar soluciones Pareto-óptimo diferentes y en paralelo. Las características principales del *SPEA* son las siguientes:

- guarda las soluciones Pareto-óptimo que ha encontrado hasta el momento en una población externa, de esta manera implementa elitismo;
- usa el concepto de dominancia Pareto, para asignar un valor de *fitness* a los individuos;
- realiza agrupaciones [MOR80] o clustering para reducir el número de soluciones Pareto-óptimo que tiene almacenadas, tratando de no destruir las características del Frente Pareto-óptimo delineado hasta el momento.

Esencialmente, la diferencia entre el *SPEA* y el *GA* tradicional radica en la asignación de *fitness* y el mantenimiento de una población externa de soluciones Pareto-óptimo encontradas hasta ese momento de los cálculos, población que recibe el nombre de P_{known} o conjunto Pareto-óptimo conocido.

Los operadores genéticos pueden ser los tradicionales o cualesquiera sean apropiados para la resolución del *MOP*. El valor del tamaño máximo de la población externa, *NP*, se define previamente y sirve además para la decisión de la aplicación del proceso agrupador, que permite controlar el tamaño de la población externa.

La selección se realiza en toda la unión de los dos conjuntos *Pop* y P_{known}, hasta que se obtiene la cantidad de padres deseada, en este caso esta cantidad es *N*, o sea, el tamaño de la población corriente.

El procedimiento de asignación de *fitness*, así como la reducción del conjunto P_{known} utilizando un proceso agrupador se especifican en las siguientes secciones.

El proceso de inicialización de la población *Pop* se refiere a la lectura de la población inicial aleatoriamente generada.

El criterio de parada que se aplican al *SPEA* es la cantidad máxima de generaciones.

4.2.1 Procedimiento para asignar *fitness* a los individuos

Una de las particularidades del *SPEA* es su forma de asignar *fitness* a cada individuo. El proceso se realiza de modo a lograr que los individuos dominantes y más representativos tengan mejores valores de *fitness*. A la vez, el proceso está pensado para inducir la diversidad genética y obtener soluciones distribuidas en todo el Frente Pareto-óptimo

Para ello, el procedimiento de asignación de *fitness* se realiza en dos fases. Primero, se asigna un rango a los individuos del conjunto P_{known}. Luego, se evalúan a los miembros de *Pop*.

Para asignar *fitness* a los miembros de P_{known}., a cada solución $x_i \in P_{known}$. se le asigna un valor real $s_i \in (0,1)$, llamado fuerza (*strength*), término tomado de [HOR97], donde fue introducido en el contexto de sistemas clasificadores, se refiere a una cantidad que resume la utilidad de la regla. Aquí refleja la utilidad de una solución Pareto-óptimo. Donde s_i es proporcional al número de individuos $x_j \in Pop$ dominados o iguales a x_i. Sea n_i el número de individuos en

Pop que están dominados por x_i, y asumiendo que *N* es el tamaño de *Pop*. Luego s_i se define como:

$$s_i = \frac{n_i}{N+1} \quad , \quad s_i \in (0,1) \tag{4.2}$$

El *fitness* de x_i es igual a la inversa de su fuerza: $a_i = \frac{1}{s_i}$.

La fuerza de un individuo x_j perteneciente al conjunto *Pop* se calcula así:

$$s_j = \sum s_i \ \ (\forall i \mid x_i \succ x_j \vee x_i = x_j) \ , \ s_j \in [0, N) \tag{4.3}$$

Es decir, el *strength* de un miembro de la población evolutiva *Pop*, x_j, se halla sumando el *strength* de todos los individuos de P_{known} que dominan a x_j, se suma 1 este valor para asegurar que los miembros de P_{known} tengan mejor fuerza que los miembros de *Pop*. Así el *fitness* del individuo x_j se expresa como:

$$a_j = \frac{1}{1+s_j} \quad , \quad a_j \in (\frac{1}{N+1} \ , \ 1] \tag{4.4}$$

La idea detrás de este mecanismo es preferir siempre los individuos que están más cerca del Frente Pareto-óptimo y al mismo tiempo, distribuirlos en toda la superficie factible. La principal diferencia con el *fitness* compartido es que los nichos se definen en términos de la dominancia Pareto, y no en términos de distancia. Esto es más adecuado ya que en los problemas de la vida real la distancia no tiene un significado práctico si se computa en el espacio objetivo, ya que cada objetivo puede estar expresado en magnitudes totalmente diferentes y no comparables a las de los demás, como ser miles de dólares y Voltios. Al mismo tiempo, como los individuos no-dominados que dominan a una menor cantidad de individuos de *Pop*, tienen un *fitness* mayor,

se ejerce una presión de selección positiva hacia nuevas zonas del dominio, ya que tendrán una probabilidad mayor de ser seleccionados [ZIT99].

4.2.2 Reducción del conjunto Pareto-óptimo utilizando un proceso agrupador

En algunos problemas, el conjunto Pareto-óptimo puede ser muy grande o contener incluso un número infinito de soluciones. Sin embargo, desde el punto de vista del diseñador, obtener todas las soluciones Pareto-óptimo encontradas no agrega ventajas, una vez que se alcanzó un límite razonable.

Más aún, el tamaño de la población externa de soluciones Pareto-óptimas altera el comportamiento del *SPEA* [ZIT99]. Esto es evidente si se observa con más detenimiento el procedimiento de asignación de *fitness* que el algoritmo utiliza. Cuando el conjunto de soluciones Pareto-óptimo crece por encima de un límite impuesto, el algoritmo ya no encuentra buenas soluciones y además tiene mayor probabilidad de estancarse en un conjunto Pareto-óptimo local, debido a que la población resultado de los operadores genéticos pierde importancia al tener en promedio menor *fitness* y número menor que la población Pareto-óptimo. Por estas razones, purgar el conjunto Pareto-óptimo no solo puede ser necesario sino incluso obligatorio.

Un método que se ha aplicado a este problema con éxito relativo y se ha estudiado extensivamente en el mismo contexto es el análisis de agrupaciones (*cluster analysis*) [MOR80]. En general un proceso de análisis de agrupaciones particiona una colección de p elementos en q grupos de elementos

homogéneos, donde q < p. De cada grupo se escoge luego un elemento representativo o centroide de la agrupación.

El Método de Enlace Promedio ALM (*Average Linkage Method*) [MOR80], ha demostrado un comportamiento adecuado en este problema y fue escogido por Zitzler et al. en [ZIT99] para el *SPEA*. Por ello, es también el método que se utiliza en [BAR01a], [BAR01b], [BAR01c] y [VAL02], para controlar el tamaño de la población externa del *SPEA* tratando de no perder soluciones buenas y significativas ya identificadas. El procedimiento se expresa en el pseudocódigo siguiente [ZIT99]:

4.2.3 Procedimiento ALM

1. Inicializar el conjunto de agrupaciones C_a; cada individuo $x_i \in P_{known}$ constituye una agrupación distinta. Así: $C_a = V_i \{\{x_i\}\} = NP$.
2. Mientras $C_a > NP$ ir a 3, sino a 5.
3. Calcular la distancia de todos los posibles pares de agrupaciones. La distancia d_{ij} de dos pares de agrupaciones c_i y $c_j \in C_a$ es la distancia promedio entre pares de individuos de las dos agrupaciones;

$$d_{ij} = \frac{1}{|c_i| \cdot |c_j|} \sum_{x_i \in c_i, x_j \in c_j} \| F(x_i) - F(x_j) \| \qquad (4.5)$$

donde la métrica ||.|| refleja la distancia entre dos individuos x_i y x_j, en los estudios realizados por Barán et al. se utilizo una métrica Euclidiana sobre el espacio objetivo conocida como norma 2, $||.||_2$.

4. Determinar dos agrupaciones c_i y c_j con distancia mínima d_{ij}; las agrupaciones escogidas se unen para conformar una sola agrupación, luego ir a 2.
5. Computar el conjunto P_{known} reducido, seleccionando un individuo representativo de cada agrupación *c*. Se considera el centroide, el punto con distancia promedio mínima con respecto a todos los otros puntos del cluster, como la solución representativa.

Hasta aquí se ha descrito al *SPEA* en forma genérica como fue implementado por Zitzler et al., a partir de aquí se describen las modificaciones hechas en la aplicación del *SPEA* al *RPC* por Barán et al. [BAR01a], [BAR01b] y [BAR01c]

4.2.4 Generación heurística de la población inicial

La población inicial es generada heurísticamente, con la finalidad de obtener individuos eléctricamente bien compensados que permitan acelerar la convergencia del algoritmo.

El método se basa en favorecer la compensación en barras con elevado número de líneas y bajo perfil de tensión. Este método puede resumirse en los siguientes pasos:

1. Escoger B_{tot}: cantidad total máxima de compensación a ser aplicada al *EPS*.
2. Para cada barra *i* del *EPS*, calcular el factor K_i utilizando la siguiente expresión:

$$K_i = \begin{cases} (V_i - V_i^*) l_i & si \quad V_i < V_i^* \\ 0 & si \quad V_i \geq V_i^* \end{cases} \tag{4.6}$$

donde l_i representa el número de líneas asociado a la barra *i*. K_i = 0 significa que no se asignará heurísticamente compensación de potencia reactiva en la barra *i*.

3. Normalizar K_i utilizando:

$$K_i' = \frac{K_i}{\sum_{i=1}^{n} K_i} \tag{4.7}$$

4. Compensar cada barra *i* con b_i calculado por:

$$b_i = K_i' B_{tot} \tag{4.8}$$

4.2.5 Dos poblaciones externas

Si solamente se emplea una sola población externa, es posible que: para guardar todas las soluciones Pareto-óptimo encontradas, P_{known} resulte demasiado numerosa y que la población evolucionaria, *Pop*, pierda importancia en el proceso de búsqueda, cuando se apliquen los operadores genéticos sobre *Pop* + P_{known} (unión multiconjunto); se pierdan soluciones Pareto-óptimo encontradas al aplicar ALM para mantener fijo el tamaño de P_{known}.

En el método propuesto por Barán et al., dos poblaciones externas son guardadas, una con tamaño fijo mediante la aplicación de ALM y que participa en los procesos de evolución P_{known} y otra que guarda todas las soluciones Pareto-óptimo encontradas SP_{known}. De esta manera, P_{known} no disminuye la influencia de la población evolutiva *Pop* y no se pierden soluciones Pareto-

óptimo encontradas. Además, la población SP_{known} puede ser guardada en disco duro, ya que no participa en el proceso evolutivo.

4.2.6 Operadores genéticos

Barán et al. no utilizaron los operadores genéticos empleados por Ziztler et al. en su original propuesta *SPEA* [ZIT98], [ZIT99] y [ZIT01a]. En cambio, propusieron los siguientes operadores:

- Selección

El método empleado por Barán et al. utiliza la *Ruleta* como operador de selección. Este operador devuelve una población de individuos seleccionados en forma aleatoria constituida en su mayoría por individuos de elevado *fitness*.

- Cruzamiento

El operador de cruzamiento empleado toma un par de individuos de la población de individuos seleccionados, aleatoriamente, luego parte en tres secciones de longitudes aleatorias cada allele e intercambia entre ellos las secciones del medio. Este operador recibe el nombre de operador cruzamiento de dos puntos y requiere de la definición del parámetro P_c que define la proporción de individuos de la población de individuos seleccionados (*mating pool*) que serán sometidos a cruzamiento.

- Mutación

El método propuesto por Barán et al. ha implementado la mutación múltiple, que se basa en que cada gen tiene la probabilidad P_m de mutar, esto a

cada allele se le puede asignar un valor de compensación distinto al que tiene. El valor de P_m debe ser elegido apropiadamente pues valores muy pequeños o muy elevados provocarían efectos no deseados [VAL02].

Cabe destacar que Zitzler et al. [ZIT99] no utilizaron el operador mutación, debido a la naturaleza de los problemas de prueba que resolvieron.

4.2.7 Optimizador local

Esta técnica heurística fue especialmente diseñada para mejorar configuraciones de compensación. Se basa en una adecuada búsqueda direccionada por la expresión del flujo de potencia [KUN93]:

$$\begin{bmatrix} \Delta P \\ \Delta Q \end{bmatrix} = \begin{bmatrix} J_1 & J_2 \\ J_3 & J_4 \end{bmatrix} \cdot \begin{bmatrix} \Delta \theta \\ \Delta V \end{bmatrix} \tag{4.9}$$

de donde se obtiene:

$$\Delta Q = J_3 \Delta \delta + J_4 \Delta V \tag{4.10}$$

Partiendo de (4.10) y despreciando J_3 y los elementos no diagonales en J_4 se llega a la siguiente expresión:

$$\Delta Q_i \approx J_{ii} \Delta V_i \tag{4.11}$$

donde ΔQ_i es la variación de carga reactiva de la barra *i*, numéricamente igual a la variación de compensación necesaria en dicha barra, es así que la nueva configuración de compensación del sistema estará dada por:

$$b_i^{gen+1} = b_i^{gen} + \Delta Q_i^{gen} \tag{4.12}$$

para cada ciclo generacional *gen*.

4.2.8 Enfriado

Inspirado en el templado simulado *SA*, la probabilidad P_{lo} de aplicar el optimizador local se va reduciendo generación a generación de modo a asegurar la convergencia hacia P_{true} aplicando la siguiente fórmula:

$$P_{lo} = w_{lo} \times e^{-\left(\frac{gen}{gen^m}\right)} \tag{4.13}$$

donde $0 \leq P_{lo} \leq 1$ es la proporción de la población a la cual se aplicará el optimizador local en el ciclo generacional *gen*; w_{lo} es el máximo valor que puede tomar P_{lo} y gen^m es el número máximo de ciclos generacionales.

4.2.9 Verificación de la factibilidad

Las soluciones generadas tanto heurística como genéticamente, que representan una determinada topología de compensadores, pueden ser soluciones factibles o no. Debido a esto se realiza la verificación de factibilidad evaluando primero el *LF* y posteriormente, solo si la solución es factible, se hace el estudio de dominancia Pareto.

4.2.10 Criterio de Parada

Se definieron dos criterios de parada. La computación es parada cuando no son encontradas nuevas soluciones Pareto-óptimo en un número de generaciones determinado. El segundo criterio detiene el proceso cuando se llega al número máximo de generaciones determinado gen^m.

El diagrama de flujo del método propuesto por Barán et al. se aprecia a continuación en la figura 4.1 [VAL02].

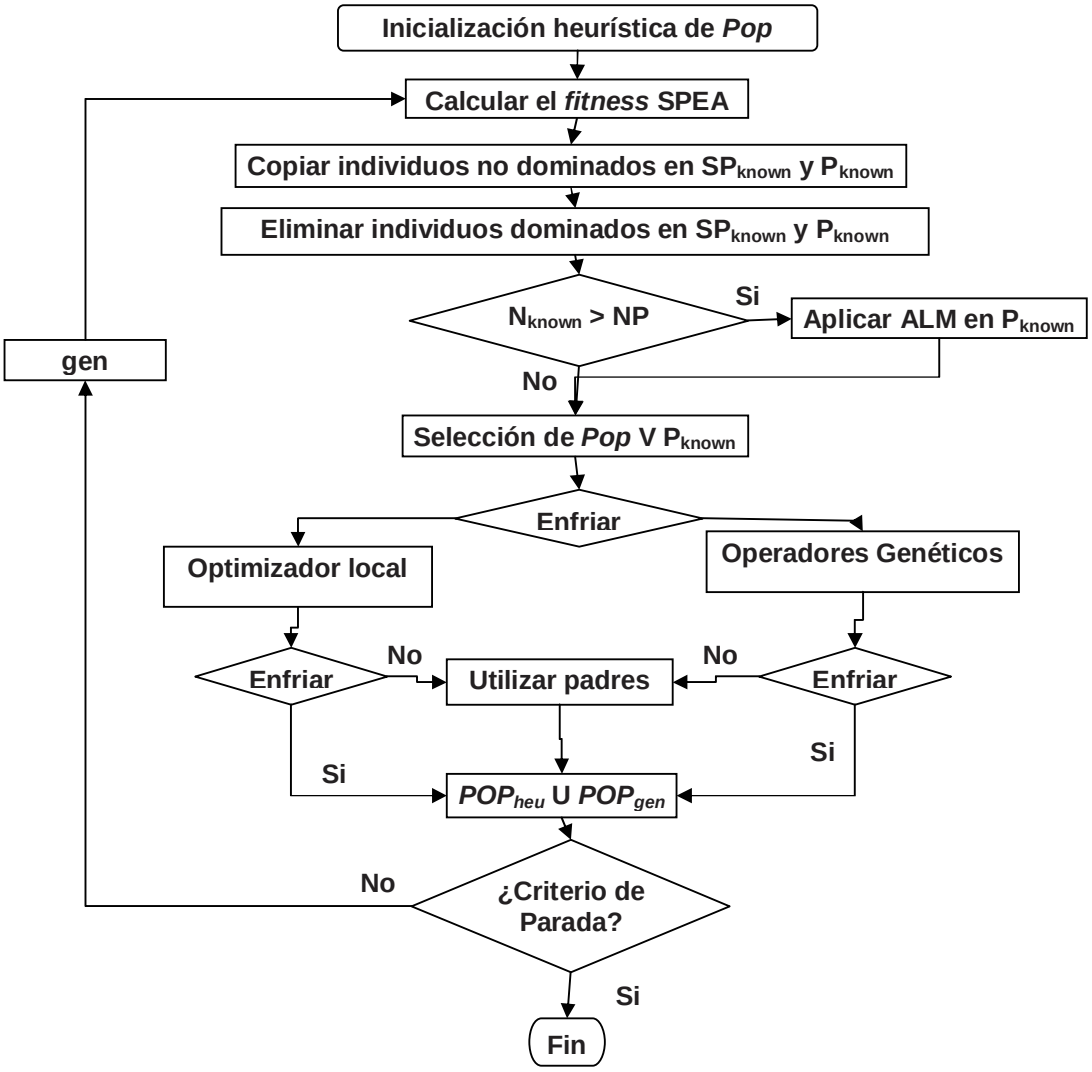

Figura 4.1: Diagrama de flujo del *SPEA* con las modificaciones hechas por Barán et al.

4.2.11 Resumen

El método propuesto por Barán et al. puede resumirse en los siguientes pasos:

1. Generar la población inicial *Pop* utilizando el método heurístico previamente descrito y crear dos nuevos conjuntos externos de soluciones Pareto-óptimas: P_{known} y SP_{known}.

2. Copiar todas las soluciones no dominadas de *Pop* en P_{known} y SP_{known}.
3. Remover soluciones de P_{known} y SP_{known} dominadas por otras soluciones de SP_{known}.
4. Si el número de soluciones de P_{known} excede *NP*, aplicar *ALM* para reducirla.
5. Calcular el *fitness* para cada individuo de *Pop* utilizando el procedimiento de asignación de *fitness* del *SPEA*.
6. Seleccionar individuos de *Pop* + P_{known} (unión multiconjunto) por medio de la *Ruleta* para formar el conjunto de parejas.
7. Aplicar P_{lo}, P_c y P_m para determinar que individuos serán optimizados localmente o seleccionados para cruzamiento y mutación. Aplicar el optimizador local y los operadores genéticos cruzamiento y mutación.
8. Si las nuevas soluciones no son factibles reemplazarlas por las soluciones seleccionadas en el punto 7.
9. Si no se cumple el criterio de parada volver a 2.

Capítulo 5

Colonia de Hormigas

Introducción

En este capítulo se presentan los conceptos básicos de la Optimización basada en Colonia de Hormigas (*ACO - Ant Colony Optimization*), así como los algoritmos propuestos, basados en este método, para el problema de Compensación de Potencia Reactiva. Posteriormente se describe al método propuesto en este trabajo, el *Ómicron Eléctrico OE*, resaltando sus innovaciones.

El presente capítulo queda organizado de la siguiente manera: en la Sección 5.1 se explica el comportamiento de las hormigas reales en la búsqueda de alimentos. Posteriormente, en la Sección 5.2 se presenta la Optimización basada en Colonia de Hormigas y en la Sección 5.3 el enfoque típico de *ACO* es dado. La descripción del *Ómicron ACO* se presenta en la Sección 5.4. Finalmente en la Sección 5.5 se detalla el *Ómicron Eléctrico OE* propuesto en este trabajo.

5.1 Comportamiento de búsqueda de alimentos de las hormigas reales

Las hormigas son insectos sociales que viven en colonias y que, debido a su colaboración mutua, son capaces de mostrar comportamientos complejos y realizar tareas difíciles desde el punto de vista de una hormiga individual. Un aspecto interesante del comportamiento de muchas especies de hormigas es su habilidad para encontrar los caminos más cortos entre su hormiguero y las

fuentes de alimento. Este hecho es especialmente interesante si se tiene en cuenta que muchas de las especies de hormigas son casi ciegas, lo que evita el uso de pistas visuales [DOR92].

Mientras que se mueven entre el hormiguero y la fuente de alimento, algunas especies de hormigas depositan una sustancia química denominada *feromona* (una sustancia que puede "olerse"). Si no se encuentra ningún rastro de feromona, las hormigas se mueven de manera básicamente aleatoria, pero cuando existe feromona depositada, tienen mayor tendencia a seguir el rastro. De hecho, los experimentos realizados por biólogos han demostrado que las hormigas prefieren de manera probabilística los caminos marcados con una concentración superior de feromona [ALO04]. En la práctica, la elección entre distintos caminos toma lugar cuando varios caminos se cruzan. Entonces, las hormigas eligen el camino a seguir con una decisión probabilística sesgada por la cantidad de feromona: cuanto más fuerte es el rastro de feromona, mayor es la probabilidad de elegirlo. Puesto que las hormigas depositan feromona en el camino que siguen, este comportamiento lleva a un proceso de retroalimentación que concluye con la formación de rastros señalados por una concentración de feromona elevada. Este comportamiento permite además a las hormigas encontrar los caminos más cortos entre su hormiguero y la fuente del alimento [ALO04]. Nótese que las hormigas solo se comunican de manera indirecta, a través de modificaciones del espacio físico que perciben. Esta forma de comunicación se denomina *Estimergia Artificial* [ALO04].

Como se ilustra en la Figura 5.1 este mecanismo permite a las hormigas encontrar el camino más corto. Supongamos que inicialmente todas las hormigas siguen el camino directo entre el nido y la fuente de alimento. Si algún obstáculo es puesto en ese camino directo, las hormigas eligen aleatoriamente cualquier camino. Según transcurre el tiempo y mientras que las hormigas están recorriendo los caminos más prometedores, estos van recibiendo una cantidad superior de feromona. Esto ocurre gracias a que al ser los caminos más cortos, las hormigas que los siguen consiguen encontrar la comida más rápidamente, por lo que comienzan su viaje de retorno antes. Entonces, en el camino más corto habrá un rastro de feromona ligeramente superior y, por lo tanto, las decisiones de las siguientes hormigas estarán dirigidas en mayor medida a dicho camino. Además, este camino recibirá una proporción mayor de feromona por las hormigas que vuelven por él que por las que vuelven por el camino más largo. Este proceso finaliza haciendo que la probabilidad de que una hormiga escoja el camino más corto aumente progresivamente y que al final el recorrido de la colonia converja al más corto de todos los caminos posibles.

Esta convergencia se complementa con la acción del entorno natural que provoca que la feromona se evapore transcurrido un cierto tiempo. Así, los caminos menos prometedores pierden progresivamente feromona porque son visitados cada vez por menos hormigas [ALO04].

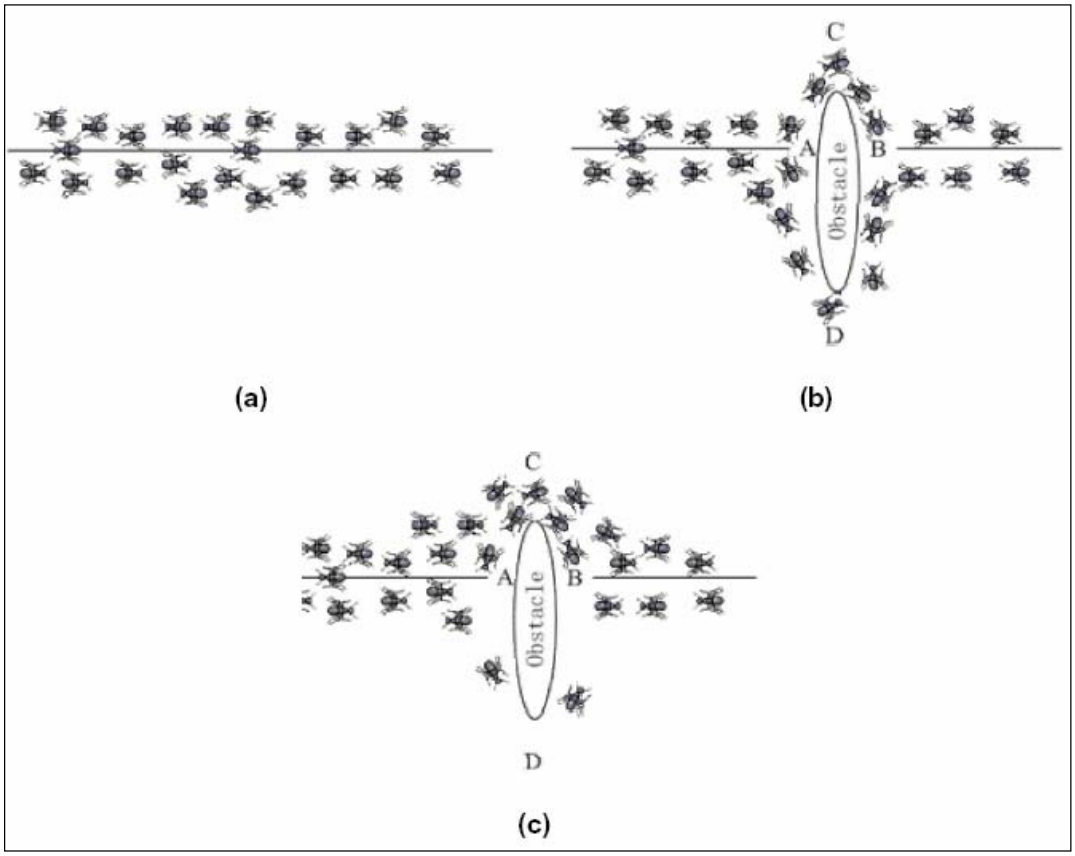

Figura 5.1. Comportamiento de las hormigas en la búsqueda de su alimento entre el nido y su fuente de alimentación. (a) Todas las hormigas van por el camino más corto, (b) eligen aleatoriamente los caminos alternativos en ausencia de feromonas y (c) los altos niveles de concentración de feromonas atraen a las hormigas por el camino más corto.

5.2 Optimización por Colonia de Hormigas

Los algoritmos de Optimización por Colonia de Hormigas se inspiran directamente en el comportamiento de búsqueda de alimento de las colonias de hormigas reales, para solucionar problemas de optimización combinatoria. Se basan en una colonia de hormigas artificiales, esto es, unos agentes

computacionales simples que trabajan de manera cooperativa y se comunican mediante rastros de feromona artificiales [DOR92].

Los algoritmos de *ACO* son esencialmente *algoritmos constructivos, i.e.*: en cada iteración del algoritmo, cada hormiga construye una solución al problema recorriendo un grafo de construcción. En el caso del problema de Compensación de Potencia Reactiva *RPC,* cada hormiga construye una distribución de elementos de compensación. Cada arista del grafo, que representa los posibles elementos de compensación que la hormiga puede ubicar en una determinada barra del sistema, tiene asociada dos tipos de información que guían el movimiento de la hormiga:

Información heurística, mide la preferencia heurística o deseabilidad de ubicar el elementos de compensación de valor j en la barra i, o sea, de utilizar $b_i = b_j$ (ver sección 2.4) en la barra i, lo que se nota por η_{ij}. Las hormigas generalmente no modifican esta información durante la ejecución del algoritmo. La visibilidad que se utiliza en el *OE* para el problema de Compensación de Potencia Reactiva es una innovación del presente trabajo y será descripta con mayores detalles posteriormente.

Información de los rastros de feromona artificiales, mide la "deseabilidad aprendida" de ubicar el elemento de compensación b_j en la barra i. Imita a la feromona real que depositan las hormigas naturales. Esta información se modifica durante la ejecución del algoritmo dependiendo de las soluciones encontradas por las hormigas. Se denota por τ_{ij}.

El modo de operación básico de un algoritmo de *ACO* es como sigue: dada m_h hormigas (artificiales) de la colonia, estas se mueven concurrentemente y de manera asíncrona, a través de los estados adyacentes del problema (que puede representarse en forma de grafo con pesos). Este movimiento se realiza siguiendo una regla de transición que está basada en la información local disponible en los componentes (enlaces o aristas del grafo). Esta información local incluye la información heurística e histórica (rastros de feromona) para guiar la búsqueda. Al moverse por el grafo de construcción, las hormigas construyen incrementalmente soluciones. Una vez que cada hormiga ha generado una solución ésta se evalúa y puede depositar una cantidad de feromona que es función de la calidad de la solución. Esta información guiará la búsqueda de las otras hormigas de la colonia en el futuro.

Además, el modo de operación genérico de un algoritmo de *ACO* incluye la evaporación de los rastros de feromona. La evaporación de feromona la lleva a cabo el entorno y se usa como un mecanismo que evita el estancamiento en la búsqueda y permite que las hormigas busquen y exploren nuevas regiones del espacio [ALO04].

5.3 Enfoque típico de *ACO*

Con el objetivo de proveer un marco de referencia para el diseño de nuevas versiones de algoritmos, la metaheurística *ACO* fue propuesta posteriormente a las primeras versiones [DOR92]. Aun cuando existen varias versiones de *ACO*, se presenta a continuación lo que se considera un enfoque estándar [GOM04b].

Inicialmente el *ACO* fue diseñado para resolver el Problema del Cajero Viajante o *TSP* (*Travelling Salesman Problem*), por lo que el enfoque estándar esta definido para dicho problema. Debido a esto se presenta a continuación una breve descripción del *TSP*.

El problema del Cajero Viajante puede ser representado por un gráfico completo $\boldsymbol{G} = (\boldsymbol{V}, \boldsymbol{E})$ siendo $\boldsymbol{V}$ el conjunto de nodos, también llamados ciudades, y $\boldsymbol{E}$ el conjunto de arcos que conectan completamente todos los nodos. Cada arco $(h, l) \in \boldsymbol{E}$ tiene asignado un valor d_{hl} que representa la distancia entre las ciudades *h* y *l*. El *TSP* es el problema de encontrar el recorrido más corto o recorrido óptimo, denotado como r*, que visite cada uno de los $n' = |\boldsymbol{V}|$ nodos de $\boldsymbol{G}$ exactamente una vez. Para *TSP* simétricos la distancia entre las ciudades es independiente de la dirección en que se atraviesen los arcos, esto es $d_{hl} = d_{lh}$ para cada par de ciudades.

Aún cuando existen diversas variantes de *ACO*, a continuación se presenta la que puede ser considerada como el enfoque típico [GOM04b].

ACO usa una matriz de feromonas $\tau = \{\tau_{hl}\}$ para la construcción de soluciones potencialmente buenas. Los valores iniciales de τ son fijados a un valor constante: $\tau_{hl} = \tau_0 \ \forall \ (h, l)$ siendo $\tau_0 > 0$. También aprovecha la información heurística utilizando un parámetro $\eta_{hl} = 1/d_{hl}$. Situados en la ciudad *h*, N_h representa el conjunto de ciudades aún no visitadas. La posibilidad de escoger la ciudad *l* estando en la ciudad *h* está definida por la siguiente ecuación:

$$P_{hl} = \begin{cases} \dfrac{\tau_{hl}^{\alpha} \times \eta_{hl}^{\beta}}{\sum_{\forall l \in N_h} \tau_{hl}^{\alpha} \times \eta_{hl}^{\beta}} & si \quad l \in N_h \\ 0 & si \quad l \notin N_h \end{cases} \tag{5.1}$$

donde los parámetros α y β definen la influencia relativa entre la información heurística y los niveles de feromonas.

En cada una de las iteraciones del algoritmo, cada hormiga comienza en una ciudad aleatoriamente escogida, luego va eligiendo al azar las ciudades a visitar del conjunto N_h mediante las probabilidades dadas por la ecuación (5.1), hasta completar un recorrido. La evaporación de las feromonas se aplica a todos los arcos (*h*, *l*) de acuerdo a:

$$\tau_{hl} = (1 - \rho).\tau_{hl} \tag{5.2}$$

donde el parámetro $\rho \in (0,1]$ determina la tasa de evaporación.

Considerando una estrategia elitista, la mejor solución encontrada hasta el momento (r_{best}) actualiza τ de acuerdo a:

$$\tau_{hl} = \tau_{hl} + \Delta\tau \tag{5.3}$$

donde:

$$\begin{aligned} \Delta\tau &= \frac{1}{L(r_{best})} \quad si \quad (h,l) \in r_{best} \\ \Delta\tau &= 0 \qquad si \quad (h,l) \notin r_{best} \end{aligned} \tag{5.4}$$

5.4 *Ómicron ACO*

Esta variante de *ACO* desarrollado por Gómez et al. toma su nombre del uso del parámetro *Ómicron* (O). A continuación se presenta al *Ómicron ACO* para el caso mono-objetivo [GOM04a]:

En *OA*, una matriz de feromonas de valores constantes:

$$\tau_0 = \{\tau_{hl} = 1 \quad \forall(h,l) \quad \in \quad E\} \tag{5.5}$$

es definida inicialmente [GOM04a]. Se escoge una población utilizando τ_0 y la ecuación (5.1). Resulta importante enfatizar que *OA* mantiene una población *P* = {P_x} de *m'* individuos o soluciones diferentes, las mejores soluciones encontradas hasta el momento. El mejor individuo de *P* en cualquier momento es denotado por *P**, mientras que el peor por P_{worst}. En cada iteración un nuevo individuo P'_{new} es generado, éste reemplaza a P_{worst} en *P* si P'_{new} es mejor que P_{worst} y diferente a todos los individuos de *P*.

Después de *K'* iteraciones τ es recalculada. Al principio $\tau = \tau_0$, luego a cada elemento τ_{hl} se le suma una cantidad igual a O/m' cada vez que un arco (*h*, *l*) aparece en alguno de los m individuos de *P*. Este proceso se repite cada *K'* iteraciones hasta que una condición de parada es alcanzada, (ver detalles en pseudocódigo). Nótese que $1 \leq \tau_{hl} \leq (1 + O)$ donde $\tau_{hl} = 1$ si el arco (*h*, *l*) no está presente en ningún P_x, mientras que $\tau_{hl} = (1 + O)$ si el arco (*h*, *l*) está presente en cada P_x de P.

A continuación el pseudocódigo típico del *OA* mono-objetivo considerando un *TSP* con *n* ciudades [GAR04]:

Pseudocódigo de: ***Ómicron ACO***.
Parámetros de entrada: *n'*, matriz $D = \{d_{lh}\}$, O, *K'*, α, β.
Parámetros de salida: *P* (*m'* mejores soluciones).
$\tau_0 = \{\tau_{hl} = 1 \quad \forall(h,l) \in E\}$
P = ***Inicializar población*** (τ_0)
Repetir hasta alcanzar condición de parada.
    Repetir *K'* veces
        P'_{new} = ***Nueva solución*** (τ).
        Si $L(P_{new}) < L(P_{worst})$ y $P'_{new} \neq$ a todos los elementos de *P*.
            Eliminar P_{worst} e incluir de P'_{new} en *P*.
            P = Ordenar *P* de peor a mejor respecto a la longitud del recorrido
        Fin si.
    Fin repetir.
    τ = ***Actualizar matriz de feromonas*** (*P*).
Fin repetir.

Pseudocódigo de: ***Inicializar población*** (τ).
Para x = 1 hasta *m'*
    P'_{new} = ***Nueva solución*** (τ).
    Si $P'_{new} \neq$ cada individuo de *P*.
        $P[x] = P'_{new.}$
    Fin si.
Fin para.
P = Ordenar *P* de peor a mejor respecto a la longitud del recorrido.

Pseudocódigo de : ***Nueva solución*** (τ).
$P'_{new}[0]$ = Seleccionar una ciudad al azar (*i*). Obs.: Inicio del recorrido.
Para *x* = 1 hasta *n'* Obs.: Recorrido sin terminar.
    P[*x*] = Seleccionar una ciudad a visitar mediante la ecuación (5.1).
Fin para.

Pseudocódigo de: ***Actualizar matriz de feromonas***.
τ = ***Inicializar matriz de feromonas*** ().
Para *x* = 1 hasta *m'*
    Repetir para cada arco (*h, l*) de cada recorrido de *P*.
        $\tau_{hl} = \tau_{hl} + O/m'$.
    Fin repetir.
Fin para.

5.5 *Ómicron* Eléctrico *OE*.

El *OE* utiliza el concepto del *ACO* para generar soluciones o individuos potencialmente buenos [GOM04a] y [GOM04b].

El conjunto de soluciones no dominadas encontradas durante el proceso es agrupado en la población P_{oe}. Cada nueva solución generada es comparada con P_{oe}, conservándose solamente las no dominadas.

Este proceso de generación, evaluación y comparación es repetido iterativamente.

Todas las soluciones de P_{oe} se utilizan para actualizar la matriz de feromonas (τ). El parámetro *O* (*Ómicron*) que es un parámetro constante determina la cantidad de feromona que cada solución deposita al actualizar la matriz de feromonas.

Por otro lado, la probabilidad $\Pr_{ij}$ de escoger el banco b_j para ser ubicado en la barra *i* está definida por la siguiente ecuación:

$$\Pr_{ij} = \begin{cases} \dfrac{\tau_{ij}^{\alpha} \times \eta_{ij}^{\beta}}{\sum \tau_{ij}^{\alpha} \times \eta_{ij}^{\beta}} \end{cases} \qquad (5.6)$$

donde, de forma análoga a la fórmula 5.1, los parámetros α y β definen la influencia relativa entre los niveles de feromonas y la visibilidad.

Para generar un individuo, cada hormiga recorre secuencialmente las barras del sistema eléctrico. Basados en la probabilidad Pr_{ij}, un determinado

valor b_{ij} es seleccionado y asignado a b_i. Al final del recorrido, la hormiga genera la n-tupla *B* (vector de decisión).

Una generación es definida como un número *K'* de iteraciones, luego de las cuales se procede a la actualización de la matriz de feromonas, que se describe a continuación.

La matriz de feromonas τ, se encarga de almacenar la información aprendida en las iteraciones previas, u obtenida de la población inicial, para ello consta de un número de filas *n*, igual al número de barras del sistema y un número de columnas *c*, igual a la cantidad de niveles de discretización de b_j. De esta manera cada fila de τ tiene asociada una barra del sistema y cada columna un valor de de compensación posible, b_j. La primera columna de τ representa el mayor valor del reactor b_{il}^m permitido y la última columna corresponde al mayor valor de capacitancia b_{iC}^m.

De esta forma τ asocia a cada posible compensación un valor de deseabilidad, este valor influye directamente en la distribución de probabilidades que otorgará la ecuación 5.6. Así, cuanto mayor sea la deseabilidad asociado a un determinado valor de compensación, mayor será la probabilidad de que sea efectivamente elegido.

En la actualización de τ se utilizan todos los individuos de P_{oe}. El número de individuos en P_{oe} es denotado por m_h. Para la actualización de la matriz de feromonas la hormiga realiza los siguientes pasos:

1- Igualar τ a la matriz unitaria.

2- Seleccionar un individuo de P_{oe}.

3- Detectar el valor b_{1j} de reactivo asignado a la primera barra del sistema.

4- Depositar un cantidad de O/m_h feromonas en la columna j de τ.

5- Repetir los pasos 3 y 4 para todas las barras del sistema.

6- Repetir los pasos del 2 al 5 para todos los individuos de P_{oe}.

Ejemplo 5.1: *Actualización de la matriz de feromona* τ.

Considerando los siguientes valores:

n = 3 o sea un sistema eléctrico de 3 barras.

b_i^m = 2 esto es; un valor máximo de compensación admisible de 2 MVAr, dando c = 5 posibles compensaciones (-2 MVAr, -1 MVAr, 0 MVAr, 1 MVAr, 2 MVAr)

O = 30.

m_h = 3, el conjunto P_{oe}

$$P_{oe} = \begin{cases} [1, 1, 2] \\ [-2, 1, -1] \\ [0, 1, 0] \end{cases}$$

Primer paso: se iguala τ a una matriz, con unos en todas sus entradas, de dimensión m_h x c.

$$\tau = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \end{bmatrix}$$

Segundo paso: Se selecciona P_{oe} [1] = [1, 3, 2].

Tercer paso: $b_{1j} = 1$. ($O/m_h = 10$)

Cuarto paso: se suma O/m_h a la entrada de τ asociada a b_{1j}.

$$\tau = \begin{bmatrix} 1 & 1 & 1 & 11 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \end{bmatrix}$$

Repitiendo pasos 3 y 4 para $b_{2j} = 3$ y $b_{3j} = 2$

$$\tau = \begin{bmatrix} 1 & 1 & 1 & 11 & 1 \\ 1 & 1 & 1 & 11 & 1 \\ 1 & 1 & 1 & 1 & 11 \end{bmatrix}$$

Repitiendo los pasos 2 al 4 para P_{oe} [2] = [-2, 1, -1], se obtiene:

$$\tau = \begin{bmatrix} 11 & 1 & 1 & 11 & 1 \\ 1 & 1 & 1 & 21 & 1 \\ 1 & 11 & 1 & 1 & 11 \end{bmatrix}$$

Repitiendo los pasos 2 al 4 para P_{oe} [3] = [0, 1, 0], se obtiene:

$$\tau = \begin{bmatrix} 11 & 1 & 11 & 11 & 1 \\ 1 & 1 & 1 & 31 & 1 \\ 1 & 11 & 11 & 1 & 11 \end{bmatrix}$$

Tabla 5.1 Matriz de feromonas del ejemplo 5.1

Observación: Nótese que el valor de la matriz de feromona asociado a la deseabilidad de ubicar un capacitor de 1 MVAr a la segunda barra tiene un valor de 1 + O, esto es debido a que todas las soluciones de P_{oe} asigna a dicha barra un capacitor de 1 MVAr. En cambio la deseabilidad asociada a no compensar la segunda barra tiene un valor de 1, a causa de que ninguna solución de P_{oe} asigna la compensación nula a dicha barra.

Visibilidad η.

La visibilidad η es una función que intenta guiar a las hormigas en la construcción de buenas soluciones. De manera similar a la matriz de feromonas, la visibilidad asigna valores de deseabilidad a todas las compensaciones factibles para cada barra del sistema, para ella asocia a cada barra *i* un vector fila $\eta[i]$ con *c* columnas. Cada columna de $\eta[i]$ está asociada a un valor en MVAr de banco de reactivo.

Recordemos que una barra con desviación de tensión positiva, tensión mayor que la deseada (V_i*), necesitaría una compensación inductiva y una barra con desviación negativa, tensión menor que V_i*, requeriría compensación capacitiva [DEL00], [MIU97].

La visibilidad opera asignando una determinada deseabilidad de ser elegido a cada valor de compensación de reactivos representado en cada fila de η. Para poder explorar eficientemente el espacio de soluciones del problema, la visibilidad no es estática durante una generación, sino que varía dinámicamente en el transcurso de la misma. Para conseguir este efecto dinámico η está compuesta por dos funciones η_1 y η_2, conforme a la siguiente ecuación:

$$\eta[ij] = w_1 \times \eta_1[ij] + w_2 \times \eta_2[j] \tag{5.7}$$

donde
$$\begin{cases} w_1 + w_2 = 1 \\ w_1 \in [1,0] \\ w_2 \in [0, 1] \end{cases}$$

w_1 y w_2 son valores de ponderación que varían al transcurrir la generación

La función η_1 otorga mayor deseabilidad a las soluciones con mucha compensación y η_2 a las soluciones con poca compensación.

Los pasos a seguir para calcular la visibilidad son presentados a continuación:

(1) *Calcular las tensiones en las barras sin ninguna compensación de reactivos en la red, o con una distribución base de reactivos*.

(2) *Calcular la desviación de tensión en las barras*.

(3) *Asignar valores de deseabilidad crecientes a los distintos valores de compensación de acuerdo a la necesidad de cada barra con la función* η_1.

(4) *Asignar valores de deseabilidad mayores a los bancos de reactivos de pequeña dimensión a través de la función* η_2

(5) *Los valores de* $\eta[ij]$ *para cada iteración son calculados mediante la fórmula (5.7)*, *donde los valores de ponderación* w_1 *y* w_2 *varían de acuerdo al número de iteración de la generación*. En base al número identificador de hormiga de la generación, w_1 varía gradualmente de 1 en la primera iteración hasta 0 en la última iteración y w_2 varía de 0 en la primera iteración hasta 1 en la última. Estos valores son los utilizados en la ecuación 5.7 para hallar la probabilidad final que guiará a las hormigas para la construcción de buenas soluciones.

Así, con la utilización de la función compuesta η se busca construir buenos individuos con gran cantidad de compensación al principio de una generación e ir disminuyendo la cantidad de compensación al terminar la misma. Con esto se busca una mejor exploración del espacio de búsqueda.

Ejemplo 5.2: Cálculo de la visibilidad

Considerando mismos valores utilizados en el ejemplo 5.1:

$n = 3$.

$b_i^m = 2$, por lo tanto $c = 5$ posibles compensaciones por barra.

1) Cálculo de tensiones en las barras:

En nuestro ejemplo supongamos que, luego de resolver el flujo de potencia con los datos de la red y de la carga, obtenemos las siguientes tensiones en las barras: V = [1.1; 0.82; 0.98], es decir, la primera barra tiene el 110% de la tensión ideal, la segunda el 82% y la tercera el 98%.

2) Cálculo de desviación de tensión:

En el ejemplo este valor seria ΔV = [0.1; –0.18; –0.02]. Nótese que la primera barra necesita compensación inductiva y las otras dos capacitiva.

3) *Asignación de deseabilidad de acuerdo a la función* η_1

Esta función favorece la elección de soluciones con gran cantidad de reactivo, siendo el máximo valor asignado proporcional a la desviación de tensión en cada barra, utilizándose un factor de proporcionalidad "*fa*", hallado empíricamente. Los valores asignados por η_1 siguen una progresión aritmética creciente o decreciente de acuerdo a la necesidad de una compensación capacitiva o inductiva. En el ejemplo, suponiendo que elegimos un factor de proporcionalidad *fa* = 100, se obtiene:

Para la barra 1: ΔV = 0.1, por lo tanto el máximo valor de probabilidad, que es asignado al banco de reactores de 2 MVAr, se determina de la siguiente manera: $\Delta V \times fa$+1=0.1×1000+1=11. El valor asignado al capacitor de 2 MVAr será de 1. Los demás valores siguen una progresión aritmética de paso = $\frac{\text{fa}\times\Delta\text{V}}{\text{c}-1}=\frac{100\times 0{,}1}{5-1}$=2,5

Para la barra 2: ΔV = –0.18, por lo tanto el máximo valor de probabilidad, asignado al banco de capacitores de 2 MVAr, será de: $\Delta V \times fa$ +1=–0.18×100+1 = 19. El valor asignado al reactor de 2 MVAr será de 1. Los demás valores siguen una progresión aritmética de paso = $\frac{\text{fa}\times\Delta\text{V}}{\text{c}-1}=\frac{100\times 0.18}{5-1}$=4,5.

Para la barra 3 se procede de forma análoga, los valores obtenidos se resumen en la tabla 5.1

	Barra Nº	-2 MVAr	-1 MVAr	0 MVAr	1 MVAr	2 MVAr
	1	11	8,5	6	3,5	1
η_1 =	2	1	5,5	10	14,5	19
	3	1	1,5	2	2,5	3

Tabla 5.2: Asignación de deseabilidad otorgados por la función η_1 para el ejemplo 5.2

Para tener una visión más clara de la asignación de probabilidades dada por η_1, una representación *gráfica* de la misma se presenta a continuación:

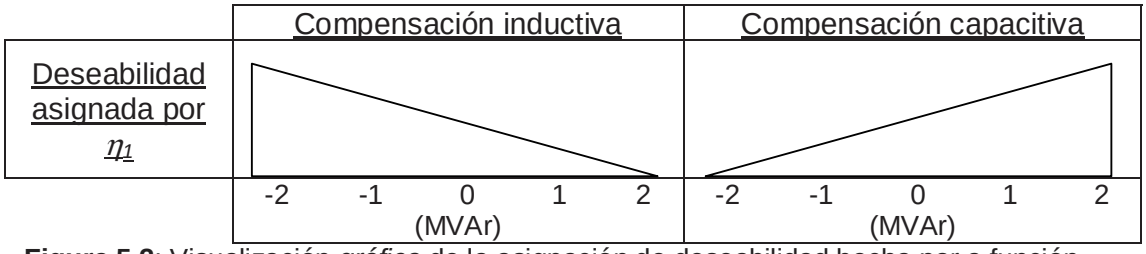

Figura 5.2: Visualización *gráfica* de la asignación de deseabilidad hecha por a función η_1

4) Asignación de deseabilidad mediante la función η_2

Esta función tiene como objetivo guiar a las hormigas para encontrar soluciones con poca compensación**.** Los valores de deseabilidad asignados por η_2 siguen una progresión aritmética, primero creciente y luego decreciente teniendo su pico en la deseabilidad asociada a la compensación nula. Para un valor de referencia se utiliza el promedio de la desviación de tensión ($\overline{\Delta V}$) en todas las barras y un factor de proporcionalidad "*fb*".

En el ejemplo $\overline{\Delta V}$ = (0,1 +0,18 + 0,02)/3 = 0,1 y para una constante de proporcionalidad *fb* = 100 se obtiene:

La deseabilidad asignada a la compensación nula será de $\overline{\Delta V} \times fb+1$ =0,1×100+1=11, la deseabilidad asignada a los mayores bancos, tanto capacitivos como inductivos será 1. A continuación se muestran los valores calculados en la tabla 5.2

	-2 MVAr	**-1 MVAr**	**0 MVAr**	**1 MVAr**	**2 MVAr**
η_2 =	1	6	11	6	1

Tabla 5.3: Asignación de deseabilidad hecha por la función η_2 para el ejemplo 5.2

De forma análoga a lo hecho con η_1 a continuación se presenta una visualización *gráfica* de de la asignación de deseabilidad hecha por η_2.

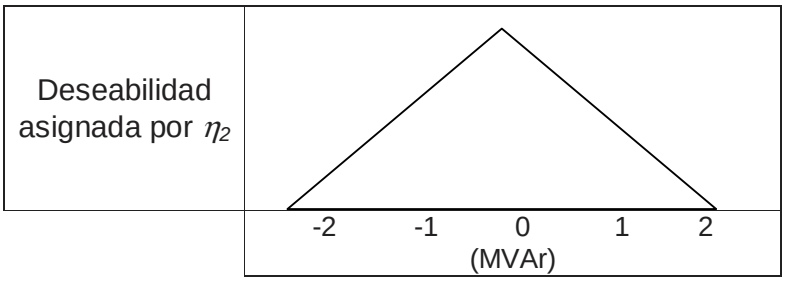

Figura 5.3: Visualización *gráfica* de la asignación de deseabilidad de la función η_2

5) Cálculo de η

Para el cálculo de η usaremos las tablas 5.1, 5.2 y la fórmula 5.7.

Así para w_1 = 1 y w_2 = 0, que corresponde al inicio de una generación tenemos que: $\eta[ij]=1\times\eta_1+0\times\eta_2$

MVAR	**-2**	**-1**	**0**	**1**	**2**
	11	8,5	6	3,5	1
1×	1	5,5	10	14,5	19
	1	1,5	2	2,5	3

+0×

-2	**-1**	**0**	**1**	**2**
1	6	11	6	1

=

Barra	**-2 MVAr**	**-1 MVAr**	**0 MVAr**	**1 MVAr**	**2 MVAr**
1	11	8,5	6	3,5	1
2	1	5,5	10	14,5	19
3	1	1,5	2	2,5	3

$\eta[ij]$

Tabla 5.4: Ejemplo de asignación de deseabilidad de la función compuesta η para la primera iteración de una generación,

Para w_1 = 0,5 y w_2 = 0,5, que corresponde a una iteración intermedia de una generación tenemos que: $\eta[ij]=0,5\times\eta_1+0,5\times\eta_2$

MVAR	**-2**	**-1**	**0**	**1**	**2**
	11	8,5	6	3,5	1
0,5×	1	5,5	10	14,5	19
	1	1,5	2	2,5	3

+0,5×

-2	**-1**	**0**	**1**	**2**
1	6	11	6	1

=

Barra	**-2 MVAr**	**-1 MVAr**	**0 MVAr**	**1 MVAr**	**2 MVAr**
1	6	7,25	8,5	4,75	1
2	1	5,75	10,5	10,25	10
3	1	3,75	6,5	4,25	2

$\eta[ij]$

Tabla 5.5: Ejemplos de asignación de deseabilidad de la función compuesta η para una iteración intermedia de la generación

Para la última iteración de una generación, en ese caso $w_1 = 0$ y $w_2 = 1$, tenemos que: $\eta[ij]=0 \times \eta_1+1\times \eta_2$

MVAR	**-2**	**-1**	**0**	**1**	**2**
	11	8,5	6	3,5	1
0×	1	5,5	10	14,5	19
	1	1,5	2	2,5	3

+1×

-2	**-1**	**0**	**1**	**2**
1	6	11	6	1

=

$\eta[ij]$	**Barra**	**-2 MVAr**	**-1 MVAr**	**0 MVAr**	**1 MVAr**	**2 MVAr**
	1	1	6	11	6	1
	2	1	6	11	6	1
	3	1	6	11	6	1

Tabla 5.6: Ejemplos de asignación de deseabilidad de la función compuesta η para la última iteración de la generación.

En la figura 5.4 se muestra una representación *gráfica* de la asignación de deseabilidad hecha por η.

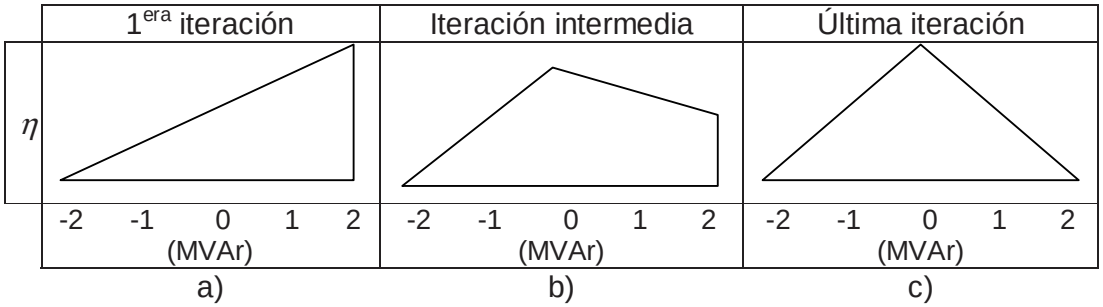

Figura 5.4: Visualización *gráfica* de la asignación de deseabilidad de la función compuesta η para tres iteraciones distintas: a) la primera de la generación, b) una intermedia y c) la última iteración de la generación.

A continuación se presenta el pseudocódigo del *Ómicron Eléctrico* propuesto.

Pseudocódigo de: ***Ómicron Eléctrico****:*

Parámetros de entrada: O, Configuración de la red con sus cargas, *K'*.

Parámetros de salida: P_{oe}., frente de soluciones no dominadas.

***Calcular visibilidad*.**

Cargar población inicial.

Mientras no se cumpla con la condición de parada.

Eliminar soluciones dominadas de P_{oe}.

Actualizar τ.

Mientras no se llegue a la condición de término de la generación, *K'*.

Crear nuevo individuo

Correr el flujo de potencia.

Si P_{new} es no dominado con respecto a P_{oe}.

$P_{oe} = P_{oe} + P_{new}$.

Fin mientras, de la generación.

Fin mientras, del algoritmo.

Pseudocódigo de: ***Calcular visibilidad*.**

Correr el flujo de potencia con la red sin ninguna compensación de reactivos.

Cálculo de η_1:

Para i = 1 hasta n.

$$\Delta Vi = Vi - Vi^*$$

Si $\Delta Vi > 0$

Para j =1 hasta c

$$\eta_1[i, j] = a\Delta V + 1 - (j-1) \cdot \frac{fa \cdot \Delta V_i}{c-1}$$

Obs.: Los valores de $\eta_1[i, j]$ disminuyen conforme a una progresión aritmética

Fin para

Fin si.

Si $\Delta Vi < 0$

Para j =1 hasta c

$$\eta_1[i, j] = 1 + (j-1) \cdot \frac{fa \cdot \Delta V_i}{c-1}$$

Obs.: Los valores de $\eta_1[i, j]$ aumentan conforme a una progresión aritmética.

Fin para

Fin si.

Fin para.

Cálculo de η_2:

$$\overline{\Delta V} = \frac{\sum_{i=1}^{n} \Delta V_i}{n}$$

Para *j* = 1 hasta $\frac{c-1}{2}+1$.

$$\eta_2[j] = 1 + (j-1) \cdot \frac{2 \cdot fb \cdot \overline{\Delta V}}{c-1}.$$

Obs.: Los valores de $\eta_2[j]$ aumentan gradualmente desde $\eta_2[1]$ hasta la columna asociada a la compensación nula

Fin para.

Para $j = \frac{c-1}{2}+1$ hasta c

$$\eta_2[j] = 1 + 2 \cdot \overline{\Delta V} - (j-1) \cdot \frac{2 \cdot fb \cdot \overline{\Delta V}}{c-1}$$

Obs.: Los valores de $\eta_2[j]$ disminuyen gradualmente desde la columna asociada a la compensación nula hasta $\eta_2[c]$

Fin para (De subrutina).

Pseudocódigo de: ***Actualizar*** τ.

Inicializar τ como matriz de unos de $n \times c$.

Para cada individuo P_{oe}.

Para cada barra *i* se determina el valor *j* del banco de compensación asignado a *i*.

τ (*i*, *j*)= τ (*i*, *j*) + *O/m*'.

Obs.: Se le suma O/*m*' a la columna asociada al valor del banco ubicado en la barra *i* del individuo P_{oe}.

Fin para.

Fin para (De subrutina).

Pseudocódigo de: ***Crear nuevo individuo*****.**

Para *i* = 1 hasta *n*.

Para *j* = 1 hasta *c*.

$$\eta[ij] = w_1 \times \eta_1[ij] + w_2 \times \eta_2[j]$$

$$\Pr_{ij} = \left\{ \frac{\tau_{ij}^{\alpha} \times \eta_{ij}^{\beta}}{\sum \tau_{ij}^{\alpha} \times \eta_{ij}^{\beta}} \right.$$

Se escoge el banco de correspondiente a cada barra de P_{new} probabilísticamente de acuerdo a la distribución de probabilidades $\Pr_{ij}$

Fin para.

Fin para (De subrutina).

Ejemplo 5.3 Creación de una solución.

Se explicará paso a paso la creación de dos soluciones, la primera y la última de una generación. Para este ejemplo se utilizarán los resultados de los ejemplos 5.1 y 5.2. Suponiendo α y β unitarios, con los valores obtenidos de: 1) la matriz de feromonas y 2) la visibilidad para la primera iteración, se procede a hallar la distribución de probabilidades según la ecuación 5.6.

Utilizando las tablas 5.1 de feromonas y 5.4 como visibilidad:

Cálculo de Pr_{ij}

Visibilidad

MVAr	-2	-1	0	1	2
τ_{ij}	1	6	11	6	1
	1	6	11	6	1
	1	6	11	6	1

Matriz de Feromonas

η_{ij}	-2	-1	0	1	2
	11	1	11	11	1
	1	1	1	31	1
	1	11	11	1	11

$\tau_{ij} \times \eta_{ij}$

MVAr	-2	-1	0	1	2
	11	6	121	66	1
	1	6	11	186	1
	1	66	121	6	11

$\sum \tau_{ij} \times \eta_{ij}$

205
205
205

Pr_{ij}

Barras	-2 MVAr	-1 MVAr	0 MVAr	1 MVAr	2 MVAr
1	0,054	0,029	0,590	0,322	0,005
2	0,005	0,029	0,054	0,907	0,005
3	0,005	0,322	0,590	0,029	0,054

Tabla 5.7: Asignación de probabilidades Pr_{ij}, para la iteración inicial del ejemplo 5.3

Nótese que en la primera y tercera barras la compensación nula es la que tiene mayor probabilidad de ser electa, no ocurre lo mismo con la segunda barra debido al alto nivel de feromona asociado al banco de 1 MVAr.

Ahora, que se ha hallado la distribución de probabilidades mediante la ecuación 5.6 se utiliza un método de selección probabilístico para elegir la compensación en cada barra. De este proceso resulta la solución: B = [0, 1, 0].

Para la iteración final de una generación utilizamos las tablas 5.1 de feromonas y la 5.6 como visibilidad:

Visibilidad

MVAr	-2	-1	0	1	2
	11	8,5	6	3,5	1
τ_{ij}	1	5,5	10	14,5	19
	1	1,5	2	2,5	3

Matriz de Feromonas

	-2	-1	0	1	2
	11	1	11	11	1
η_{ij}	1	1	1	31	1
	1	11	11	1	11

$\tau_{ij} \times \eta_{ij}$

MVAr	-2	-1	0	1	2
	121	8,5	66	38,5	1
	1	5,5	10	449,5	19
	1	16,5	22	2,5	33

$\sum \tau_{ij} \times \eta_{ij}$

235
485
75

Pr_{ij}

Barras	-2 MVAr	-1 MVAr	0 MVAr	1 MVAr	2 MVAr
1	0,515	0,036	0,281	0,164	0,004
2	0,002	0,011	0,021	0,927	0,039
3	0,013	0,220	0,293	0,033	0,440

Tabla 5.8: Asignación de probabilidades Pr_{ij}, para la iteración final del ejemplo 5.3

Puede observarse que en la primera y tercera barra la máxima compensación, inductiva y capacitiva respectivamente, tienen asociadas la mayor probabilidad de ser seleccionadas. En la segunda barra si bien la probabilidad asociada al banco de 1 MVAr es muy elevada aún existe una probabilidad mayor al 6 % de elegir otro banco, esto evita que el algoritmo se estanque prematuramente.

Nuevamente se utiliza un método probabilístico para elegir la compensación en cada barra de acuerdo a las probabilidades halladas, obteniéndose de este la solución B = [-2, 1, 2].

Aquí se puede observar como el algoritmo busca soluciones con poca compensación al principio de la generación, así, la primera solución generada utiliza solo 1 banco, y mayor compensación al final de la generación como se nota en la solución hallada al final que necesita en total 5 MVAr de compensación. Además, en todos los casos la probabilidad de ubicar un capacitor de 1 MVAr en la segunda barra era la mayor debido a que todas las soluciones de P_{oe} asignan dicha compensación a la segunda barra del sistema.

Capítulo 6

Estudios Experimentales

Introducción

En este capítulo se presentan los resultados de los experimentos realizados con el *SPEA* y el *Ómicron Eléctrico* respectivamente, mostrando el *OE* un mejor desempeño. Primeramente, se describe como fueron diseñadas las pruebas para validar el presente trabajo, mostrando tanto el sistema eléctrico en que fueron probados los algoritmos como las métricas que se utilizaron para la comparación de los mismos. Se finaliza este capítulo con la presentación y análisis de los resultados experimentales obtenidos.

6.1 Diseño de experimentos

De manera análoga a lo realizado por Vallejos [VAL02] se decidió presentar el diseño de los experimentos en base a guías sugeridas por Barr [BAR95] y Jackson [JAC91], quienes presentan una discusión acerca del diseño de experimentos con métodos heurísticos y dan algunas sugerencias para reportar resultados y asegurar que los mismos puedan ser reproducidos. Específicamente sugieren los siguientes pasos:

- definir los objetivos experimentales;
- escoger las métricas para medir el desempeño;
- diseñar y ejecutar los experimentos;
- analizar los datos y obtener las conclusiones;
- reportar los resultados experimentales.

En base a estos pasos en las siguientes secciones se da una descripción de las fases del experimento realizado.

6.2 Objetivo del experimento

El objetivo de los experimentos y de este capítulo, es comparar el desempeño del método propuesto en el presente trabajo, *OE*, con respecto al *SPEA* propuesto por Barán et al. [BAR01a] y [BAR01b], para resolver el problema de compensación de potencia reactiva en el Sistema de Potencia de Pruebas *IEEE* de 118 barras planteado como problema multiobjetivo. Posteriormente, se presentarán y analizarán los resultados en base a métricas de amplia utilización por la comunidad científica.

6.3 Elección de métrica comparativa.

La métrica de rendimiento utililizada para evaluar los frentes de soluciones producidos por ambos algoritmos fue la cobertura. Este tipo de comparación se aplica a los algoritmos multiobjetivos, ya que ellos no encuentran una única solución óptima, sino un conjunto de soluciones, las cuales no pueden clasificarse entre mejores y peores, considerando que son soluciones de compromiso. El estudio de cobertura está basado en el concepto de dominancia Pareto, presentado en el capítulo 2.

Sean FP^{SPEA} y $FP^{OE} \in Y_f$ los conjuntos de vectores objetivos no dominados encontrados por los algoritmos *SPEA* y *OE*, respectivamente. La función $\mathbb{C}$ (cobertura) mapea el par ordenado (FP^{SPEA}, FP^{OE}) en el intervalo [0,1]. Una definición más rigurosa de la cobertura se da a continuación:

$$\mathbb{C}\left(FP^{SPEA}, FP^{OE}\right) \equiv \frac{\left|\left\{y'' \in FP^{OE}\ ; \exists\ y' \in FP^{SPEA} \quad t.q.\ y' \succ y''\right\}\right|}{\left|FP^{OE}\right|} \tag{6.1}$$

El valor $\mathbb{C}\,(FP^{SPEA}, FP^{OE})$ =1 significa que todas las soluciones en FP^{OE} se encuentran dominados por soluciones de FP^{SPEA}. El resultado opuesto, o sea, $\mathbb{C}\,(FP^{SPEA}, FP^{OE})$ = 0 expresa que ninguna solución del conjunto FP^{OE} es dominada por alguna solución de FP^{SPEA}. Nótese que ambos $\mathbb{C}\,(FP^{SPEA}, FP^{OE})$ y $\mathbb{C}\,(FP^{OE}, FP^{SPEA})$ deben ser calculados porque no son necesariamente complementarios.

Para la mejor comprensión de la métrica de cobertura se muestra un ejemplo gráfico del cálculo del mismo en las figuras 6.1 y 6.2. Dados dos conjuntos de soluciones conocidos C_1 y C_2, en la figura 6.1 se muestra como se calcula el valor de $\mathbb{C}\,(C_1, C_2)$ y en la figura 6.2 se hace lo propio con el valor de $\mathbb{C}\,(C_2, C_1)$.

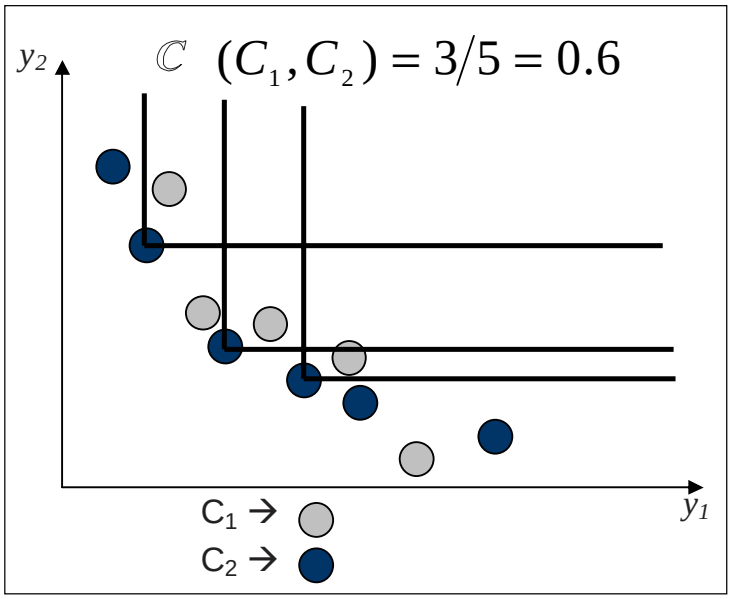

Figura 6.1. Cálculo de $\mathbb{C}\,(C_1, C_2)$ dados dos conjunto de soluciones, C_1 y C_2.

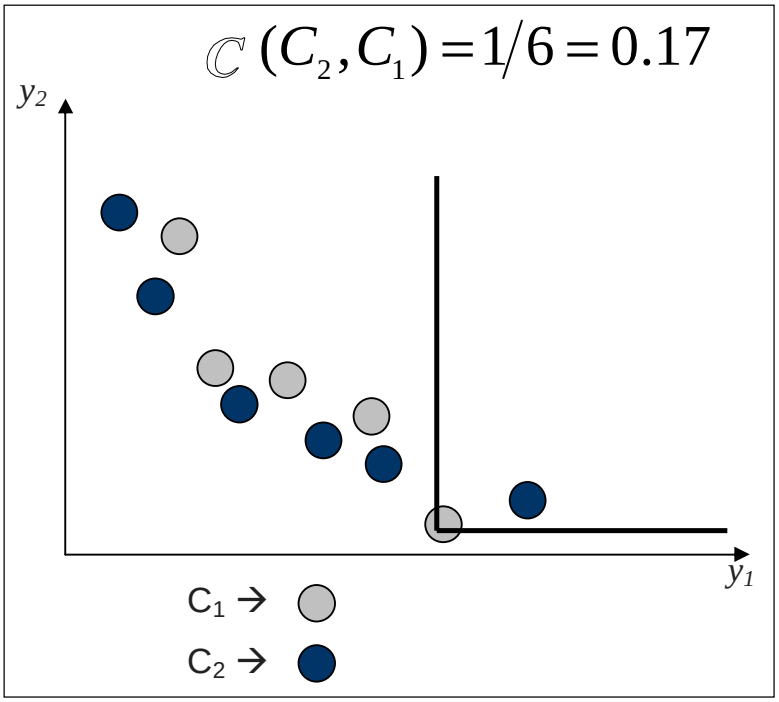

Figura 6.2. Cálculo de $\mathbb{C}$ (C_2, C_1) dados dos conjunto de soluciones, C_2 y C_1.

De las figuras 6.1 y 6.2 se concluye que el conjunto C_2 es mejor que C_1 pues tiene un nivel de cobertura mayor.

6.4 Diseño y ejecución de los experimentos

6.4.1 Problema de referencia

Según Christie [CHR00] el Sistema de Potencia de Prueba IEEE de 118 barras representa una porción del Sistema Eléctrico de los Estados Unidos de Norteamérica. (medio oeste). Los datos fueron recopilados de una copia del Sistema de Potencia de Prueba AEP (*American Electric Power*) de 118 barras de fecha Diciembre de 1962 y fueron habilitados para la industria eléctrica como un caso estandarizado de estudio.

Los MVA de potencias límites de cada línea no forman parte de los datos originales. Es un sistema robusto ya que posee una gran cantidad de reguladores de voltaje (9 de los cuales son bancos de compensadores estáticos de reactivos) y 55 generadores, que le dan una convergencia en aproximadamente 5 iteraciones cuando se aplica el método de Newton-Raphson desacoplado para resolver el flujo de potencia. Debido a lo expuesto, para tornar apto el sistema para compensación de potencia reactiva, se incrementó tanto la carga activa como la reactiva en un 50%. La figura 6.3 muestra un esquema del sistema en estudio.

6.4.2 Plataforma computacional.

Se utilizaron computadores personales con procesadores AMD K6-2 de 350 MHz de velocidad y 128 MB de memoria RAM, con sistema operativo Windows 98. Todas las rutinas fueron programadas en Matlab 5.3.

6.4.3 Metodología Experimental.

Con el objetivo de poder comparar el desempeño del método propuesto, *OE*, con el ya reconocido *SPEA* [BAR01a] y [BAR01b], se realizaron diez corridas de cada algoritmo divididas en dos grupos de cinco. La duración de cada corrida fue determina de la siguiente forma:

SPEA: la condición de parada del primer grupo de ejecuciones del algoritmo se determinó que sea el número máximo de generaciones evaluadas igual a 120. Este valor es similar al utilizado por Barán et al. en sus estudios [BAR01a] y [BAR01b]. En este primer grupo cada corrida requirió aproximadamente 8

horas de tiempo de cómputo. Posteriormente, determinó que el segundo conjunto de corridas se ejecutase durante el doble de tiempo de cómputo, es decir, durante aproximadamente 16 horas en cada corrida. Cada corrida de este segundo grupo creó y evaluó un total de 230 generaciones. Para facilitar la exposición de los resultados la nomenclatura adoptada para designar a los conjuntos de soluciones hallas por el *SPEA* es la siguiente:

FP^{SPEA-1}	Frente de soluciones no dominadas halladas por las 5 corridas de 8 horas y 120 generaciones del *SPEA*
FP^{SPEA-2}	Frente de soluciones no dominadas halladas por las 5 corridas de 16 horas y 230 generaciones del *SPEA*
FP^{SPEA}	Frente Pareto hallado por todas las corridas del *SPEA*

Ómicron Eléctrico: Debido a que la duración de una generación es diferente para los algoritmos, *SPEA* y *OE*, se determinó que la condición de término de las corridas del *OE* sea calculada tomando como referencia la duración de las corridas del *SPEA*. Esto es, se determinó que el primer grupo de ejecuciones del *OE* dure aproximadamente 8 horas, en este tiempo el algoritmo evaluó 10.000 soluciones. Análogamente a lo hecho con el primer grupo de soluciones, se determinó que el segundo conjunto de 5 ejecuciones del *OE* durase igual que su contraparte del *SPEA*, es decir 16 horas cada una. En este tiempo cada corrida del algoritmo generó y evaluó unas 20.000 soluciones. La nomenclatura adoptada para designar a los conjuntos de soluciones hallas por el *OE* es la siguiente:

FP^{OE-1}	Frente de soluciones no dominadas halladas por las 5 corridas de 8 horas y 10.000 soluciones del *OE*
FP^{OE-2}	Frente de soluciones no dominadas halladas por las 5 corridas de 16 horas y 20.000 soluciones del *OE*
FP^{OE}	Frente Pareto hallado por todas las corridas del *OE*

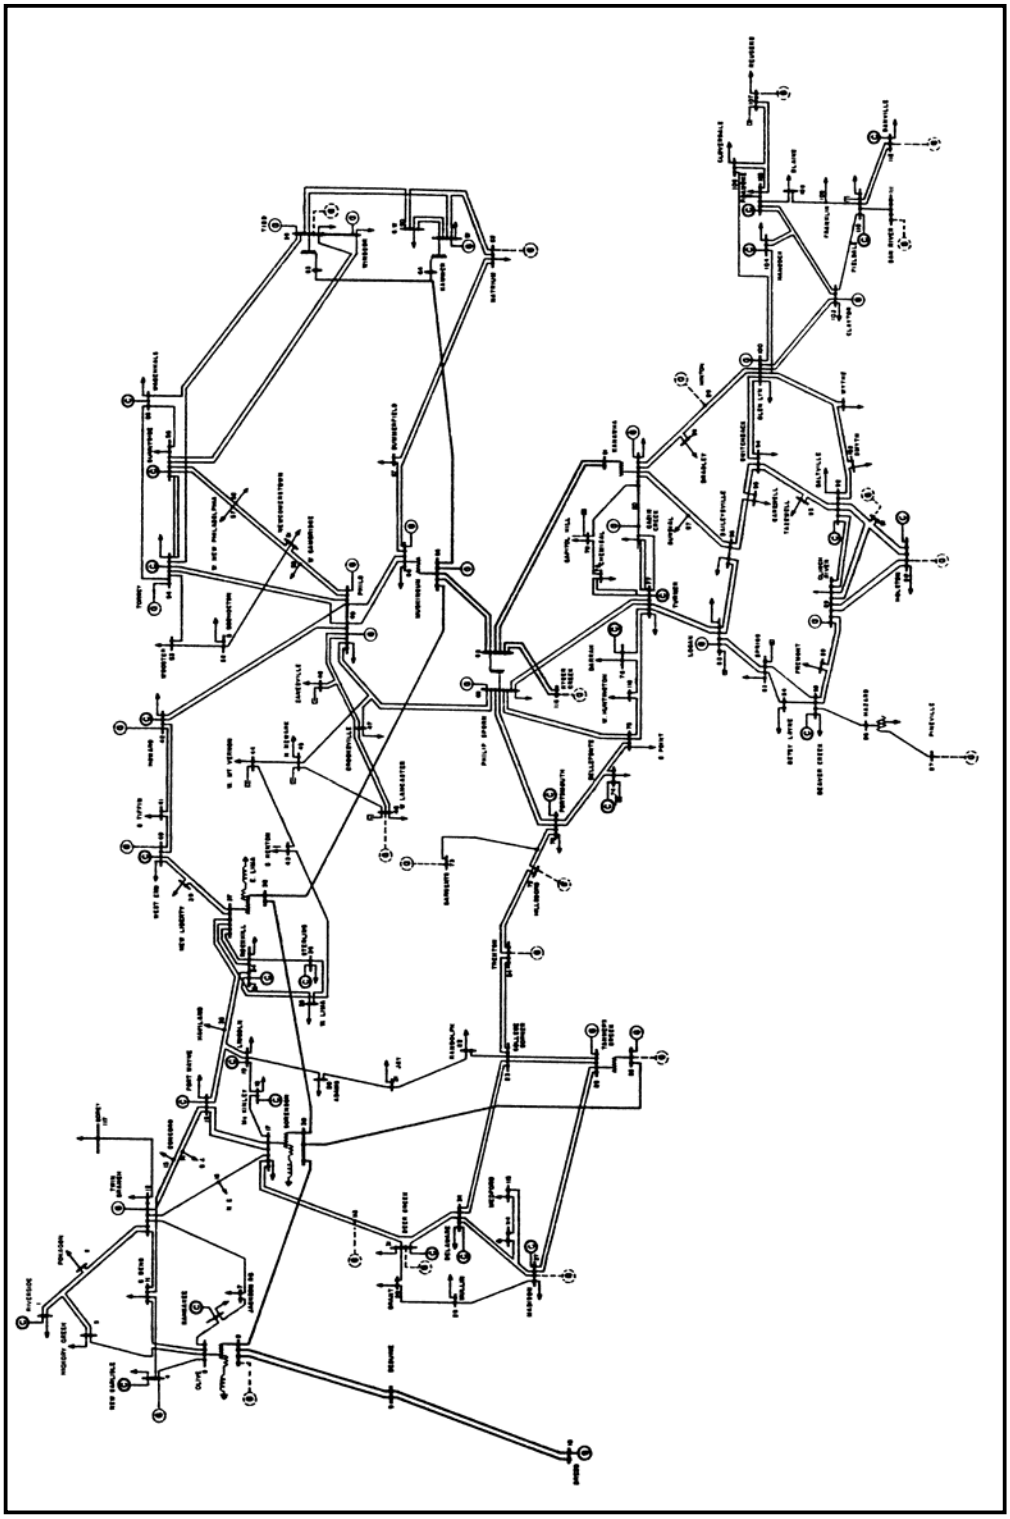

Figura 6.3. Sistema eléctrico de potencia estandarizado IEEE de 118 barras.

6.5 Resultados experimentales y análisis de datos.

Los parámetros utilizados para el *SPEA* son los mismos que en la implementación de Barán et al., estos son:

- probabilidad de cruzamiento P_c = 0.7.
- probabilidad de mutación P_m = 0.3.
- probabilidad de aplicación del optimizador local P_{lo} = 0.7.
- pamaño de la población evolutiva *Pop*, *N* = 100.

Los parámetros del *OE* fueron sintonizados a través de extensas pruebas, que consistieron en variar sucesivamente dichos parámetros para hallar el par de valores que presenten la mejor performance. Dichos valores fueron:

- Número de iteraciones por generación K' = 1000.
- Constante *Ómicron O* = 1500.

En la tabla 6.1 se presentan los valores de *cobertura* del *SPEA* sobre el *OE*, así en la primera columna se muestran los valores de cobertura del conjunto FP^{SPEA-1} sobre las soluciones halladas por el *OE*. La segunda y tercera columnas hacen los propio con los valores de FP^{SPEA-2} y FP^{SPEA}. Nótese la escasa cantidad de soluciones calculadas por el *Ómicron Eléctrico* que llegan a ser dominadas por alguna solución hallada por el *SPEA*.

	FP^{SPEA-1}	FP^{SPEA-2}	FP^{SPEA}
FP^{OE-1}	0%	1,2%	1,2%
FP^{OE-2}	0%	0%	0%
FP^{OE}	0%	0%	0%

Tabla 6.1. Valores de *cobertura* del *SPEA* sobre el *OE* $\mathbb{C}$ (FP^{SPEA}, FP^{OE}).

En la tabla 6.2 se muestran los valores de cobertura del *Ómicron Eléctrico* sobre el *SPEA*. Esta tabla, de forma análoga a la 6.1, presenta los valores de cobertura del conjunto FP^{OE-1} sobre los Frentes Pareto hallados por el *SPEA* en la primera columna. La segunda y tercera columnas hacen lo propio con los valores de FP^{OE-2} y FP^{OE}. Aquí se puede apreciar como las soluciones generadas por el *OE* dominan casi completamente a las halladas por el *SPEA*.

	FP^{OE-1}	FP^{OE-2}	FP^{OE}
FP^{SPEA-1}	100%	100%	100%
FP^{SPEA-2}	98,2%	100%	100%
FP^{SPEA}	98,2%	100%	100%

Tabla 6.2. Valores de *cobertura* del *OE* sobre el *SPEA*, $\mathbb{C}(FP^{OE}, FP^{SPEA})$.

Los resultados mostrados en la tabla 6.2 indican que las soluciones hallas por el *OE* en las corridas de 16 horas dominan a todas las soluciones generadas por el *SPEA*, y que solo algunas soluciones halladas por el *SPEA* en 16 horas no son dominadas por las soluciones halladas por el *OE* en la mitad del tiempo.

Para poder visualizar estos resultados de una forma más expresiva y amigable al lector, se presenta en la figura 6.4 la gráfica de los Frentes Pareto obtenidos por el *SPEA* y el *OE* en sus respectivas corridas de 8 horas. En la figura 6.5 se hace lo propio con las corridas de 16 horas de ambos algoritmos. En ambas figuras puede apreciarse claramente como las soluciones generadas por el *OE* consiguen menores desviaciones de tensión promedio con menor cantidad de compensación, lo cual se traduce en mejores perfiles de tensión con inversiones más bajas.

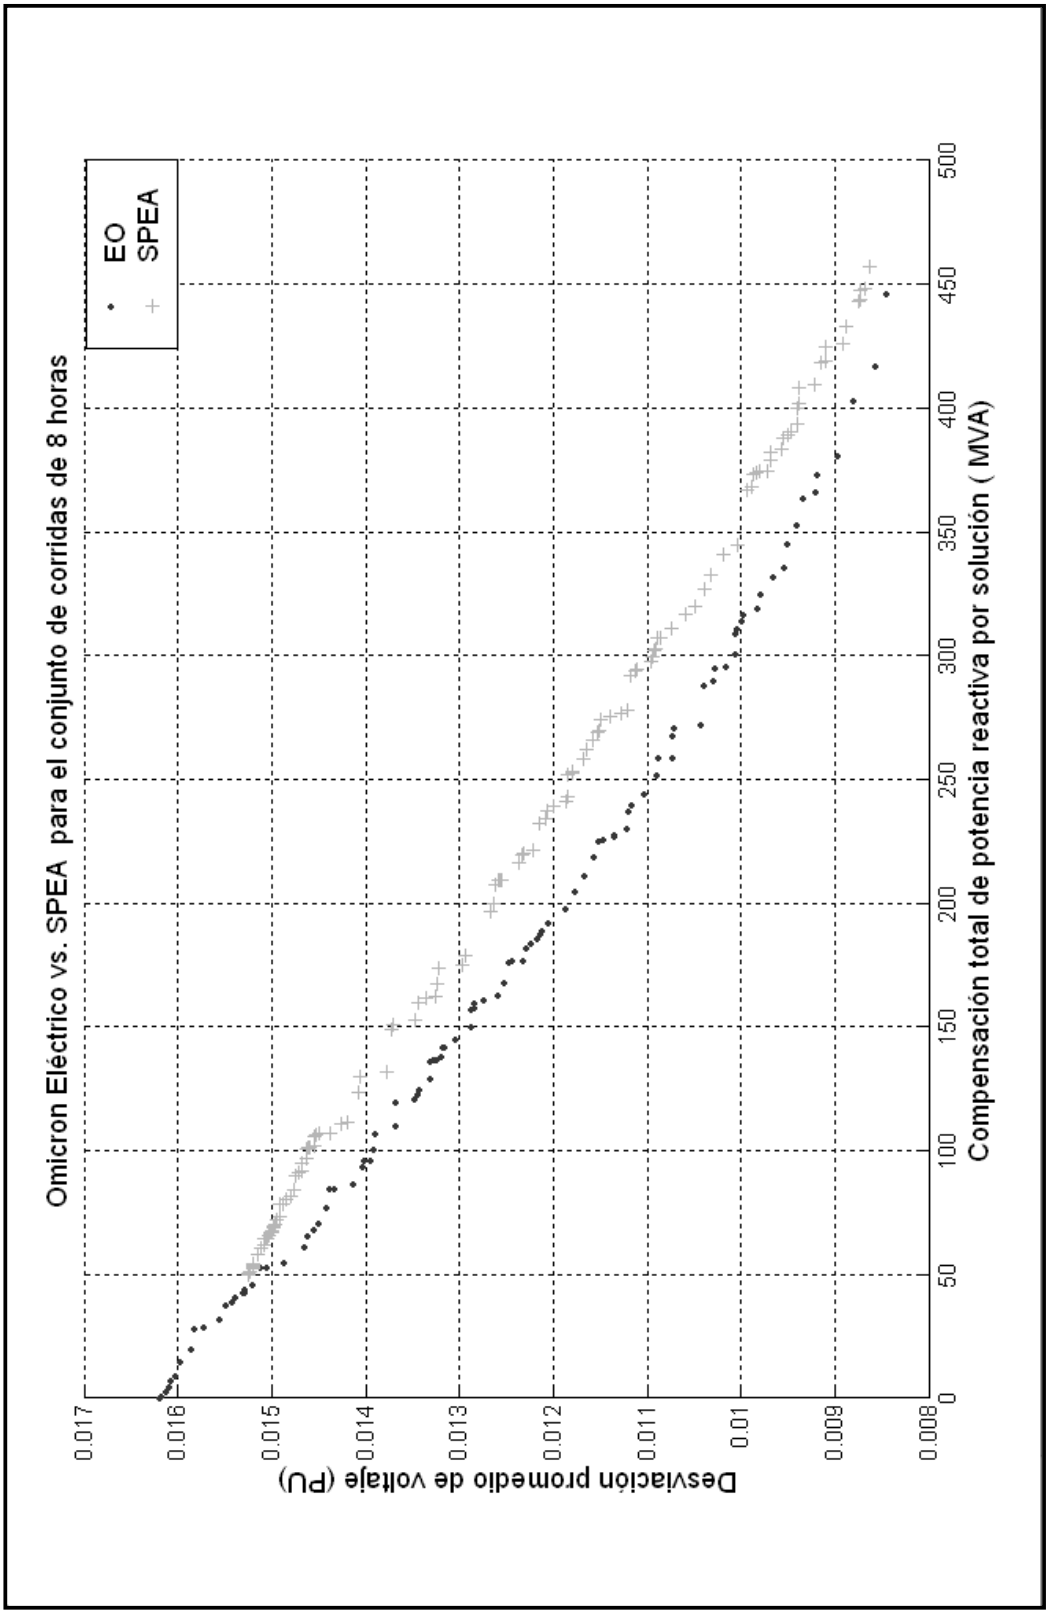

Figura 6.4 *Ómicron Eléctrico* vs. *SPEA* para el conjunto de 8 horas de corrida.

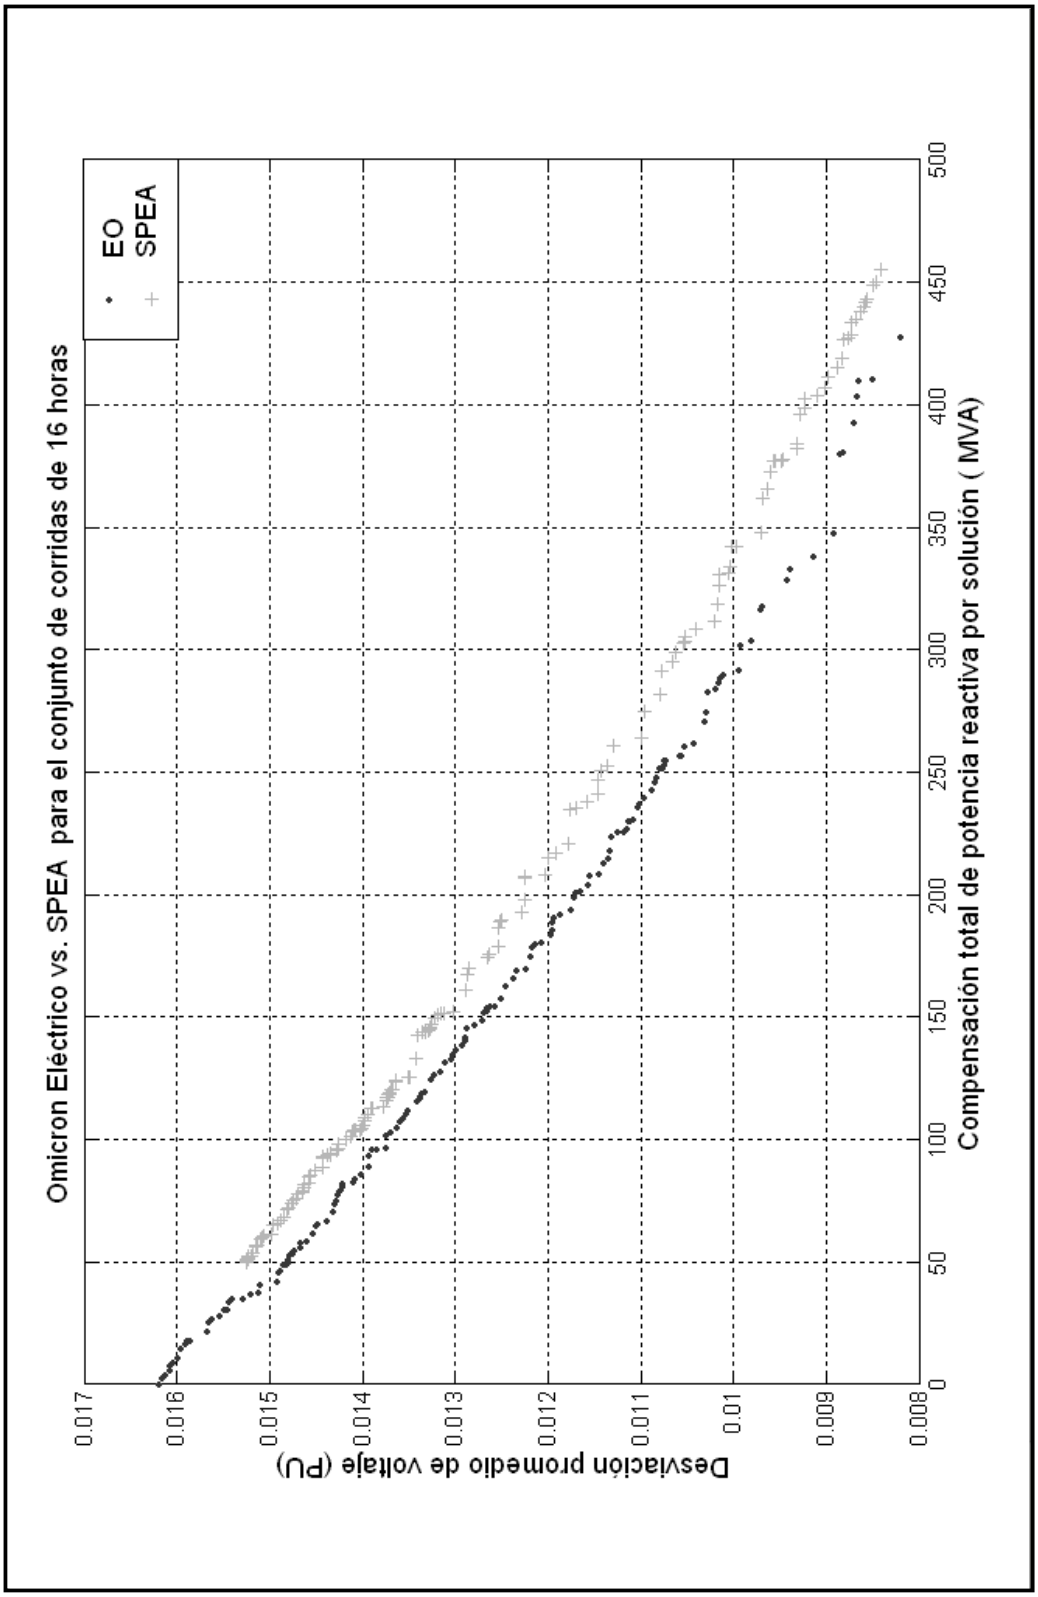

Figura 6.5 *Ómicron Eléctrico* vs. *SPEA* para el conjunto de 16 horas de corrida.

6.6 Selección de una solución.

La gran ventaja de tener un Frente de soluciones en vez de una única solución es que esto permite al equipo de ingenieros encargados de tomar las decisiones de diseño escoger aquella solución de compromiso que mejor se adecue a las necesidades del sistema en estudio, i.e. soluciones con menor valor de inversión pero que al mismo tiempo maximicen la calidad de servicio, representada en este estudio por el desvió promedio de voltaje.

Se puede seleccionar una solución específica a partir de la carta generada de varias formas, por ejemplo, seleccionando la calidad de servicio que se pretende, en nuestro caso determinando la desviación de voltaje deseada y seleccionando la solución con menor inversión que logra el objetivo, o determinando una cantidad de inversión disponible para la compensación y seleccionando de la carta la solución que presenta la mejor calidad de servicio con dicha inversión.

Para ejemplificar el proceso de toma de decisión se arbitra una desviación promedio de voltaje de 1 %, es decir se determina el nivel de calidad de servicio deseado. En la figura 6.6 se presenta amplificada una gráfica con todas las mejores soluciones halladas por ambos algoritmos donde se resaltan las soluciones con menor inversión que logran la desviación de voltaje deseada hallada por cada método. En la tabla 6.3 se muestran ambas soluciones. En dicha tabla se indican solo las barras que presentan compensación de reactivos para al menos una de las soluciones, es decir, las barras no representadas tienen compensación nula para ambas soluciones.

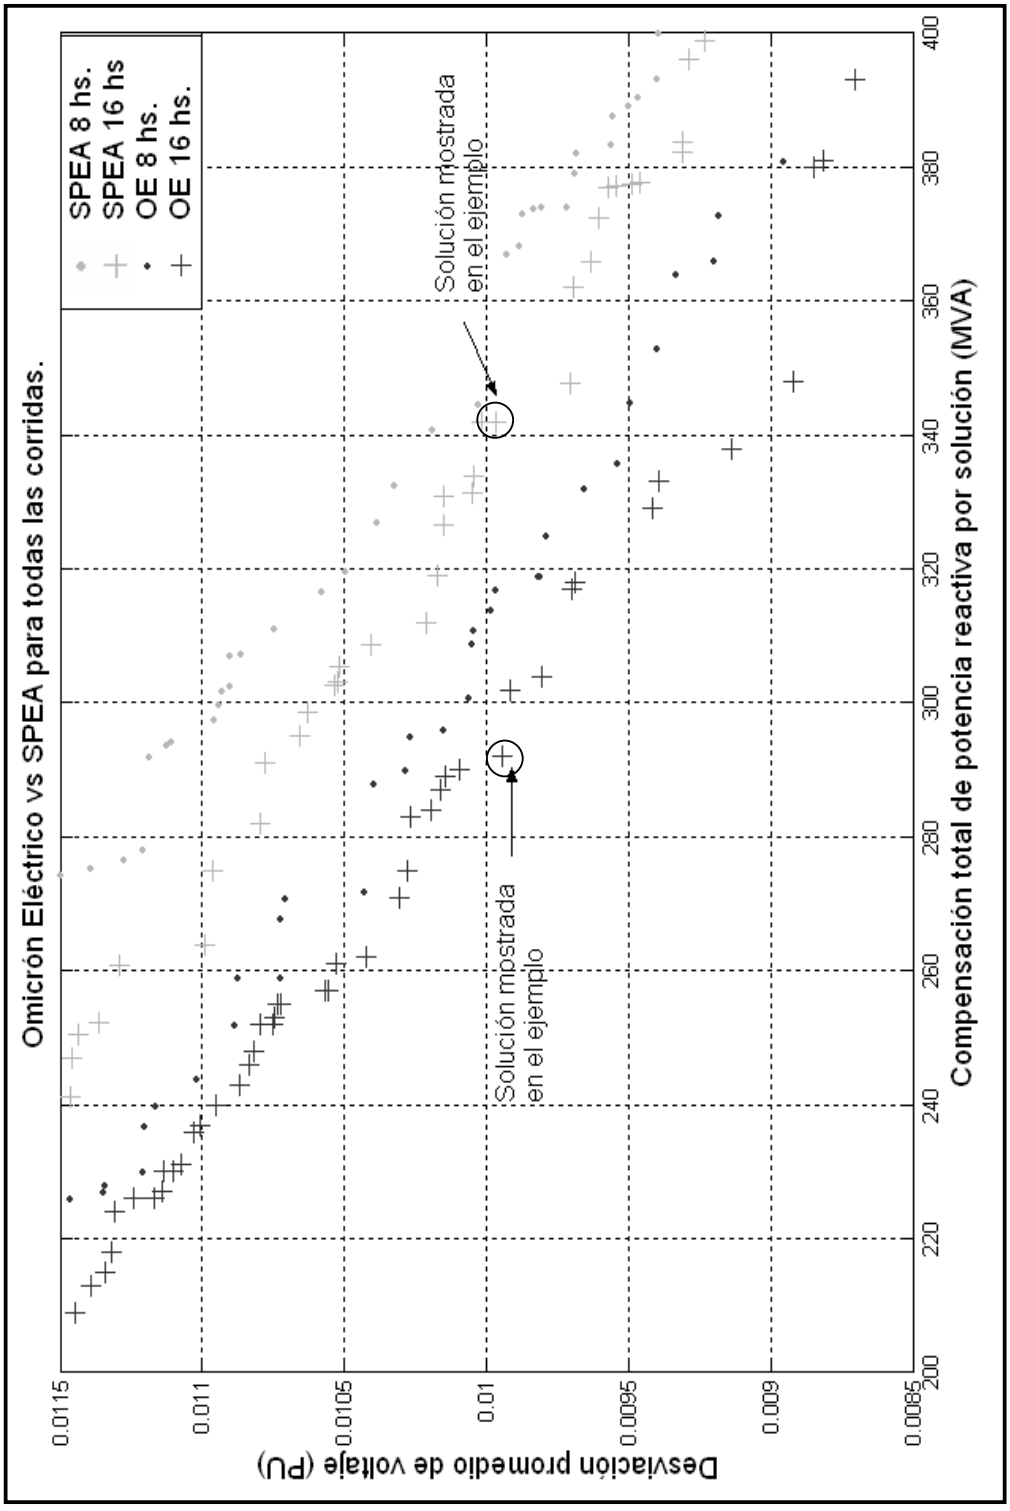

Figura 6.6 *Ómicron Eléctrico* vs. *SPEA* para todos los conjuntos de corridas. Se resaltan las mejores soluciones halladas por cada algoritmo que consiguen una desviación promedio de voltaje menor a 1 %

Barra	**Compensación reactiva en MVAr**	
	SPEA	***Ómicron_Eléctrico***
1	1	0
3	1	2
5	-3	0
9	2	0
11	1	0
13	4	0
18	1	0
19	2	1
20	9	6
21	10	24
22	8	0
32	1	0
33	1	0
35	1	1
38	2	0
43	3	2
44	1	40
45	2	0
51	1	0
52	8	0
53	3	0
56	1	0
58	3	0
63	2	0
74	13	0
75	10	0
76	54	53
78	3	0
82	38	52
83	29	53
84	14	18
86	1	1
88	1	0
93	1	0
95	3	0
96	46	0
97	1	0
102	1	0
104	2	1
105	1	0
106	3	0
108	2	0
110	1	0
114	7	0
118	41	38
Total:	**343**	**292**

Tabla 6.3: Soluciones halladas por el *SPEA* y el *OE* que consiguen un desvío promedio de tensión de 1 % con la menor cantidad de compensación posible.

Observando la tabla 6.3 se destaca que ambos algoritmos asignaron una gran cantidad de compensación a las barras 76, 82, 83, 84 y 118. El *SPEA* asigna 46 MVAr a la barra 96 mientras el *OE* no compensa dicha barra, por otra parte el *OE* asigna 40 MVAr a la barra 44 y el *SPEA* solo la compensa con 1 MVAr. También es resaltante como el *SPEA* distribuye mayor cantidad de bancos de pequeño valor, esto es menor a 10 MVAr, que el *OE*. Se puede concluir que la solución generada por el método propuesto logra el objetivo, una desviación promedio de voltaje de 1 %, con 51 MVAr de compensación menos que la hallada por el *SPEA*.

Capítulo 7

Conclusiones

Introducción

Como culminación del presente trabajo, en este último capítulo se mencionan los artículos que publicaron los resultados experimentales obtenidos en este estudio. A consecuencia se formulan las conclusiones finales para posteriormente finalizar el capítulo mencionando, a modo de sugerencia, las posibles ampliaciones del trabajo.

7.1 Reporte de los experimentos.

Los resultados del estudio expuesto en el presente trabajo fueron reportados en conferencias nacionales e internacionales por medio de tres publicaciones:

1. El primer trabajo titulado: **"Comparación del *Ómicron* ACO con el SPEA en el problema de Compensación de Potencia Reactiva en un contexto Multiobjetivo",** fue publicado en el 1º Encuentro Científico Tecnológico ECT05 Organizado por la Facultad de Politécnica de la Universidad Nacional del Este, constituye este un novel foro en informática a nivel nacional. Ciudad del Este - Paraguay. Marzo del 2005

2. El segundo trabajo se dio a denominar: **"Aplicación del *Ómicron* ACO al problema de Compensación de Potencia Reactiva en un contexto Multiobjetivo"** fue publicado en el XIX Congreso Argentino de Ciencias de la

Computación - CACIC'2005. Este evento fue organizado por la Universidad Nacional de Entre Ríos y se constituye en el principal foro de difusión de las innovaciones en informática de la Republica Argentina. Esta conferencia tiene a su vez repercusión internacional al contar con importantes aportes de representantes de Brasil, Uruguay, Paraguay y Chile. Fue realizada en Concordia – Argentina. Octubre del 2005

3. El tercer articulo se denomino: **"Multiobjective Reactive Power Compensation with an Ant Colony Optimization Algorithm"**. Publicado en "8TH International Conference AC and DC Power Transmission", conferencia organizada por la *IEE* (*International Electric Engineer*) en Londres Inglaterra, del 28 al 30 de marzo del 2006. Este evento además, de ser organizado por la *IEE* fue apoyado por la *IEEE* y el Consejo Internacional de Grandes Sistemas Eléctricos *CIGRE* (*Conseil International des Grands Réseaux Électriques)*, siendo estas tres las mayores organizaciones que nuclean a ingenieros eléctricos a nivel internacional. En consecuencia, esta puede ser considerada como una de las principales conferencias en el campo de la transmisión y distribución de energía eléctrica a nivel mundial.

7.2 Conclusiones finales.

Este trabajo propone el algoritmo *Ómicron Eléctrico*, una variante del *Ómicron ACO* para su aplicación al problema de compensación de potencia reactiva en un contexto multiobjetivo. El método propuesto en el presente estudio es el primer Algoritmo de Optimización por Colonia de Hormigas

aplicado al problema de compensación de potencia reactiva, en un contexto puramente multiobjetivo.

Uno de los principales aportes de la presente tesis es la creación de un nuevo enfoque de la visibilidad. Dicho enfoque fue especialmente desarrollado para un algoritmo ACO multiobjetivo aplicado al problema en estudio. La innovación de la visibilidad propuesta consiste en su carácter dinámico que persigue generar buenas soluciones con mucha o poca compensación dependiendo del punto de la generación en que se encuentre el algoritmo. Con esto se pretende una mejor exploración del espacio de soluciones y obtener un conjunto de soluciones más cercano al Frente Pareto real.

De los resultados experimentales obtenidos en el presente estudio se concluye que el *Ómicron Eléctrico* es una alternativa muy promisoria para la solución del problema de Compensación de Potencia Reactiva, presentando un desempeño claramente superior al SPEA, uno de los algoritmos más competitivos en este tipo de problemas, para un reconocido sistema eléctrico de prueba (IEEE-118). De hecho, las soluciones halladas por el *Ómicron Eléctrico* llegan a dominar totalmente a las encontradas por el SPEA dentro del rango de compensación en estudio.

Estos resultados son por demás alentadores considerando además, que el *Ómicron* ACO aplicado a resolver el Problema de Compensación de Reactivos aquí presentado (*OE*) no presenta grandes refinamientos ni utiliza algoritmos de búsqueda local, como lo hace el SPEA utilizado con fines de comparación.

7.3 Trabajos futuros.

Como posibles trabajos futuros se propone:

- Probar el *Ómicron Eléctrico* con más funciones objetivos como ser la minimización de la potencia perdida o minimización de la desviación máxima de tensión.
- Limitar las posibles compensaciones admisibles para las barras a equipos de compensación disponibles comercialmente.
- Probar el desempeño del algoritmo propuesto con otros sistemas eléctricos.
- Realizar estudios económicos de las soluciones generadas.
- Introducir refinamientos al algoritmo como ser:

  a) la utilización de más de una matriz de feromonas, para guardar y agrupar en cada matriz soluciones semejantes,

  b) almacenar también algunas relativamente buenas soluciones, no pertenecientes al frente Pareto, durante el proceso de tal manera a tener mayor diversidad.

Apéndices:

A- Lista de Acrónimos.

B- Lista de Símbolos.

Apéndice A: Lista de Acrónimos:

ACO	Optimización por Colonia de Hormigas (*Ant Colony Optimization*)
AI	Inteligencia Artificial (*Artificial Intelligence*)
ALM	Método de Enlace Promedio (*Average Linkage Method*)
ANDE	Administración Nacional de Electricidad.
ANN	Redes Neuronales (*Artificial Neural Networks*)
CA	Corriente Alterna
CACIC	Congreso Argentino de Ciencias de la Computación.
CC	Corriente Continua
CIGRE	Consejo Internacional de Grandes Sistemas Eléctricos (*Conseil International des Grands Réseaux Électriques*)
CS	Sistemas Clasificadores (*Clasificatory Systems*)
DP	Programación dinámica (*Dynamic Programming*)
EA	Algoritmo Evolutivo (*Evolutionary Algorithm*)
ECT	Encuentro Científico Tecnológico
EP	Programación Evolutiva (*Evolutionary Computing*)
EPSs	Sistemas Eléctricos de Potencia (*Electric Power Systems*)
ES	Sistemas Expertos (*Expert Systems*)
EvS	Estrategias de evolución (Evolutionary Strategies)
FES	Sistema Experto Difuso (*Fuzzy Expert System*)
FST	Teoría de Conjuntos Difusos (*Fuzzy Set Theory*)
GA	Algoritmos Genéticos (*Genetic Algorithms*)
GP	Programación Genética (*Genetic Programming*)
HE	Expertos humanos (*Human Expert*)
i.e.	*it est.* (*latín*) esto es.
IEE	Instituto de Ingenieros Eléctricos (*Institution of Electrical Engineers*)
IEEE	Instituto de Ingenieros Eléctricos y Electronicos (*Institute of Electrical and Electronics Engineers*)
IP	Método del punto interior (*Interior Point Method*)

KBS	Sistemas basados den conocimiento (*Knowledge-Based Systems*)
LF	Flujo de Potencia (*Load Flow*)
LP	Programación Lineal (*Lineal Programming*)
MOP	Problema de Optimización Multiobjetivo (*Multiobjective Optimization Problem*)
NLP	Programación no lineal (*Non-Lineal Programming*)
OE	Ómicron Eléctrico
OPF	Flujo de Potencia Óptimo (*Optimal Power Flow*)
ORDP	Despacho óptimo de potencia reactiva (*Optimal Reactive Power Dispatch*)
PSO	Optimización por enjambre de partículas (*Particle Swarm Optimization*)
pu	por unidad
QP	Programación cuadrática (*Quadratic Programming*)
RPC	Compensación de Potencia Reactiva (*Reactive Power Compensation*)
SA	Templado Simulado (*Simulated Annealing*)
SCADA	Sistema de adquisición remota de datos (*Supervisory Control and Data Acquisition*)
SOP	Problema de Optimización Monoobjetivo (*Single-objective Optimization Problem*)
SPEA	Algoritmo Evolutivo de la Fuerza Pareto (*Strength Pareto Evolutionary Algorithm*)
TLE	Literatura técnica experta (*Technical Literature Expert*)
TS	Búsqueda Tabú (*Tabú Search*)

Apéndice B: Lista de Símbolos:

a	Función de adecuabilidad o *fitness*.
a_i	*Fitness* del individuo x_i perteneciente a P_{known} del *SPEA.*
a_j	*Fitness* del individuo x_j perteneciente a *Pop* del *SPEA*
A, ***B***, ***C***	Soluciones del ejemplo 2.1.
A_b	Alfabeto binario.
A_f	Alfabeto finito.
$\|b_i^m\|$	Máxima compensación que se puede instalar en una barra.
B_i	Compensación instalada en le barra *i.*
b_{iC}^m	Máximo valor de compensación capacitiva admisible en la barra i.
b_{iI}^m	Máximo valor de compensación inductiva admisible en la barra *i*.
$\mathbb{C}$	Valor de cobertura.
C_a	Conjunto de agrupaciones del procedimiento ALM.
CC_B	Costo de instalación de capacitores utilizada en métodos analíticos.
CP_{true}	Conjunto Pareto Optimo.
d_{hl}	Distancia entre las ciudades h y l de una instancia TSP.
d_{ij}	Distancia entre los puntos i y j.
$e : \Re^n \rightarrow \Re^m$	Restricciones de desigualdad.
E	Conjunto de arcos de una instancia TSP.
E_a	Energía ahorrada utilizada en métodos analíticos.
E_k	Tensión en el nodo k.
f_1	Potencial reactiva total nominal instalada en el EPS.
f_1^m	Máxima potencial reactiva total nominal que se puede instalar en el EPS.
f_2	Promedio de la desviación de voltaje
FP_{true}	Frente Pareto Optimo

FP^{OE}	Frente Pareto hallado por el *OE*
FP^{SPEA}	Frente Pareto hallado por el *SPEA*
$f : \Re^n \rightarrow \Re$	Función objetivo.
G	Conductancia de línea entre los nudos *k* y *m*.
G	Gráfico completo que representa una instancia TSP
gen	Ciclo generacional del *SPEA*
gen^m	Número máximo de ciclos generacionales del *SPEA*
G_{km}	Conductancia de línea entre los nodos k y m.
h, l	Nodos o ciudades de una instancia TSP
I_{km}	Corriente de línea entre los nudos *k* y *m*.
J	Jacobiano del LF.
k	Nodo de na red eléctrica.
k	Número de funciones objetivos de un *MOP.*
K	Número de iteraciones que determina una generación en el OE
K'	Número de iteraciones que determina una generación en el *Ómicron ACO*
K_i	Factor utilizado para generar la heurísticamente la población inicial.
L(r)	Longitud del recorrido r
l_i	Número de lineas asociadas a la barra i.
m	Nodo de una red eléctrica
m	Número de restricciones de un MOP
m'	Tamaño de P_{oe} en el *Ómicron Eléctrico.*
m_h	Tamaño de *P* en el Ómicron A*CO.*
n	Número de variables de decisión.
n	Número de barras de sistema eléctrico de potencia.
n_i	Número de individuos en *Pop* dominados por x_i
n_j	
N_h	Conjunto de ciudades aun no visitadas durante la construcción de una recorrido del TSP

N_P	Número de soluciones de Pknown
NP	Tamaño máximo de la población externa utilizada en el *SPEA*.
NP	Número máximo de soluciones en Pknown
O	*Ómicron*, parámetro utilizado en el *Ómicron ACO*
P	Población de soluciones guardadas por el *Ómicron ACO*
P*	La mejor de las soluciones guardadas por el *Ómicron ACO*
P_c	Probabilidad de cruzamiento.
C	Cantidad de valores de compensación admisibles para la barra i
P_k	Potencia activa neta en la barra k.
P_{known}	Conjunto Pareto Optimo conocido del *SPEA.*
P_{lo}	Probabilidad de aplicar el optimizador local.
P_m	Probabilidad de mutación.
P_{new}	Nueva solución generada por el *Ómicron ACO*
P_{oe}	Conjunto de soluciones no dominadas guardadas por el *OE*
Pop	Conjunto de soluciones
P_{sel}	Probabilidad de selección de un algoritmo genético.
PP	Potencia pico disminuida utilizada en métodos analíticos.
P_{worst}	La peor de las soluciones guardadas por el *Ómicron ACO*
Q	Conjunto de soluciones.
Q_k	Potencia reactiva neta en la barra k.
ρ	Parámetro que determina la tasa de evaporación en un *ACO*.
r*	Recorrido optimo de una instancia TSP.
S	Función de "Ahorro con Capacitores" utilizada en métodos analíticos.
s_i	Fuerza o *strength* de un individuo de P_{known} del *SPEA*.
s_j	Fuerza o strength de un individuo de Pop del *SPEA*.
S_k	Potencia aparente neta en la barra k.
SP_{known}	Población externa de soluciones no dominadas en el *SPEA*..
V	Conjunto de nodos de una instancia *TSP*.

V_i	Voltaje efectivo obtenido en la barra i.
V_i^*	Voltaje deseado en la barra i.
V_k	Módulo de la tensión E_k.
ΔV	Desviación de tensión.
ΔV^m	Máxima desviación de tensión admisible.
w_j	Peso de ponderación.
w_{lo}	Máximo valor que puede tomar P_{lo}.
w_1, w_2	Pesos de ponderación utilizados por el *Ómicron* Eléctrico en la visibilidad.
$\boldsymbol{X}$	Espacio de decisión.
$\boldsymbol{x}$	Vector de decisión.
x_i	Solución del conjunto P_{known} del *SPEA*.
x_j	Solución del conjunto *Pop* del *SPEA*.
$x \in \Re^n$	Variable de control o independiente.
$\boldsymbol{X_f}$	Conjunto de soluciones factibles.
x_i	Elemento del conjunto optimo conocido del *SPEA*.
x_j	Elemento de la población evolutiva Pop del *SPEA*.
Y_{kk}	Admitancia propia del nudo *k.*
Y_{km}	Admitancia mutua entre los nudos *k* y *m.*
y_{km}	Admitancia de línea entre los nudos *k* y *m.*
$\boldsymbol{Y}$	Espacio objetivo.
$\boldsymbol{y}$	Vector objetivo.
$\boldsymbol{Y_f}$	Conjunto de vectores objetivo factibles.
Y_{kk}	Admitancia propia del nudo k.
Y_{km}	Admitancia mutua entre los nudos k y m.
$\|\|.\|\|$	Norma.
$\|\|.\|\|_2$	Norma dos.
$\rhd$ $\succ$	Domina o es no comparable con.
	Dominan a.
$\sim$	Son no comparables.

α	Parámetro que determina la influencia de la feromona en un *ACO*.
β	Parámetro que determina la influencia de la visibilidad en un *ACO*.
η	Matriz de visibilidad utilizada por *ACO*.
η_1, η_2	Funciones de visibilidad especialmente diseñadas para el *OE*.
O	*Ómicron*.
σ_{km}	Susceptancia de línea entre los nudos *k* y *m*.
τ	Matriz de feromona utilizada por *ACO*.
τ_0	Valor inicial de la matriz de feromonas utilizado por *ACO*.
θ_k	Fase de la tensión E_k.

Bibliografía:

[ABB05] ABB Support AB, “Power Capacitors'', ABB Capacitors AB, SECAP A05.en, 5nd edition, Diciembre 2005. [Online]. Accesible en: http://www.abb.com/support/capacitor/secapA05en.pdf

[ABD94] Abdel-Salam, T., Chikhani A., y Hackam R., “A New Technique for Loss Reduction Using Compensating Capacitors Applied to Distribution Systems with Varying Load Condition”. in IEEE Trans. on Power Delivery, vol. 9, no. 2, pp. 819-827, Apr. 1994.

[ABO97] Aboytes F. y Ramirez R., “Transient Stability Assessment in Longitudinal Power Systems using Artificial Neural Networks”. IEEE Tran. Power Systems, 11(4): 2003 –2010, 1997.

[ADA73] Adams R. y Laughton M. A., “Optimal Planning of Power Networks using Mixed Integer Programming”. Proceedings IEE, 121(2): 139-145, 1974.

[AFZ00] Afzalin A. y Linkens D. A., “Training of Neuro Fuzzy Power System Stabilizer using Genetic Algorithms”. Int. Journal of Electrical Power and Energy Systems, 22(2): 93-102, 2000.

[AGG97a] Aggarwal R., Joorabian M., y Song Y. H., “Fuzzy Neural Network Approach to Accurate Transmission Line Fault Location”. Int. Journal of Engineering Intelligent Systems, 5(4), 1997.

[AGG97b] Aggarwal R. y Song Y. H., “Artificial Neural Networks in Power Systems: Part 1 General Introduction to Neural Computing”. IEE Power Engineering Journal, 11(3): 129-134, 1997.

[AGG97c] Aggarwal R. y Song Y. H., “Fuzzy Logic and Neural Networks in Generation and Distribution”. Power Technology International, Spring Issue, 39-45, 1997.

[AGG98a] Aggarwal R. y Song Y. H., “Artificial Neural Networks in Power Systems: Part 2 Types of Artificial Neural Networks”. IEE Power Engineering Journal, 12(1):41-47, 1998.

[AGG98b] Aggarwal R. y Song Y. H., "Artificial Neural Networks in Power Systems: Part 3 Examples of Applications in Power Systems". IEE Power Engineering Journal, 12(6):279-287, 1998.

[AHM98] Ahmad A. y Kothari D. P., "A Review of Recent Advances in Generator Maintenance Scheduling". Electric Machines and Power Systems, 26(4):373- 387, 1998.

[ALA96] Alander J. T., "An Indexed Bibliography of Genetic Algorithm in Power Engineering". Report Series 94-1, Power, Feb. 1996.

[ALD01] Aldridge C.J., Mekee S., Mc Denel J. R., Gallowak S.J., Dahal K.P., Bradley M. C., y Macqueen J. F., "Knowledge-Based Genetic Algorithm for Unit Commitment Problem". IEE Proceedings-Generation Transmission and Distribution, 146(2): 146-152, 2001.

[ALG00] Alguacil N. y Conejo A. J., "Multi-Period Optimal Power Flow using Benders Decomposition". IEEE Trans. Power Systems, 15(1):196-201, 2000.

[ALO04] Alonso S., Cordón O., Fernández de Viana I. y Herrera F., "La Metaheurística de Optimización Basada en Colonias de Hormigas: Modelos y Nuevos Enfoques". G. Joya, M.A. Atencia, A. Ochoa, S. Allende (Eds.), Optimizacion Inteligente: Técnicas de Inteligencia Computacional para Optimización, 2004, Servicio de Publicaciones de la Universidad de Málaga, páginas 261-313.

[ALS90] Alsac O., Bright J., Prais M., y Scott B., "Further Developments in LP Based Optimal Power Flow". IEEE Trans. Power Systems, 5(3):697-711, 1990.

[ANA96] Ananthapadmanabha, T., Kulkami A., Gopala Rao A., y Raghavendra Rao K., "Knowledge-based Expert Systems for Optimal Reactive Power Control in Distribution System". Electrial Power & Energy Systems, vol. 18, no. 1, pp. 27-31, 1996.

[AND06] Administración Nacional de Electricidad. Datos de generación, accesible en : http://www.ande.gov.py/

[ANN95] Annakkage U.D., Numnonda T., y Pahalawaththa N.C., "Unit Commitment by Parallel Simulated Annealing". IEE Proceedings-Generation Transmission and Distribution, 142(6): 595-600, 1995.

[AOK88] Aoki K., Fan M., y Nishikori A. "Optimal VAR Planning by Approximation Method for Recursive Mixed–Integer Linear Programming". IEEE Trans. Power Systems, 3(4): 1741 – 1747, 1988.

[ARR83] Arrillaga, J., Arnold, C.P. y Harker B. J., *Computer Modelling of Electrical Power Systems*, Editorial John Wiley & Sons, Reino Unido. 1983.

[BAE78] Bae, Y., "Analytical Method of Capacitors Allocations on Distribution Primary Feeders". in IEEE Trans. on Power Apparatus and Systems, vol. 97, no. 11, pp. 1232-1238, July/Aug. 1978.

[BAI96] Bai X. y Shahidehpour S., "Hydro-Thermal Scheduling by Tabu Search and by Decomposition Method". IEEE Trans. Power Systems, 11(2): 968-974, 1996.

[BAK95] Bakirtzis A. C., Theocharis J. B., Kiartzis S. J., y Satsios K. J., "Short Term Load Forecasting Fuzzy Neural Networks". IEEE Trans. Power Systems, 10(3): 1518-1524, 1995.

[BAL90] Baldick, R. y Wu F., "Efficient Integer Optimization Algorithms for Optimal Coordination of Capacitors and Regulators". in IEEE Trans. on Power Systems, vol. 5, no. 3, pp. 805-812, Aug. 1990.

[BAL92] Balu N. J., Adapa R. A., Cauley G., Lauby M., y Maratukulam D. J., "Review of Expert Systems Planning And Operations". Proceedings of IEEE, 80(5): 727-731, 1992.

[BAN03a] Bansal R.C., "Bibliography on the Fuzzy Set Theory Applications to Power Systems (1994-2001)". IEEE Trans. Power Systems, 18(4):1291-1299, 2003.

[BAN03b] Bansal R.C., "Literature Survey on Expert System Applications to Power Systems (1990-2001)". Int. Journal Engineering Intelligent Systems, 11(3):103-112, 2003.

[BAN05] Bansal R.C., “A Bibliographical Survey of Evolutionary Computation Applications in Power Systems (1994-2003)”. En Int. Journal of Power and Energy Systems, Vol. 25, 2005.

[BAR89a] Barán, M. y Wu F., “Optimal Capacitor Placement on Radial Distribution Systems''. En IEEE Trans. on Power Delivery, vol. 4, no. 1, pp. 725-734, Enero, 1989.

[BAR89b] Barán, M. y Wu F., “Optimal Sizing of Capacitor Placed on a Radial Distribution Systems''. En IEEE Trans. on Power Delivery, vol. 4, no. 1, pp. 735-743, Enero, 1989.

[BAR95] Barr, R., “Desingning and Reporting on Computational Experiments with Heuristic Methods''. Journal of Heuristic, vol. 1, pp. 9-32. 1995.

[BAR01a] Barán, B., Vallejos J. y Ramos R., “Multi-Objective Optimization in Reactive Power Compensation''. En Proc. Jornadas Internacionales de Tecnología- (JIT-CITA'2001), Asunción, Set. 2001.

[BAR01b] Barán, B., Vallejos J., Ramos R. y Fernández U., “Multi-Objective Reactive Power Compensation''. En Proc. IEEE 2001 Transmission and Distribution Conference and Exposition, Atlanta, Oct-Nov. 2001.

[BAR01c] Barán, B., Vallejos J., Ramos R. y Fernández U., “Reactive Power Compensation Using a Multi-Objective Evolutionary Algorithm''. En Proc. IEEE 2001 Porto Power Tech, Porto, Set. 2001.

[BOO93] Boone, G. y Chiang H., “Optimal Capacitor Placement in Distribution Systems by Genetic Algorithm”. Electrical Power & Energy Systems, vol. 15, no. 3, pp. 155-162, 1993.

[BOU05] BOUKTIR T. y SLIMANI L., “Optimal Power Flow of the Algerian Electrical Network using an Ant Colony Optimization Method”. En Leonardo Journal of Sciences de Amici Publishing House editores, diciembre 2005.

[BUC78] Bucannan B.G. y Feigenbaum E.A. Dendral and Metadendral: Their Applications Dimension. Artificial Intelligence, 5-24, Nov.1978.

[BUN82] Bunch, J., Miller R. y Wheeler J., “Distribution System Integrated Voltage and Reactive Power Control”. in IEEE Trans. on Power Apparatus and Systems, vol 101, no. 2, pp. 284-289, Feb. 1982.

[CAP83] Capacitor Subcommittee of the IEEE Transmision and Distribution Committee, “Bibliography on Power Capacitors 1975-1980”. in IEEE Trans. on Power Apparatus and Systems, vol. 102, no. 7, pp. 2331-2334, July 1983.

[CAR00] Carlisle, J. y El-Keib A., “A Graph Search Algorithm for Optimal Placement of Fixed and Switched Capacitors on Radial Distribution Systems”. in IEEE Trans. on Power Delivery, vol. 15, no.1, pp. 423-428, Jan. 2000.

[CHA69a] Chang, N., “Generalized Equations on Loss Reduction with Shunt Capacitors”. in IEEE Trans. on Power Apparatus and Systems, vol. 91, 1574-1577, 1969.

[CHA69b] Chang, N., "Locating Shunt Capacitors on Primary Feeders for Voltage Control and Loss Reduction”. in IEEE Trans. on Power Apparatus and Systems, vol. 88, no. 10, pp. 1574-1577, Oct. 1969.

[CHA95] Chang H.C. y Wang M.H.. Neural Network-Based Self-Organizing Fuzzy Controller for Transient Stability of Multimachine Power Systems. IEEE Trans. Energy Conversion, 10(2): 339-347, 1995.

[CHA96] Chan P.H. y Chang H.C.. Genetic Aided Scheduling of Hydraulically Coupled Plants in Hydrothermal Coordination. IEEE Trans. Power Systems, 11(2): 975-981, 1996.

[CHA98] Chang C.S., Fu W., y Wen F.. Load Frequency Control using Genetic Algorithm Based Fuzzy Gain Scheduling of PI Controller. Electrical Machines and Power Systems, 26(1): 39-52, 1998.

[CHA00a] Charytoniuk W. y Chen M.S.. Very Short Term Load Forecasting using Artificial Neural Network. IEEE Trans. Power Systems, 15(1): 263-268, 2000.

[CHA00b] Chan W.L.,. So A.T.P y. Lia L.L. Initial Application of Artificial Neural Network to Load Flow Analysis. IEE Proceedings- Generation Transmission and Distribution, 147(6): 361-366, 2000.

[CHE95a] Chebbo A.M. y Irving M.R.. Combined Active and Reactive Power Dispatch Part 1: Problem Formulation and Solution Algorithm. IEE Proceedings- Generation Transmission and Distribution, 142(4):393-400, 1995.

[CHE95b] Chebbo A.M., Irving M.R., y Dandachi N.H.. Combined Active and Reactive Power Dispatch Part 2: Test Results. IEE Proceedings-Generation Transmission and Distribution, 142(4):401-405, 1995.

[CHE00a] Cheng C.P., Liu C.W., y Lin C.C.. Unit Commitment by Lagrangian Relaxation and Genetic Algorithms. IEEE Trans. Power Systems, 15(2): 707-714, 2000.

[CHE00b] Chen Z. y Mann J.C.. Artificial Neural Network Approach to Single Ended Fault Locator for Transmission Lines. IEEE Trans. Power Systems, 15(1): 370-375, 2000.

[CHI95] Chin, H., "Optimal Shunt Capacitor Allocation by Fuzzy Dynamic Programming". Electric Power Systems Research, vol. 35, pp. 133-139, 1995.

[CHI97] Chis, M., Salama M., and Jayaram S., "Capacitor Placement in Distribution Systems using Heuristics Search Strategies". IEE Proceedings Generation, Transmission and Distribution, vol. 144, no. 2, pp. 225-230, May 1997.

[CHR96] Christoforidis M., Aganagic M., Awobamise B., Tong S., y. Rahimi A.F. Long-Term/Mid-Term Resource Optimization of a Hydro-Dominant Power System using Interior Point Methods. IEEE Trans. Power Systems, 11(1):287-294, 1996.

[CHR00] Christie, R., "Power Systems Test Case Archive". Electrical Engineering Dept., University of Washington, Apr. 2000. . Available: http://www.ee.washington.edu/research/pstca.

[CIG91] CIGRE Task Force 38-06-02, Survey on Expert System in Alarm Handling, Electra, Vol. 139:133-151, 1991.

[CIV85a] Civanlar, S. y Grainger J., "Volt/VAR Control on Distribution Systems with Lateral Branches Using Shunt Capacitors and Voltage Regulators, Part II: The solution method". in IEEE Trans. on Power Apparatus and Systems, vol. 104, no. 11, pp. 3284-3290, Nov. 1985.

[CIV85b] Civanlar, S. y Grainger J., "Volt/VAR Control on Distribution Systems with Lateral Branches Using Shunt Capacitors and Voltage Regulators, Part III: The numerial results". in IEEE Trans. on Power Apparatus and Systems, vol. 104, no. 11, pp. 3291-3297, Nov. 1985.

[CIV88] Civanlar, S., Grainger J., Yin H., y Lee S., "Distribution Feeder Reconfiguration for Loss Reduction". in IEEE Trans. on Power Delivery, vol. 3, no. 3, pp. 1217-1223, July 1988.

[COE96] Coello, C., "An empirical study of Evolutionary Techniques for multi objective optimization in Engineering Design". PhD Thesis, Department of Computer Science, Tulane University, New Orleans, April, 1996.

[COE99] Coello, C., "A comprehensive Survey of Evolutionary-based Multiobjective Optimization Techniques". in Knowledge and Information Systems: An International Journal, vol. 1, no. 3, pp. 269-308, Aug. 1999.

[COH78] Cohon, J., Multiobjective Programming and Planning, New York: Academic Press, 1978.

[COO59] Cook, R., "Analysis of Capacitor Application as Affected by Load Cycle". in AIEE Trans., vol. 78, pp. 950-957, Oct. 1959.

[COO61] Cook, R., "Optimizing the Application of Shunt Capacitors for Reactive-volt-ampere Control and Loss Reduction". in AIEE Trans., vol. 80, pp. 430-444, Aug. 1961.

[DAI99] Dai X.Z., He D., Fan L.L., Li N.H., y Chen H.. Improved ANN Alpha Th-Order Inverse TCSC Controller for Enhancing Power System Transient Stability. IEE Proceedings- Generation Transmission and Distribution, 146(6): 550-556, 1999.

[DAP75] Dapezo J.F. y Merill H.M.. Optimal Generator Scheduling with Integer Programming. IEEE Trans. Power Apparatus and Systems, PAS-94 (3): 1537-1545, 1975.

[DAR85] Darwin, C., On the Origins of Species by Means of Natural Selection, 6th edition, Penguin Classics, 1985.

[DAR01] Darwish H.A. y Taalab A.M.I.. Development to Implementation of ANN-Based Fault Diagnosis Scheme for Generator Winding Protection. IEEE Trans. Power Delivery, 16(2): 200-207, 2001.

[DAS96] Dash P.K., Liew A.C., y Rahman S.. Fuzzy Neural Network and Fuzzy Expert Systems for Load Forecasting. IEE Proceedings - Generation Transmission and Distribution, 143(1): 106-114, 1996.

[DAV91] David A.K. y Zhao R.. An Expert Systems With Fuzzy Sets for Optimal Long Range Operation Planning. IEEE Trans. Power Systems, 6(1):59-65, 1991.

[DEB99a] Deb K., "Evolutionary algorithms for multi-criterion optimization in engineering design", Proceedings of the Evolutionary Algorithms in Engineering and Computer Science (EUROGEN'99), 1999.

[DEB99b] Deb, K. "Non-linear Goal Programming Using Multi-objective Genetic Algorithms". Technical Report TR CI-60/98, University of Dortmund, Germany: Department of Computer Science/XI. 1999.

[DEE90] Deeb N. y Shahidehpour S.M.. Linear Reactive Power Optimization in a Large Power Network Using the Decomposition Approach. IEEE Trans. Power Systems, 5(2):428 – 438, 1990.

[DEL00] Delfanti M., Granelli G.P., Marannino P., y Montagna M.. Optimal Capacitor Placement using Deterministic and Genetic Algorithms. IEEE Trans. on Energy Conversion, 15(3): 1041-1046, 2000.

[DIL78] Dillon T.S., Edwin K.W., Kochs H.D., y Tand R.D.. Integer Programming Approach to the Problem of Unit Commitment with Probabilistic Reserve Determination. IEEE Trans. Power Apparatus and Systems, PAS-97(6): 2154-2166, 1978.

[DIL90] Dillon T.J. y Laughton MA.. Expert System Application in Power Systems. Prentice Hall, Londres, 1990.

[DJU96] Djukanovi M., Alovi M., Miloevi B., y Sobajic D.J.. Neural-Net Based Real-Time Dispatch for Thermal Power Plants. IEEE Trans. Energy Conversion, 11(4): 755-761, 1996.

[DON04] Donoso, Y., Fabregat, R. y Marzo, J. "Multi-objective Optimization Algorithm for Multicast Routing with Traffic Engineering", *IEEE 3rd International Conference on Networking* (ICN´2004), Guadalupe – Caribe Francés, 2004

[DOR92] Dorigo M., Optimization, learning and natural algorithms, disertación de Ph.D. Departatimento di Electtronica, Politecnico di Milano, Italia, 1992.

[DOR96] Dorigo M., Maniezzo V., y Colorni A.. The Ant System: Optimization by a Colony of Co-Operating Agents. IEEE Trans. Systems, Man and Cybernetics, 26(1): 29-41, 1996.

[DOR01] Dorigo M. y Stützle T.. *"An Experimental Study of the Simple Ant Colony Optimization Algorithm*". En 2001 WSES International Conference on Evolutionary Computation (EC'01). WSES-Press International, 2001.

[DUR05] Durairaj Mr. S., Kannan Dr. P.S., y Devaraj Dr. D. "Multi-Objective VAR Dispatch Using Particle Swarm Optimization", International Journal of Emerging Electric Power Systems: Vol. 4: No. 1, Article 1082, diciembre del 2005. Accesible en la siguiente dirección web: http://www.bepress.com/ijeeps/vol4/iss1/art1082

[DUR68] Duran, H., "Optimum Number, Location, and Size of Shunt Capacitors in Radial Distribution Feeders, A dynamic programming approach". in IEEE Trans. on Power Apparatus and Systems, vol. 87, no. 9, pp. 1769-1774, Sept. 1968.

[DWY92] Dwyer, A., "The Use of Shunt Capacitors Applied for Line Loss Savings". in Proc. 1992 CEA Conference, Apr. 1992.

[EBE95] Eberhart, R. C. and Kennedy, J. A new optimizer using particle swarm theory. Proceedings of the Sixth International Symposium on Micromachine and Human Science, Nagoya, Japan. pp. 39-43, 1995

[EBR90] Ebrom S., Lubkeman D.L. y White M.. A Neural Network Approach to the Detection of the Incipient Faults on Power Distribution Feeders. IEEE Trans. Power Delivery, 5(2):505-514, 1990.

[ELI00] Elithy K. y Al-Naamany A., Hybrid A. Neuro Fuzzy Network (ANN) and Static VAR Compensator for Stabilizer System Damping Improvement in the Presence of Load Parameters Uncertainty. Electric Power Systems Research, 56(3): 211-223, 2000.

[ESM05] Esmin, A.A.A.; Lambert-Torres, G.; Zambroni de Souza, A.C. A Hybrid Particle Swarm Optimization applied to Loss Power Minimization, en IEEE Transaction on Power System, vol. 20 issue 2, pp. 859-866, mayo 2005.

[FAL98] Falcao, D., Análise de Redes Elétricas, Rio de Janeiro: COPPE/UFRJ., 1998.

[FAW83] Fawsi, T., El-Sobki S. y Abdel-Halim M., “New approach for the Application of Shunt Capacitors to the Primary Distribution Feeders”. in IEEE Trans. on Power Apparatus and Systems, vol. 102, no. 1, pp. 10-13, enero. 1983.

[FON95a] Fonseca, C. y Fleming, P. “An Overview of Evolutionary Algorithm in Multiobjective Optimization”. Evolutionary Computation, vol. 3, no. 1, pp 1-16, Spring 1995.

[FON95b] Fonseca, C. y Fleming P., “Multiobjective Optimization and Multiple Constraint Handling with Evolutionary Algorithms I: A Unified Formulation." Technical Report 564, Department of Automatic Control and System Engineering. University of Sheffield. Sheffield, UK: January 1995.

[FUK94] Fukuyama Y. y Ueki Y.. An Application of Neural Network to Dynamic Dispatch using Multi Processors. IEEE Trans. Power Systems, 9(4): 1759- 1765, 1994.

[GAL97] Gallego R.A., Alves A.B., Monticelli A., y Romero R.. Parallel Simulated Annealing Applied to Long Term Transmission Network Expansion Planning. IEEE Trans. Power Systems, 12(1): 181-188,1997.

[GAN95a] Gan D., Hayashi Y., y Nara K.. Multi-Level Reactive Resource Planning by Tabu Search. Proc. of IEE of Japan Power and Energy, Nagoya, Japan, 137-142, 1995.

[GAN95b] Gan D., Qu Z., y Cai H.. Large Scale VAR Optimization by Tabu Search. Electric Power System Research, 39(3): 195-204, 1995.

[GAR04] Gardel P., Gómez O. y Barán B. *"Analisis del Omicron ACO con optimización local",*. Congreso Argentino de Ciencias de la Computación - CACIC'2004. Bs. Aires – Argentina 2004.

[GAR05] Gardel P., Barán B., Fernández U. y Estigarribia H., Aplicación del Ómicron ACO al problema de Compensación de Potencia Reactiva en un contexto Multiobjetivo". En el Congreso Argentino de Ciencias de la Computación - CACIC'2005. Concordia – Argentina. 2005.

[GAR06] Gardel P., Baran B., Fernandez U., Estigarribia H y Duarte S.; Multiobjective Reactive Power Compensation with an Ant Colony Optimization Algorithm, a aparecer en proceedings de 8th International Conference AC and DC Power Transmission, en Londres Inglaterra, marzo 2006.

[GEO72] Geoffrion A.M.. Generalized Benders Decomposition. Journal Of Optimization Theory Applications, 10(4) 237-261, 1972.

[GHO98] Ghosh S. y Chowdhury B.H., Security Constrained Optimal Rescheduling of Real Power using Hopfield Neural Network. IEEE Trans. Power Systems, 11(4): 1743-1748, 1996.

[GLO89] Glover F.. Tabu Search – Part 1. ORSA Journal on Computing, 1(3): 190- 206, 1989.

[GLO90] Glover F., Tabu Search – Part 1. ORSA Journal on Computing, 2(1): 4-32, 1990.

[GLO93] Glover F., Laguna M., Tallard E. y de Werra D.. Tabu Search. Science Publishers, Basel, Switzerland, 1993.

[GLO97] Glover F. y Laguna M.. Tabu Search. Kluwer Academic Publishers, Boston, USA, 1997.

[GOL89] Goldberg D.E.. Genetic Algorithms in Search, Optimization and Machine Learning. Addison-Wesley, New York, 1989.

[GOM04a] Gómez O. y Barán B., "Òmicron ACO". En Proceedings de la Conferencia Latinoamericana en Informática (CLEI'04). Septiembre 2004.

[GOM04b] Gómez O., "Razones del Éxito de Optimización por Colonia de Hormigas en el Problema del Cajero Viajante". Tesis de Maestria. Universidad Nacional de Asunción. Septiembre 2004.

[GON81] Gonen T. y Foote B.L.. Distribution System Planning using Mixed Integer Programming. IEE Proceedings-Generation, Transmission and Distribution, 128(2): 70-79, 1981.

[GON83] Gonen T. y Mahmoud A.A.. Bibliography of Power Distribution System Planning. IEEE Trans. Power Apparatus and Systems, PAS-102(6):1778-1787, 1983.

[GRA81] Grainger, J. y Lee S., “Optimum Placement of Shunt Capacitors for Reduction of Losses on Distribution Feeders”. in IEEE Trans. on Power Apparatus and Systems, vol. 100, no. 3, pp. 1105-1118, Mar. 1981.

[GRA85] Grainger, J. y Civanlar S., “Volt/VAR Control on Distribution Systems with Lateral Branches Using Shunt Capacitors and Voltage Regulators, Part I: The overall problem”. in IEEE Trans. on Power Apparatus and Systems, vol. 104, no. 11, pp. 3278-3283, Nov. 1985.

[GRA88] Granville S., Pereira M.V.F., y Monticelli A.. An Integrated Methodology for VAR Source Planning. IEEE Trans. Power Systems, 3(2):549-557, 1988.

[GRA94] Granville S.. Optimal Reactive Dispatch Through Interior Point Methods. IEEE Trans. Power Systems, 9(1): 136-144, 1994.

[GU96] Gu, Z. y Rizy D., “Neural Networks for Combined Control of Capacitor Banks and Voltage Regulators in Distribution Systems”. in IEEE Trans. on Power Delivery, vol. 11, no. 4, pp. 1921-1928, Ost. 1996.

[HAI91] Haida T. y. Akimoto A. Voltage Optimization using Genetic Algorithm. Proc. 3rd Symposium on Expert System Applications to Power Systems, Tokyo, Japan, 375-380, 1991.

[HAP77] Happ H.H.. Optimization Power Dispatch – A Comprehensive Survey. IEEE Trans. Power Apparatus and Systems, PAS-96(2):841-854, 1977.

[HEG83] Hegdt G.T. y Grady W.M.. Optimal Var Siting Using Linear Load Flow Formulation. IEEE Trans. Power Apparatus and Systems, PAS-102 (5):1214-1222, 1983.

[HEI00] Heitkoetter, Joerg y Beasley. “The Hitch-Hiker's Guide to Evolutionary Computation: A list of Frequently Asked Questions (FAQ)'', USENET: comp.ai.genetic. Available via anonymous FTP from rtfm.mit.edu/pub/usenet/news.answers/ai-faq/genetic/ About 110 pages. 2000.

[HIG93] Highly D.D. y Hilmes T.J.. Load Forecasting by ANN. IEEE Computer Applications in Power, 6(3) 10-15, 1993.

[HIP01] Hippert H.S., Pedeira C.E., y Hamadanizadeh H.. Neural Network for Short-Term Load Forecasting. IEEE Trans. Power Systems, 16(1): 44-55, 2001.

[HIY97] Hiyama T., Ueki Y., Andou H.. Integrated Fuzzy Logic Generator Controller for Stability Enhancement. IEEE Trans. Energy Conversion, 12(4): 400 –406, 1997.

[HO92] Ho K.L., Hsu Y.Y., y Yang C.C.. Short Term Load Forecasting using a Multilayer Neural Network with an Adaptive Learning Algorithm. IEEE Trans. Power Systems, 7(1): 141-149, 1992.

[HOB88] Hobbs W.J., Hermon G., Warner S., y Sheble G.B.. An Enhanced Dynamic Approach for Unit Commitment. IEEE Trans. Power Systems, 3(3):1201-1205, 1988.

[HOL75] Holland, J., Adaptation in Natural and Artificial Systems, Ann Harbor: Univ. of Michigan Press, 1975.

[HOR94] Horn, J., Nafpliotis N. y Golberg D., “A Niched Pareto Genetic Algorithm for Multiobjective Optimization”. in Proc. of the First IEEE Conference on Evolutionary Computation, IEEE World Congress on Computational Intelligence, vol. 1, pp. 82-87, Piscataway, USA, June 1994.

[HOR97] Horn, J., "The nature of niching: genetic algorithms and the evolution of optimal, cooperative population". PhD thesis, University of Illinois at Urbana-Champaign, Urbana, Illinois. 1997.

[HSU91] Hsu Y.Y. y Yang C.C.. Design of Artificial Neural Networks for Short Term Load Forecasting. Part I and II. IEE Proceedings- Generation, Transmission and Distribution, 138(5): 407-418, 1991.

[HSU95] Hsu L.R. y Yih H.Y. A Hybrid Artificial Neural Network-Differential Dynamic Programming Approach for Short-Term Hydro Scheduling. Electric Power System Research, 33(2): 77-86, 1995.

[HUA96] Huang Y.C., Yang H.T., y Haung C.L.. Solving the Capacitor Placement Problem in a Radial Distribution System using Tabu Search Approach. IEEE Trans. Power Systems, 11(4): 1868-1873, 1996.

[HUG96] Hugh R., Palma R., Cura E., y Silva C.. Economically Adapted Transmission System in Open Access Schemes - Application of Genetic Algorithm. IEEE Trans. Power Systems, 11(3): 1427-1440, 1996.

[HUN91] Huneault M. y Galiana F.D.. A Survey of the Optimal Power Flow Literature. IEEE Trans. Power Systems, 6(2): 762-770, 1991.

[HWA79] Hwang, C. y Masud A., Multiple Objective Decision Making – Methods and Applications: A State of the Art Survey. Springer-Verlarg. 1979

[IBA94] Iba K.. Reactive Power Optimization by Genetic Algorithm. IEEE Trans. Power Systems, 9(2): 685- 692, 1994.

[IEE80] IEEE Committee Report. Load Forecasting, Bibliography, Phase-1. IEEE Trans. Power Apparatus and Systems, PAS-99(1): 53-58, 1980.

[IEE81] IEEE Committee Report. Load Forecasting, Bibliography, Phase-2. IEEE Trans. Power Apparatus and Systems, PAS-100(7):3217-3220,1981.

[IEE97] IEEE VAR Management Working Group of the IEEE System Control Subcommittee, "Bibliography on Reactive Power and Voltage Control". in IEEE Trans. on Power Systems, vol. 2, no. 2, pp. 361-370, May 1997.

[IRR98] Irrisari G.D., Kimball L.M., Clements K.A., Bagchi A. y Davis P.W.. Economic Dispatch with Network and Ramping Constraints via Interior Point Methods. IEEE Trans. Power Systems, 13(1):236-242, 1998.

[IRV00] Irving M.R. y Song Y.H.. Optimization Methods for Electric Power Systems, Part 1, Mathematical Optimization Methods. IEE Power Engineering Journal, 14 (5):245-254, 2000.

[JAC91] Jackson, R., "Guidelines for Reporting Results of Computational Experiments". Report of the Ad Hoc Comitte. Mathematical Programming, vol. 49, pp. 413-425. 1991.

[JWO95] Jwo W.S., Liu C.W., Liu C.C., y Hsiao Y.T.. Hybrid Expert System and Simulated Annealing Approach to Optimal Reactive Power Planning. IEE Proceedings- Generation Transmission and Distribution, 142(4): 381-385, 1995.

[KAR97] Karaki S.H., Deba A.S., y Saliva Y.E.. Multi-Machine Classical Transient Stability using ANN. Int. Journal of Power and Energy Systems, 19(1): 49-55, 1997.

[KAZ96] Kazarlis S.A., Bakirtzis A.G., y Petridis V.. A Genetic Algorithm Solution to Unit Commitment Problem. IEEE Trans. Power Systems, 11(1): 83-92,1996.

[KIM94] Kim H., Nara K., y Gen M.. A Method for Maintenance Scheduling using GA Combined with SA. Computers and Industrial Engineering, 27(4): 477- 480, 1994.

[KIM95] Kim K.H., Park K. J., Hwang K. J., y Kim S.H.. Implementation of Hybrid Short Term Load Forecasting using Artificial Neural Networks and Fuzzy Expert Networks. IEEE Trans. Power Systems, 10(3): 1534-1539, 1995.

[KOT88] Kothari D.P.. Optimal Hydrothermal Scheduling: A Review. Journal of Scientific and Industrial Research, Vol. 47: 98-101, Feb. 1988.

[KOT89] Kothari D.P.. Optimal Stochastic Hydrothermal Scheduling using Nonlinear Programming Technique Presented Australian Society, Melbourne (Australia), 335-344, 1989.

[KRU00] Krunic S., Krcmar I., y Rajakovic N.. An Improved Neural Network Approach for Short-Term Load Forecasting. Electric Machines and Power Systems, 28(8): 703-722, 2000.

[KUL99] Kulkarni P.S., Kothari A.G., y Kothari D.P.. Adaptive BP NN Approach to Emission Constrained Economic Dispatch. Proc. CBIP Int. Conference., Nueva Deli (India), pp. viii-1-10, 1999.

[KUL00] Kulkarni P.S., Kothari A.G., y Kothari D.P.. Combined Economic Dispatch Unit using Economic Improved Back Propagation Neural Network. Electric Machines and Power Systems, 28(8): 31-44, 2000.

[KUM95] Kumar J. y Sheble G.. Clamped State Solution of Artificial Neural Network for Real Time Economic Dispatch. IEEE Trans. Power Systems, 10(2): 925-931, 1995.

[KUN93] Kundur, P., Power Systems Stability and Control, Neava York: Mc Graw-Hill, 1993.

[LAF95] Laframboise, J., Ferland G., Chikhani A. y Salama M., “An Expert System for reactive Power Control of a Distribution Systems, Part II: System Implementation”. in IEEE Trans. on Power Delivery, vol. 10, no. 3, pp. 1433-1441, Aug. 1995.

[LAK88] Lakshmi P. y Khan M.A.. Stability Enhancement of a Multi-Machine Power System using Fuzzy Logic Based Power System Stabilizer Tuned Through Genetic Algorithm. Int. Journal of Electrical Power and Energy Systems, 22(2): 137-145, 2000.

[LAM96] Lamedica R., Prudenzi A., Sofrna M., Caciottas M., y Cencelli V.O.. A Neural Network Based Technique for Short Term Load Forecasting. IEEE Trans. Power Systems, 11(4): 1749-1756, 1996.

[LAN02] Landa R.. "Algoritmos Culturales Aplicados a Optimización con Restricciones y Optimización Multiobjetivo". Tesis de Maestría, Centro de Investigación y Estudios Avanzados, Instituto Politécnica Nacional. México, 2002.

[LEE81] Lee, S. y Grainger J., “Optimum Placement of Fixed and Switched Capacitors on Primary Distribution Feeders”. in IEEE Trans. on Power Apparatus and Systems, vol. 100, no. 1, pp. 345-352, Jan. 1981.

[LEV00] Levitin, G., Kalyuzny A., Shenkman A. y Chertkov M., "Optimal Capacitor Allocation in Distribution Systems Using a Genetic Algorithm and a Fast Energy Loss Computatation Technique". in IEEE Trans. on Power Delivery, vol. 15, no. 2, pp. 623-328, April 2000.

[LIA94] Liang R.H. y Hsu Y.Y.. Scheduling of Hydroelectric Generations using Artificial Neural Networks. IEE Proceedings- Generation Transmission and Distribution, 141(5): 452-458, 1994.

[LIB04] Libao Shi, Hao Jin, Zhou Jiaqi, Xu Guoyu; Short-term generation scheduling with reliability constrains using ant colony optimization algorithm. En WCICA 2004, Fifth World Congress on Intelligent Control and Automation, Hangzhou, China

[LIN03] Lin Zhao-hua, Li-Juan Lu, Yun-He Hou, Xin-Yin Xiong; Generalized ant colony optimization algorithm for reactive power optimization in power systems. En Journal of N.C.E.P. marzo 2003.

[LIU92] Liu, C. y Dillon T., "State-of-the-art of Expert Systems Applications to Power Systems". Electrical Power & Energy Systems, vol. 14, no. 2, pp. 86-92, 1992.

[LIU93] Liu C.C., Practical Use of Expert Systems in Planning and Operation of Power Systems. Electra, 141:31-67, Feb. 1993.

[LIU94] Liu C.C., Ma T.K., Liou K.L., y Tsai M.S.. Practical Use of Expert Systems in Power Systems. Int. Journal on Engineering Intelligent Systems, 2(1): 11-22, 1994.

[LIU98] Liu C.W., Chang C.S., y Su. M.C. Neuro-Fuzzy Networks for Voltage Security Monitoring Based on Synchronized Phasor Measurements. IEEE Trans. Power Systems, 13(2):326-332, 1998.

[LIU99a] Liu C.W., Su M.C., Tsay S.S., y Wang Y.J.. Application of a Novel Fuzzy Neural Network to Real-Time Transient Stability Swings Prediction Based on Synchronized Phasor Measurements. IEEE Trans. Power Systems, 14(2): 685 –692, 1999.

[LIU99b] Liu C.W., Tsay S.S., Wang Y.J., y Su M.C. Neuro-Fuzzy Approach to Real-Time Transient Stability Prediction Based on Synchronized Phasor Measurements. Electric Power System Research, 49(2): 123-127, 1999.

[LU95] Lu F.C. y Hsu Y.Y.. Reactive Power/Voltage Control in a Distribution Substation using Dynamic Programming. IEE Proceedings-Generation Transmission and Distribution, 142(6):639-645, 1995.

[MA95] Ma, J. y Lai L., "Application to Optimal Reactive Power Dispatch Including Voltage-Dependent Load Models". in IEEE, 1995.

[MA96] Ma J.T., Lai L.L., Liang R.H., y Hsu Y.Y.. Short-Term Hydro- Scheduling using Hopfield Neural Network Evolutionary Programming Approach to Reactive Power Planning. IEE Proceedings- Generation Transmission and Distribution, 143(3): 269-275, 1996.

[MAD96] Madina J., Conejo A.J., Jimenez N.R., Thoden F.P., y Gonzalez J.. A LP Based Decomposition Approach to Solve The Medium Term Hydrothermal Coordination Problem. Proc. 12th Power System Computation Conf., Dredson, Germany, 1397-1405, 1996.

[MAD00] Madnani S.. Radial Basis Function (RBF) Network Adaptive Power System Stabilizer. IEEE Trans. on Power Systems, 15(2):722-727, 2000.

[MAM99a] Mamoh J.A., El Hawary M.E., y Adapa R.. A Review of Selected Optimal Power Flow Literature to 1993, Part-I: Non-Linear and Quadratic Programming Approach. IEEE Trans. Power Systems, 14(1):96-104, 1999.

[MAM99b] Mamoh J.A., El Hawary M.E., y Adapa R.. A Review of Selected Optimal Power Flow Literature to 1993, Part-II: Newton, Linear Programming and Interior Point Methods. IEEE Trans. Power Systems, 14(1):105-111, 1999.

[MAR91] Marx, T., The Why and How of Power Capacitor Switching. Fischer Pierce, Mar. 1991.

[MAR94] Marpaka D.R., Bodruzzaman M., Devagan S.S., Aghili S.M., y Kari S.. Neural Network Based Transient Stability Assessment of Electric Power Systems. Electric Power System Research, 30(1): 251-256, 1994.

[MEL97] Mello J.C.O., Melo A.C.G., y Granville S.. Simultaneous Capability Assessment by Combining Interior Point Method and Monte Carlo Simulation. IEEE Trans. Power Systems, 12(2):736-742, 1997.

[MEN98] Mentaway A.H., Abdel-Magid Y.L., y Selim S.Z.. A Simulated Annealing Algorithm for Unit Commitment. IEEE Trans. Power Systems, 13(1): 197-204,1998.

[MIR94] Miranda V., Ranito J. V., y Proenca L.M.. Genetic Algorithms in Optimal Multistage Distribution Network Planning. IEEE Trans. Power Systems, 9(4): 1927-1933, 1994.

[MIR95] Miranda V., Fidalgo J.N., Lopes J.A.P., y Almeida L.B.. Real Time Preventive Actions for Transient Stability Enhancement with a Hybrid Neural Network-Optimization Approach. IEEE Trans. Power Systems, 10(2): 1029 –1035, 1995.

[MIU97] Miu, K., Chiang H., y Darling G., “Capacitor Placement, Replacement and Control in Large-scale Distribution Systems by GA-based Two-stage Algorithm”. in IEEE Trans. on Power Systems, vol. 12, no. 3, pp. 1160-1166, Aug. 1997.

[MOG00] Moghivvemi M. y Yang S.S.. ANN Application Techniques for Power System Stabilizer. Electric Machines and Power Systems, 28(2): 167-178, 2000.

[MOM94] Momoh J.A., Guo S.X., Ogbuoriri E.C., y Adapa R.. The Quadratic Interior Point Method Solving Power System Optimization Problems. IEEE Trans. Power Systems, 9 (3):1327-1336, 1994.

[MOM95] Momoh J.A., Ma X.W., y Tomsovic K.. Overview and Literature Survey of Fuzzy Set Theory in Power Systems. IEEE Trans. Power Systems, 10(3): 1676-1690, 1995.

[MOR80] Morse, J., “Reducing the size of the nondominated set: pruning by clustering”. Comput. Oper. Res., vol 7, no. 1 y 2. 1980.

[MOR96] Mori H. y Usami T.. Unit Commitment using Tabu Search with Restricted Neighborhood. Proc. of Int. Conf. on Intelligent Systems Applications to Power Systems, Orlando, USA, 422-427, 1996.

[MOR01] Mori H. y Yuithara A.. Deterministic Annealing for ANN-Based Short-Term Load Forecasting. IEEE Trans. Power Systems, 16(3): 545-551, 2001.

[NAN89] Nanda J., Kothari D.P., y Srivastava S.C.. A New Optimal Power Dispatch Algorithm using Fletcher's QP Method. IEE Proceedings, Generation Transmission and Distribution, 136(3):153-161, 1989.

[NAR91] Nara K., Satoh T., Aoki K., y Kitagawa M.. Multilayer Expansion Planning for Distribution Systems Distribution Network Planning. IEEE Trans. Power Systems, 6(3): 952-958, 1991.

[NAR00] Naresh R. y Sharma J.. Hydro System Scheduling Using ANN Approach. IEEE Trans. Power Systems, 15(1): 388-395, 2000.

[NEA56] Neagle, N. y Samson D., "Loss Reduction from Capacitors Installed on Primary Feeders;" in AIEE Trans., vol. 75, pp. 950-959, Oct. 1956. "

[NG00] Ng, H., Salama M. y Chikhani A., "Classification of Capacitors Allocation Techniques". in IEEE Trans. on Power Delivery, vol. 15, nº 1, pp. 387-392, Jan. 2000.

[NIB92] Nibur D. y Germond A.J.. Power System Static Security Assessment using the Kohonen Neural Network Classifier. IEEE Trans. Power Systems, 7(2):865-872,1992.

[NIE96] Niebur D. y Dillon T.S., Neural Network Applications in Power Systems, CRL Publishing Ltd. U.K. 1996.

[OPO90] Opoku G.. Optimal Power System VAR Planning. IEEE Trans. Power Systems, 5(1): 53-59, 1990,.

[ORE96] Orero O.S. y Irving. M.R. A Genetic Algorithm for Generator Scheduling in Power System. Int. Journal of Electrical Power and Energy Systems, 18(1): 19-26,1996.

[ORE98] Orero O.S. y Irving M.R.. A Genetic Algorithm Modeling Framework and Solution Technique for Short Term Optimal Hydrothermal Scheduling. IEEE Trans. Power Systems, 13(2): 501-518, 1998.

[PAL91] Pal S.K. y Mandal D.P.. Fuzzy Logic and Approximate Reasoning: An Overview. Journal of Institution of Electronics and Telecommunication Engineers, Paper No. 186-C, 548-559, 1991.

[PAN92] Pannambalam K., Quintana V.H., y Vannelli A.. A Fast Algorithm for Power System Optimization using Interior Point Method. IEEE Trans. Power Systems, 7(2):892-899, 1992.

[PAR90] Parten J.. A Simplified Modified Dynamic Programming Algorithm for Sizing Location and Feeder Reinforcements. IEEE Trans. Power Delivery, 5(1): 277-283, 1990.

[PAR00] Park J.B., Park Y.M., y Lee K.Y.. An Improved Genetic Algorithm for Transmission Network Expansion Planning. IEEE Trans. Power Systems, 15(3): 916-922, 2000.

[PAR91] Park D.. Electric Load Forecasting Using an Artificial Neural Network. IEEE Trans. Power Systems, 6(2): 442-449, 1991.

[PAR97] Park Y. M., Park J. B., y Won J. R., A Hybrid Genetic Algorithm/Dynamic Programming Approach To Optimal Long-Term Generation Expansion Planning, Int. Journal of Electrical Power and Energy Systems, 20(4): 295-303, 1997.

[PEN92] Peng T.M., Hubele N.F., y Karady G.G., Advancement in the Application of Neural Network for Short Term Load Forecast. IEEE Trans. Power Systems, 7(1), 1992, 250-257.

[PER85] Pereira M.V.F, Pinto L.M.V.G., Cunha S.H.F., y Oliveira C.G.. Decomposition Approach to Automated Generation/Transmission Expansion Planning. IEEE Trans. Power Apparatus and Systems, PAS-104 (11):3074-3083, 1985.

[PIN01] Pinguelli, L., Un País em Leilao: das Privatizacoes a Crise Energetica, Rio de Janeiro: Ed. COPPE/UFRJ, 2001.

[PON83] Ponnavaikko, M. y Prakasa Rao K., “Optimal Choice of Fixed and Switched Shunt Capacitors on Radial Distributors by the Method of Local Variations”. in IEEE Trans. on Power Apparatus and Systems, vol. 102, no. 6, pp.1607-1615, June 1983.

[QUI00] Quintana V.H., Torres G.L., y Palomo J.M.. Interior-Point Methods and Their Applications to Power Systems: A Classifications of Publications and Software. IEEE Trans. Power Systems, 15(1): 170-176, 2000.

[RAH93] Rahman R.. Artificial Intelligence in Electric Power System's Survey in Japanese Industry. IEEE Trans. Power Systems, 8(3):1211-1218, 1993.

[RAM96] Ramos J.L. M., Exposito A.G., y Quintana V.H.. Reactive Power Optimization by Quadratic Interior Point Method: Implementation Issues. Proc. 12th Power System Computation Conf., Dredson, Alemania, 1996.

[RAN95] Ranaweera D.K., Hubele N.F., y Papalexopoulos A.D.. Application of Radial Basis Function Neural Network Model to Short Term Load Forecast. IEE Proceedings - Generation Transmission and Distribution, 142(1): 45-50, 1995.

[RIC00] Richter Jr. C.W. y Sheble G.B.. A Profit Based Unit Commitment GA for Competitive Environment. IEEE Trans. Power Systems, 15(2): 715-721, 2000.

[ROM96] Romero R., Gallego R.A., y Monticelli A.. Transmission System Expansion Planning by Simulated Annealing. IEEE Trans. Power Systems, 11(1): 364-369, 1996.

[ROY96] Roy A.D. y Goswami S.K.. Development of Artificial Neural Networks for Solving Capacitor Control Problem in Distribution Network. Proc. 9th National Power Systems Conference, IIT Kanpur (India), 413-416, 1996.

[SAC77] Sachdev M.S., Billinton R., y Peterson C.A.. Representative Bibliography on Load Forecasting. IEEE Trans. Power Apparatus and Systems, PAS-96(2): 697-700, 1977.

[SAF95] Saforna M. y Proverbio F., A Neural Network Operator Oriented Short-Term and On-Line Load Forecasting Environment. Electric Power Systems Research, 33(2): 139-149,1995.

[SAL85a] Salama, M., Chikhani A. y Hackam R., "Control of Reactive Power in Distribution Systems with an End-load and Fixed Load Conditions". in IEEE Trans. on Power Apparatus and Systems, vol. 104, no. 10, pp. 2779-2788, Oct. 1985.

[SAL85b] Salama, M., Mansour E., Chikhani A. y Hackam R., "Control of Reactive Power in Distribution Systems with an End-load and Varying Load Conditions". in IEEE Trans. on Power Apparatus and Systems, vol. 104, no. 4, pp. 941-947, Apr. 1985.

[SAN90] Santoso N.I. y Tan O.T.. Neural-Net Based Real-Time Control of Capacitors Installed on Distribution Systems. IEEE Trans. Power Delivery, 5(1): 266-272, 1990.

[SAT91] Satoh T. y Nara K.. Maintenance Scheduling by Using Simulated Annealing Method. IEEE Trans. Power Systems, 6(2) 850-857, 1991.

[SCH65] Schmill, J., "Optimum Size and Location of Shunt Capacitors on Distribution Feeders". in IEEE Trans. on Power Apparatus and Systems, vol. 84, no. 9, pp. 825-832, Sept. 1965.

[SCH95] Schaerer, Christian y Atlasovich, José. Tesis de grado para optar al titulo de Ingeniero Electromecánico, Facultad de Ingeniería, Universidad Nacional de Asunción – Paraguay 1995.

[SCO79] Scott B. y Marinho J.L.. Linear Programming for Power System Network Security Applications. IEEE Trans. Power Apparatus and Systems, PAS-98:837-845, May/June 1979.

[SEN98] Sen S. y Kothari D.P.. Optimal Thermal Generating Unit Commitment-A Review. Int. Journal of Electrical Power and Energy Systems, 20(7): 443-451, 1998.

[SHA84] Shaffer, J. "Multiple Objective Optimization with Vector Evaluated Genetic Algorithms", *Ph.D Thesis*, Vanderbilt University, USA, 1984

[SHA00] Sharma A. y Kothari M.L.. Adaptive Network Fuzzy Interference System Based Dual Input Power System Stabilizer. Proc. National Seminar on Sustainable Energy Options for the New Millennium, Jaipur (India), 240 – 249, 2000.

[SHA94a] Sharaf A.M. y Lie T.T.. Artificial Neural Network Pattern Classification of Transient Stability and Loss of Excitation for Synchronous Generation. Electric Power Systems Research, 30(1): 9-16, 1994.

[SHE94b] Sherkat V.R. y Ikura Y.. Experience With Interior Point Optimization Software for a Fuel Planning Application. IEEE Trans. Power Systems, 9(2):833-840, 1994.

[SHO94] Short M.J., Hui C.K., Macqeen J.F., y Ekwue A.O., Application of Artificial Neural Network for NGC Voltage Collapse Monitoring. CIGRE Symposium, Paris, Paper 28-205,1994.

[SIL00] da Silva E.L., Gill H.A., y Areiza J.M.. Transmission Network Expansion Planning Under an Improved Genetic Algorithm. IEEE Trans. Power Systems, 15(3): 1168-1175, 2000.

[SIN01] Singh D. y Singh S.P.. ANN Based Short Term Load Forecasting. Institution of Engineers (India), 82(3): 155-160, 2001.

[SOB89a] Sobajic D.J. y Pao Y.H.. ANN Based Dynamic Security Assessment for Electric Power Systems. IEEE Trans. Power Systems, 4(1): 220-226, 1989.

[SOB89b] Sobojic D.J. y Pao Y.. Artificial Neural Network Based Dynamic Security Assessment for Electric Power Systems. IEEE Trans. Power Systems, 4(1): 220-228, 1989.

[SON97a] Song Y.H. y Johns A.T.. Applications of Fuzzy Logic in Power Systems. I. General Introduction to Fuzzy Logic. IEE Power Engineering Journal, 11(5): 219-222, 1997.

[SON97b] Song Y.H. y Chou C.S.. Advanced Engineered Conditioning Genetic Approach to Power Economic Dispatch. Proc. IEE – Generation Transmission Distribution, 144(3): 285-292, 1997.

[SON97c] Song Y.H., Wang G.S., Wang P.Y., y Johns A.T.. Environmental/Economic Dispatch using Fuzzy Controlled Genetic Algorithms. Proc IEE - Generation Transmission Distribution, 144(4): 377-382, 1997.

[SON97d] Song Y.H., Wan H.B., y Johns A.T.. Kohonen Neural Network Based Approach to Voltage Weak Buses Areas Identification. IEE Proceedings- Generation Transmission Distribution, 144(3):340-344, 1997.

[SON97e] Song Y.H., Johns A.T. y Aggarwal R.. Neural Network Based Adaptive Autoreclosure Technique For Long-Distance Compensated Transmission Systems. Electric Machines and Power Systems, 25(3): 281-294, 1997.

[SON98a] Song Y.H. y Johns A.T.. Applications of Fuzzy Logic in Power Systems. II. Comparison and Integration with Expert Systems Neural Networks and Genetic Algorithms. IEE Power Engineering Journal, 12(4):185-190, 1998.

[SON98b] Song Y.H. y Chou C.S.. Application of Ant Colony Search Algorithms in Power System Optimization. IEEE Power Engineering Review, 18(12): 63- 64, 1998.

[SON99a] Song Y.H. y Johns A.T.. Applications of Fuzzy Logic in Power Systems. III. Example Applications. IEE Power Engineering Journal, 13(2):97-103, 1999.

[SON99b] Song Y.H.. Modern Optimization Techniques in Power Systems. Kluwer Academic Publishers, London, UK, 1999.

[SRI94] Srinivasan D., Liew A., y Chang C.. Forecasting Daily Load Curve using a Hybrid Fuzzy-Neural Approach. IEE Proceedings- Generation Transmission and Distribution, 141(6): 561-567, 1994.

[STE86] Steuer, R., Multiple criteria optimization: theory, computation, and application. New York. 1986.

[STE88] Stevenson, W., Análisis de Sistemas de Potencia, Cuerna Vaca: Mc Graw-Hill/Interamericana de México S.A. de C.V., 1988.

[STÜ02] Stützle T .y Dorigo M.. “A Short Convergente Proof for a Class of Ant Colony Optimization Algorithms”. IEEE Transactions on Evolutionary Computation, 6:358-365, agosto 2002.

[SU97] Su C. y Chiou G.. A Fast Computation Hopfield Method to Economic Dispatch of Power Systems. IEEE Trans. Power Systems, 12(4): 1759-1764, 1997.

[SUN84] Sun D.I., Ashley B., Brewer B., Hughes A., y Tinney W.F.. Optimal Power Flow by Newton Approach. IEEE Trans. Power Apparatus and Systems, PAS-103(2):2864 – 2878, 1984.

[SUN94] Sundhararajan S. y Pahwa A., "Optimal Selection of Capacitors for Radial Distribution Systems Using a Genetic Algorithm". in IEEE Trans. on Power Systems, vol. 9, no. 3, pp. 1499-1507, Aug. 1994.

[TAN95] Tanomaru, J., "Motivacao, Fundamentos e Aplicacoes de Algoritmos Genéticos", II Congreso Brasileiro de Redes Neurais-III Escola de Redes Neurais. Curitiva. 1995.

[TAW01] Tawfik, M.M. y Morcos, M.M. ANN-Based Technique for Estimating Fault Location on Transmission Lines Using Prony Method. IEEE Trans. Power Delivery, 16(2): 219-224, 2001.

[TAY90] Taylor, T. y Lubkeman D., "Implementation of Heuristics Search Strategies for Distribution Feeder Reconfiguration". in IEEE Trans. on Power Delivery, vol. 5, no. 1, pp. 239-246, Jan. 1990.

[TIN67] Tinney, W.F. y Hart, C.S., Power Flow Solution by Newton's Method. *IEEE Trans. Power Apparatus and Systems*, PAS-86(11):1449-1460, 1967.

[VAL02] Vallejos, J. "Compensación de Potencia Reactiva en Sistemas Eléctricos de Potencia utilizando Inteligencia Artificial", Tesis de grado para optar al titulo de Ingeniero Electromecánico, Facultad de Ingeniería, Universidad Nacional de Asunción – Paraguay. 2002

[VAN00] Vankatesh, B., Sadasivam, G. y Abdullah Khan M., "A New Optimal Power Scheduling Method for Loss Minimization and Voltage Stability Margin Maximization Using Succesive Fuzzy LP Technique". in IEEE Trans. on Power Systems, vol. 15, nº 2, pp. 844-851, May 2000.

[VAN93] Vankayala, V.S.S. y Rao N.D., Artificial Neural Networks and Their Applications to Power Systems – A Bibliographical Survey. Electric Power Systems Research, 28(1):67-79,1993.

[VAN97] van Veldhuizen, D., "Multi-objective Evolutionary Algorithms: Classifications, Analysis, and Innovations". Ph. D. thesis, Department of Electrical and Computer Engineering, Graduate School of Engineering, USAF Institute of Technology, Wright-Patterson AFB, Ohio, 1997.

[VAR93] Vargas L.S., Quintana V.H., y Vannelli V.. A Tutorial Description of an Interior Point Method and its Applications to Security Constrained Economic Dispatch. IEEE Trans. Power Systems, 8(3): 1315-1324, 1993.

[VEN01] Venkatesh P., Kanan P.S., y Anudevi S.. Application of Micro Genetic Algorithm to Economic Load Dispatch. Institution of Engineers (India), 82(3): 161-166, 2001.

[WAN92] Wang C. y Shalidehpour M.. A Fuzzy Artificial Neural Network for Multi-Area Optimal Power Generation Scheduling with Transmission Losses. Proc. of the American Power Conf., Chicago, IL, 1992.

[WAR97] Wardwick K., Ekwue A., y Aggarwal R.. Artificial Intelligence Techniques in Power Systems. IEE, London, UK, 1997.

[WAS89] Wasserman P.D.. Neural Computing: Theory and Practice. Van Nostrand Reinhold, New York, 1989.

[WEN97a] Wen F.y Chang C.S.. Transmission Network Optimal Planning using Tabu Search Method. Electric Power System Research, 42(2): 153-163, 1997.

[WEN97b] Wen J., Cheng S., y Malik O.P.. A Synchronous Generator Fuzzy Excitation Controller Optimally Designed with Genetic Algorithm. IEEE Trans. Power Systems, 13(3): 884-889, 1997.

[WEN97c] Wen F. y Chang C.S.. A Tabu Search Approach to Fault Section Estimation in Power Systems. Electric Power System Research, 40(1): 63- 73, 1997.

[WEN97d] Wen F. y Chang C.S.. Tabu Search Approach to Alarm Processing in Power Systems. IEE Proceedings- Generation Transmission and Distribution, 144(1): 31-38, 1997.

[WON96] Wong K.P. y Wong Y.W.. Combined Genetic Algorithm/ Simulated Annealing /Fuzzy Set to Short Term Generation Scheduling with Take-or Pay Fuel Contract. IEEE Trans. Power Systems, 11(1): 128-136, 1996.

[WON97] Wong K.P. y Wong S.Y.W.. Hybrid Genetic/Simulated Annealing to Short Term Multiple Fuel-Constrained Generation Scheduling. IEEE Trans. Power Systems, 12(2):776-784, 1997.

[WU95] Wu, Q. y Ma J., "Power System Optimal Reactive Power Dispatch Using Evolutionary Programming". in IEEE Trans. on Power Systems, vol. 10, no. 3, pp. 1243-1249, 1995.

[YAN95] Yang H.T., Huang Y.C., y Haung C.L.. Solution to Capacitor Placement Problem in a Radial Distribution System Using Tabu Search Method. Proc. Int. Conf. on Energy Management and Power Delivery, Singapur, 388-393, 1995.

[YAN97] Yang H.T., Yang P.C., y Huang C.L.. A Parallel Algorithm Approach to Solving the Unit Commitment Problem: Implementation on the Transputer Networks. IEEE Trans. Power Systems, 12(2): 661-668, 1997.

[YEH96] Yeh EC., Venkata S.S. y Sumic Z.. Improved Distribution System Planning using Computational Evolution. IEEE Trans. Power Systems, 11(2): 668-674, 1996.

[YOK93] Yokoyama R., Niimura T., y Nakanishi. A Coordinated Control of Voltage and Reactive Power By Heuristic Modeling and Approximate Reasoning. IEEE Trans. Power Systems, 8(2): 636 – 645, 1993.

[YUN02] Yun-He Hou, Yao-Wu Wu, Li-Juan Lu, Xin-Yin Xiong, Generalized ant colony optimization for economic dispatch of power systems. En PowerCon 2002, octubre del 2002, Kunming, China.

[ZAD65] Zadeh L.A.. Fuzzy Sets. Information and Control, Vol. 8:338-353, 1965.

[ZHA89] Zhang Z.Z., Hope G.S., y Malik O.P.. Expert Systems in Electric Power Systems – A Bibliographic Survey. IEEE Trans. Power Systems, 4(4): 1355-1362, 1989.

[ZIM94] Zimmerman, H. J., Fuzzy Set Theory and Its Application: Kluwer Academic Press, 1994.

[ZIT98] Zitzler, E. y Thiele L., "An evolutionary algorithm for multiobjective optimization: the Strength Pareto Approach". Technical report no. 43. Zürich: Computer Engineering and Networks Laboratory. Switzerland. 1998.

[ZIT99] Zitzler, E. y Thiele L., "Multiobjective Evolutionary Algorithms: A Comparative Case Study and the Strength Pareto Approach". IEEE Trans. on Evolutionary Computation, vol 3, no. 4. Nov. 1999.

[ZIT01a] Zitzler, E. et al (ed.), Evolutionary Multi-Criterion Optimization: First International Conference (EMOO'2001), Berlin: Springer-Verlag, 2001.

[ZIT01b] Zitzler, E., Laumanns M. y Thiele L., "SPEA2: Improving the Strength Pareto Evolutionary Algorithm". Technical Report no. 103. Computer Engineering and Networks Laborator (TIK). Department of Electrical Engineering. Swiss Federal Institute of Technology (ETH). Zurich. 2001.