



Comité  
Nacional  
Paraguayo

Unión de  
Ingenieros  
de la ANDE



38/CE-38.19

COMITÉ 38

ANÁLISIS Y TÉCNICAS PARA ESTUDIOS DE SISTEMAS DE POTENCIA

### COMPENSACIÓN DE POTENCIA REACTIVA MULTI OBJETIVO USANDO INTELIGENCIA ARTIFICIAL\*

Rodrigo A. Ramos Galeano  
ANDE

José M. Vallejos Mernes  
CENTRO NACIONAL DE COMPUTACIÓN-U.N.A.

\*Este trabajo fue patrocinado por el Centro Nacional de Computación, dependiente de la Universidad Nacional de Asunción

#### RESUMEN

La Compensación de Potencia Reactiva en Sistemas de Potencia es usualmente estudiada como un problema de optimización simple con restricciones, donde una función objetivo está constituida por una combinación lineal de varios factores tales como la inversión y las pérdidas en transmisión. Al mismo tiempo, ciertas restricciones limitan otros parámetros tales como confiabilidad y perfil de tensiones.

Este trabajo presenta una nueva propuesta utilizando Optimización Multiobjetivo con Algoritmos Evolucionarios. Se propone una variante del Algoritmo SPEA (Strength Pareto Evolutionary Algorithm) que optimiza independientemente varios parámetros, convirtiendo las tradicionales restricciones en nuevas funciones objetivo. Así, un variado conjunto de soluciones óptimas, conocido como conjunto Pareto, es obtenido para así decidir cual solución presenta el mejor perfil.

#### PALABRAS-CLAVES

Compensación de Potencia Reactiva, Optimización Multiobjetivo, Algoritmos Evolucionarios.

#### 1- INTRODUCCIÓN

La Compensación de Potencia Reactiva es comúnmente tratada como un problema de optimización con objetivo simple [1-3]. Básicamente consiste en determinar la adecuada ubicación y dimensión de bancos de capacitores/reactores. En este contexto, la función objetivo es una combinación lineal de varios factores tales como: inversión y pérdidas de transmisión, sujeto a restricciones operacionales tales como confiabilidad y perfil de tensiones [4]. Los algoritmos tradicionales de optimización normalmente obtienen una única solución, mientras que los Algoritmos Evolucionarios de Optimización Multiobjetivo (MOEA, por sus siglas en inglés) optimizan simultánea e independientemente varios parámetros convirtiendo las restricciones tradicionales en nuevas funciones objetivo. Como resultado, un variado grupo de

soluciones óptimas (conjunto Pareto) puede ser obtenido. De este modo, un ingeniero puede tener una amplia gama de alternativas antes de decidir cual solución es el mejor compromiso entre diferentes (y a menudo contradictorias) características operativas del sistema.

Para tratar el problema de Compensación de Potencia Reactiva, este trabajo presenta una nueva propuesta basada en el SPEA (Strength Pareto Evolutionary Algorithm), que es un MOEA con una población externa de soluciones Pareto óptimas formando un llamado Frente Pareto, mejorado gracias a un proceso de agrupamiento que identifica a las soluciones más representativas.

#### 2. - PROBLEMAS DE OPTIMIZACIÓN MULTI OBJETIVO

Un problema general multiobjetivo (MOP, por sus siglas en inglés) [5], incluye a un conjunto de  $n$  variables de decisión, un conjunto de  $k$  funciones objetivo y un conjunto de  $m$  restricciones. Las funciones objetivos y las restricciones son funciones de las variables de decisión. Esto puede ser expresado según:

$$\begin{aligned} \text{Optimizar } \mathbf{y} &= \mathbf{F}(\mathbf{x}) = [F_1(\mathbf{x}) \quad F_2(\mathbf{x}) \quad \dots \quad F_k(\mathbf{x})] \\ \text{s.a. } \mathbf{e}(\mathbf{x}) &= [e_1(\mathbf{x}) \quad e_2(\mathbf{x}) \quad \dots \quad e_m(\mathbf{x})] \geq \mathbf{0} \\ \text{donde } \mathbf{x} &= [x_1 \quad x_2 \quad \dots \quad x_n] \in X \\ \mathbf{y} &= [y_1 \quad y_2 \quad \dots \quad y_k] \in Y \end{aligned} \quad (1)$$

$\mathbf{x}$  es conocida como el vector de decisión, siendo  $\mathbf{y}$  el vector objetivo.  $X$  denota el espacio de decisión y el espacio objetivo está representado por  $Y$ .

El conjunto de restricciones  $\mathbf{e}(\mathbf{x}) \geq \mathbf{0}$  determina el conjunto de soluciones posibles  $X_f$  y su correspondiente conjunto  $Y_f$  de vectores objetivo posibles.

A partir de esta definición, se concluye que cada solución consiste en una  $n$ -tupla  $\mathbf{x}$ , que da origen al vector objetivo  $\mathbf{y}$ , donde cada  $\mathbf{x}$  debe satisfacer el conjunto de restricciones  $\mathbf{e}(\mathbf{x}) \geq \mathbf{0}$ . El problema de optimización consiste en encontrar el  $\mathbf{x}$  que posea el

“mejor”  $\mathbf{F}(\mathbf{x})$ . En general, no existe una única mejor solución, sino mas bien un conjunto de mejores soluciones, siendo que ninguna de las cuales puede ser considerada mejor que las demás si se consideran nuevo concepto de optimabilidad debe ser establecido para los MOPs.

En los problemas de optimización de un solo objetivo, el conjunto de variables de decisión se encuentran completamente ordenado por la función objetivo  $F$ . El objetivo es simplemente encontrar el valor ( o los valores ) que llevan a los óptimos valores de  $F$ . Por otro lado, en la optimización multiobjetivo el conjunto de vectores de decisión posibles se encuentra sólo parcialmente ordenado, esto es, existe un vector de decisión  $\mathbf{x}_1$  y un vector de decisión  $\mathbf{x}_2$ , sin que  $F(\mathbf{x}_1)$  pueda ser considerado mejor que  $F(\mathbf{x}_2)$ , y viceversa. Por esto, matemáticamente, las relaciones  $=$ ,  $\leq$  y  $\geq$  deben ser extendidas. Esto puede ser realizado usando el concepto de *dominancia*, tal como está expuesto en [5]:

### 3. FORMULACIÓN MATEMÁTICA

Para los propósitos de este trabajo, se han hecho las siguientes asunciones en la formulación del problema:

- El costo unitario de los bancos de capacitores/reactores es el mismo para todas las barras del sistema.
- Se considera solamente la carga punta.

Basadas en estas consideraciones, cuatro funciones objetivo  $F_i$  a ser minimizadas han sido identificadas [4,8]:

$F_1$ : Inversión en dispositivos de compensación reactiva.

$$F_1 = \sum_{i=1}^n k |B_i| \quad (2)$$

$$k = \begin{cases} \alpha & \text{if } 0 \leq B_i < B_m \\ \beta & \text{if } -B_m < B_i < 0 \end{cases}$$

$$\text{s.a.: } F_1 \leq F_{1m};$$

donde  $F_1$  es la inversión total requerida;  $F_{1m}$  es la máxima compensación disponible para todo el sistema;  $B_i$  es la compensación en la barra  $i$  medida en MVAR;  $B_m$  es el valor absoluto de la mayor compensación en MVAR posible en una barra del sistema;  $\alpha$  es el costo por MVAR de un banco de capacitores;  $\beta$  es el costo por MVAR de un banco de reactores y  $n$  es el número de barras en el sistema.

$F_2$ : Pérdidas de potencia activa

$$F_2 = P_g - P_l \geq 0 \quad (3)$$

donde  $F_2$  es la pérdida total de potencia activa en MW;  $P_g$  es la potencia total generada en MW y  $P_l$  es la carga total del sistema en MW.

simultáneamente todos los objetivos. Esto deriva del hecho que podrían existir (y a menudo ocurre así) conflictos entre los diferentes objetivos que componen el problema. Así, un  $F_3$ : Desviación promedio de voltaje

$$F_3 = \frac{\sum_{i=1}^n |V_i - V_i^*|}{n} \quad (4)$$

donde  $F_3$  es la diferencia promedio de voltaje en pu;  $V_i$  es el voltaje en pu en la barra  $i$  y  $V_i^*$  es el voltaje deseado en pu en la barra  $i$ .

$F_4$ : Desviación máxima de voltaje

$$F_4 = \max_i (V_i - V_i^*) = \|\mathbf{V} - \mathbf{V}^*\|_{\infty} \geq 0 \quad (5)$$

donde  $F_4$  es la desviación máxima de voltaje con respecto al valor deseado;  $\mathbf{V} \in \mathfrak{R}^n$  es el vector de tensiones y  $\mathbf{V}^* \in \mathfrak{R}^n$  es el vector de tensiones deseado.

En resumen, el problema de optimización a ser resuelto puede ser expresado como sigue:

$$\min \mathbf{F} = [F_1 \quad F_2 \quad F_3 \quad F_4] \quad (6)$$

donde

$$\mathbf{F} = \left[ \begin{array}{c} \sum_{i=1}^n B_i \quad P_g - P_l \quad \frac{\sum_{i=1}^n |V_i - V_i^*|}{n} \quad \|\mathbf{V} - \mathbf{V}^*\|_{\infty} \end{array} \right]$$

es conocido como el *vector objetivo*, sujeto a  $F_1 \leq F_{1m}$  y a las ecuaciones de flujo de carga [9].

Para representar la cantidad de compensación reactiva a ser ubicada en cada barra  $i$ , un vector incógnita  $\mathbf{B}$ , conocido como *vector de decisión* [7], es usado para indicar el tamaño de cada banco de reactivos en el sistema, esto es::

$$\mathbf{B} = [B_1 \quad B_2 \quad \dots \quad B_n], B_i \in \mathfrak{R}, |B_i| \leq B_m \quad (7)$$

El conjunto de soluciones de un problema de optimización multiobjetivo consiste en todos los vectores de decisión  $\mathbf{B}$  para los cuales los correspondientes vectores objetivo  $\mathbf{F}$  no pueden ser mejorados en ninguna dimensión sin comprometer alguna otra.. Este conjunto de vectores de decisión es conocido como *Pareto Óptimo*, representado como  $P$ . El conjunto de vectores objetivos correspondiente  $\mathbf{F}$  calculados por medio de las ecuaciones (2) a (5) conforma un conjunto llamado *Frente Pareto Óptimo*, denotado como  $PF$ [7].

Debido a que el conjunto Pareto Optimo teórico (denominado  $P_{true}$ ), con su correspondiente  $PF_{true}$ , no son conocidos a cabalidad en la práctica sin haber realizado cálculos extensivos (lo cual no es computacionalmente posible en la mayoría de los casos), normalmente sería suficiente para fines prácticos el encontrar un conjunto Pareto Optimo conocido, denominado  $P_{known}$ , con su correspondiente frente Pareto  $PF_{known}$ , lo suficientemente cercano a la solución teórica óptima [5].

#### 4. MÉTODO PROPUESTO

Para el presente trabajo, se ha desarrollado una nueva propuesta basada en el método SPEA (Strength Pareto Evolutionary Algorithm). Este método, derivado de los Algoritmos Genéticos[10], se basa en la generación de una Población Externa compuesta por los mejores individuos  $\mathbf{B}$  de una población evolutiva. Este grupo externo de soluciones constituye el  $P_{known}$ , disponible en cada momento del cómputo, esto es, la mejor aproximación a  $P_{true}$  conocida. El SPEA original evalúa la adaptabilidad de un individuo en función al número de vectores de decisión dominados por él en la población evolutiva.

El SPEA preserva la diversidad de la población usando relaciones de Dominancia Pareto e incorporando un procedimiento de agrupamiento de manera tal a reducir el conjunto de individuos nodominados sin destruir sus características.

Una característica importante del SPEA consiste en su característica de convergencia, asegurada por el Teorema 4 provado en [5], la cual es una característica no siempre presente en otros MOEAs. Consecuentemente, el algoritmo implementado en el presente trabajo está basado en el SPEA [7], con las siguientes modificaciones:

- *Inicialización Heurística.* Un método heurístico especialmente concebido es utilizado para generar la población inicial de modo tal a obtener individuos electricamente bien compensados. La heurística propuesta se basa en fomentar la compensación en barras con mayor número de líneas y mayor desviación de tensión. Esto se efectúa mediante un procedimiento resumido a continuación:

- Determine un valor de la compensación global  $B_{tot}$ .
- Para cada barra  $i$  en el sistema, calcular un factor  $K_i$  según:

$$K_i = \begin{cases} (V_i - V_i^*) l_i & \text{si } V_i < V_i^* \\ 0 & \text{si } V_i \geq V_i^* \end{cases} \quad (8)$$

donde  $l_i$  es el número de líneas conectadas al nodo  $i$ .  $K_i = 0$  indica que no se asigna ninguna compensación reactiva inicial a la barra  $i$ .

- Normalizar  $K_i$  usando:

$$K'_i = \frac{K_i}{\sum_{i=1}^n K_i} \quad (9)$$

- Compensar cada barra  $i$  con  $B_i$  calculado según:

$$B_i = K'_i B_{tot} \quad (10)$$

- *Optimización local.* Una técnica heurística es implementada de manera tal a mejorar individuos, basada en determinar una dirección de búsqueda adecuada usando las ecuaciones de flujo de potencia [9] según:

$$\begin{bmatrix} \Delta P \\ \Delta Q \end{bmatrix} = \begin{bmatrix} \mathbf{J}_1 & \mathbf{J}_2 \\ \mathbf{J}_3 & \mathbf{J}_4 \end{bmatrix} \begin{bmatrix} \Delta \delta \\ \Delta V \end{bmatrix} \quad (11)$$

De (11) y despreciando  $\mathbf{J}_3$ , así también como los elementos no diagonales de  $\mathbf{J}_4 = \{J_{4j}\}$ , se deriva la siguiente expresión:

$$\Delta Q_i \approx J_{4i} \Delta V_i = J_{4i} (V_i^* - V_i) \quad (12)$$

donde  $\Delta Q_i$  es la cantidad de compensación reactiva a ser adicionada a la barra  $i$ .

- *Criterio de parada.* Los cálculos se detienen cuando ninguna nueva solución nodominada se encuentre luego de un número dado  $N_{stop}$  de iteraciones sucesivas.
- *Dos poblaciones externas.* Si se utilizara sólo una población externa, se podría:
  - Guardar todas las soluciones Pareto encontradas. Sin embargo, esta población podría llegar a ser demasiado grande haciendo que la población evolucionaria pierda su importancia genética en el proceso de búsqueda
  - Perder soluciones usando el proceso de agrupamiento de modo tal a mantener un número máximo de individuos en la población externa (SPEA original).

En el marco de esta nueva propuesta, dos poblaciones externas son guardadas, una con todas las soluciones nodominadas encontradas y la otra con un número máximo de individuos nodominados, fijado por medio del agrupamiento, la cual participa en el proceso evolutivo ordinario. De este modo, la población externa usada en el proceso evolutivo no disminuye la influencia de la población evolutiva, evitando al mismo tiempo perder soluciones óptimas. Nótese que la segunda población externa puede ser guardada en disco, debido a que la misma no participa en el proceso evolutivo.

- *Freezing.* Inspirado en la técnica del Templado Simulado, las probabilidades (de mutación  $P_m$ , cruzamiento  $P_c$  y de aplicación del optimizador local  $P_{lo}$ ) cambian con el número de generaciones y valor de la adaptabilidad, quedando eventualmente invariables al final para mejorar la convergencia [11].

El método propuesto puede ser resumido según los siguientes pasos:

1. Generar una población inicial  $Pop$  usando el método heurístico expuesto, creando además dos conjuntos externos nodominados  $P_{known}$  y  $SP_{known}$

(población externa almacenada).

2. Copiar los miembros no dominados de  $Pop$  en  $P_{known}$  y  $SP_{known}$ .
3. Remover los individuos en  $SP_{known}$  que sean dominados por algún miembro de  $SP_{known}$ .
4. Remover los individuos en  $P_{known}$  que sean dominados por algún miembro de  $SP_{known}$ .
5. Si el número de soluciones externas en  $P_{known}$  excede a un máximo dado, se aplica el agrupamiento para reducir la población a ese máximo.
6. Calcular la función adaptabilidad de cada individuo en  $Pop$  así también como a los individuos de  $P_{known}$  usando procedimientos de evaluación de adaptabilidad del SPEA.
7. Seleccionar individuos de  $Pop + P_{known}$  (union multigrupo) hasta que el conjunto de cruzamiento esté completo. En este trabajo, se utilizó la ruleta como método de selección.
8. Aplicar  $P_{lo}$ ,  $P_c$  y  $P_m$  para determinar si un individuo es optimizado localmente o seleccionado para cruzamiento y mutación; en este último caso, se aplican operadores genéticos standard.
9. Ir al paso 2 si el criterio de parada no se es verificado.

## 5. ENTORNO EXPERIMENTAL

Como un caso de estudio, se ha seleccionado el sistema IEEE de 118 barras. [12]. De modo tal a estresar el sistema, sus cargas activas y reactivas fueron incrementadas en 40%, haciendo al sistema un candidato adecuado para la compensación reactiva.

A efectos de comparación, el conjunto Pareto generado por el método propuesto ha sido comparado con conjuntos Pareto generados usando cuatro métodos diferentes:

1. Esquemas de compensación elaborados por un equipo de ingenieros especialistas, con la aplicación de programas de análisis de redes tradicionales. (*Especialista*).
2. SPEA original, con población inicial aleatoria. [7] (*SPEA*).
3. SPEA original con inicialización heurística (*SPEA*<sup>+</sup>).
4. Una versión especial de SPEA con inicialización heurística y el operador de mutación genética reemplazado por el algoritmo de optimización local. (*SPEA*<sup>lo</sup>).

Para la obtención de los resultados experimentales mostrados en la siguiente sección, se ha asumido que  $\alpha = \beta$ . Asimismo,  $N_{stop} = 100$  fue establecido como número máximo de iteraciones.

Para evaluar los resultados obtenidos de los cinco métodos, se han utilizado un conjunto apropiado de métricas[5], debido a que ninguna métrica utilizada independientemente puede indicar cabalmente la eficiencia y exactitud de los MOEAs. Las métricas usadas son:

### 1) Número de Vectores no Dominados ( $N$ )

Esta métrica indica el número de soluciones en  $PF_{known}$ . Un buen conjunto  $PF_{known}$  debería contar con un gran número de individuos, para ofrecer así una amplia gama de soluciones al usuario.

### 2) Relación de Número de Vectores No Dominados (ONVGR)

Esta métrica denota la relación entre el número de soluciones en  $PF_{known}$  con respecto al número de soluciones en  $PF_{true}$ . Como el objetivo es obtener un conjunto lo más semejante posible a  $PF_{true}$ , valores cercanos a 1 son deseados.

### 3) Relación de Error ( $E$ )

Esta relación indica la proporción de vectores objetivo en  $PF_{known}$  que no son miembros de  $PF_{true}$ . De este modo, un valor de  $E$  cercano a 1 denota una pobre correspondencia entre  $PF_{known}$  y  $PF_{true}$ , esto es, se desea que  $E$  tienda a 0.

### 4) Distancia Generacional ( $G$ )

Esta métrica es calculada en función a la distancia euclidiana (en el espacio objetivo) entre cada vector objetivo  $F$  en  $PF_{known}$  y el miembro más cercano en  $PF_{true}$ . Un valor grande de  $G$  indica que  $PF_{known}$  se encuentra distante a  $PF_{true}$ , siendo que  $G = 0$  es la situación ideal.

### 5) Máximo Error del Frente Pareto ( $ME$ )

Este valor indica la máxima franja de error que, considerada con respecto a  $PF_{known}$ , anarqa a todos los vectores en  $PF_{true}$ . Se desea  $ME = 0$ .

Debido a que la mayoría de las métricas reflejan la similitud entre el frente Pareto Optimo teórico  $PF_{true}$  y un frente Pareto calculado, una buena aproximación a  $PF_{true}$  se construye al reunir todos los individuos nodominados obtenidos al unir los 5 conjuntos. En otras palabras. Para os resultados que se presentan,  $PF_{true}$  se aproxima por las mejores soluciones obtenidas en todos los estudios.

## 6. RESULTADOS EXPERIMENTALES

Las tablas I y II presentan resultados experimentales usando el caso IEEE de 118 barras, con valores obtenidos por los 5 métodos utilizados. Se han seleccionado los mejores resultados obtenidos en una corrida, siendo que las implementacion de SPEA han llegado a una población estable, esto es, no se obtienen nuevas soluciones con nuevas generaciones para  $N_{stop} = 100$ . Por otro lado, el método propuesto debió ser detenido usando el criterio del máximo número de generaciones, ya que el mismo continúa produciendo nuevas soluciones, llegando a más de 2000 soluciones almacenadas ( $SP_{known}$ ). Esta se constituye en una importante ventaja ya que da al usuario una mayor variedad de opciones.

TABLA I  
RESULTADOS EXPERIMENTALES:60 GENERACIONES DEL MÉTODO  
PROPUESTO

Métrica	Especial.	SPEA	SPEA <sup>+</sup>	SPEA <sup>lo</sup>	Método Propuesto
$N$	170	100	150	172	181
ONVGR	0.4315	0.2538	0.3807	0.4365	0.4594
$E$	0.2353	0.9500	0.9533	0.2558	0.2431
$G$	0.5702	0.7325	0.6060	0.5814	0.5431
$ME$	0.0852	0.1040	0.2332	0.0324	0.0554

La Tabla I presenta resultados experimentales usando

sólamente 60 generaciones del método propuesto, mientras que los otros métodos fueron ejecutados hasta llegar a la convergencia. La Tabla II presenta valores obtenidos cuando el método propuesto completa 200 generaciones. En ambas tablas, los mejores valores están resaltados por un sombreado.

TABLA I  
RESULTADOS EXPERIMENTALES: 200 GENERACIONES DEL MÉTODO  
PROPUESTO

Métrica	Especial	SPEA	SPEA <sup>+</sup>	SPEA <sup>lo</sup>	Método Propuesto
<i>N</i>	170	100	150	172	222
<i>ONVGR</i>	0.4208	0.2475	0.3713	0.4257	0.5495
<i>E</i>	0.3235	0.9800	0.9867	0.4128	0.1486
<i>G</i>	0.6138	0.7635	0.6221	0.6022	0.5315
<i>ME</i>	0.0852	0.0948	0.2294	0.0462	0.0342

Para las primeras dos métricas, *N* and *ONVGR*, está claro que el método propuesto posee el mejor desempeño, ya que genera la más variada gama de soluciones. Este hecho es resaltado de manera especial cuando se considera la población externa.

En la Tabla I, los conjuntos de compensaciones elaborados por los especialistas poseen el menor valor de *E*, seguido muy de cerca por el método propuesto, lo que da una idea del buen trabajo realizado por los ingenieros; sin embargo, con un número mayor de generaciones, el método propuesto mejora sensiblemente su desempeño, reduciendo en aproximadamente 40% su radio de error, superando a los demás métodos, como se muestra en la Tabla II.

Los valores obtenidos según la Distancia Generacional *G* muestran los mejores resultados en ambas tablas, generando un conjunto  $PF_{known}$  más cercano a  $PF_{true}$ .

La Tabla I muestra que el método propuesto ocupa el segundo lugar con respecto a la métrica *ME*, sólamente superado por el *SPEA<sup>lo</sup>*. Sin embargo, con un número mayor de iteraciones, el método propuesto posee el menor valor de *ME* (ver Tabla II).

Un hecho a ser enfatizado, finalmente, es que el método propuesto mejora su desempeño en todas las métricas cuando el número de generaciones aumenta, mientras que los demás métodos no presentan substanciales mejoras luego de cierto número de generaciones, lo que se llama "convergencia prematura".

## 6. CONCLUSIONES

En el presente trabajo, el problema de la compensación reactiva de potencia es tratado por primera vez como un Problema de Optimización Multiobjetivo con cuatro funciones objetivo conflictuadas: (i) Inversión en dispositivos de compensación, (ii) pérdidas de potencia activa, (iii) desviación promedio de tensión y (iv) máxima desviación de tensión.

Para resolver el problema, se presenta una nueva propuesta basada en el *SPEA*. Esta nueva metodología presenta varias propuestas tales como: (i) inicialización heurística, (ii) una técnica de optimización local, (iii) un criterio de parada, (iv) dos poblaciones externas y (v) un esquema de *freezing*.

Para propósitos de comparación, el conjunto solución obtenido en una corrida del método propuesto se comparó con cuatro conjuntos de soluciones seleccionadas como las mejores de varias corridas de otros métodos.

Los resultados experimentales obtenidos usando el método propuesto demuestran varias ventajas asociadas a

la utilización del mismo, tales como un conjunto de soluciones más cercano al conjunto Pareto teórico, superando a todos los demás métodos en función a las métricas utilizadas, así también como una mayor variedad de opciones. Esta última característica reviste especial importancia, ya que el ingeniero puede modificar las restricciones de modo tal a reducir el número de soluciones, seleccionando las mejores para la situación real de interés.

Como trabajo futuro, están siendo desarrollados nuevos operadores genéticos especializados, de manera tal a mejorar localmente la compensación reactiva de un individuo dado. Asimismo, otras posibles funciones objetivo (tales como el margen de estabilidad de tensión) están siendo considerados. Finalmente, la implementación paralela asíncrona del método usando una red de computadoras se presenta como una interesante opción para lidiar con problemas de mayores dimensiones y con más cantidad de objetivos.

## 7. REFERENCIAS

- [1] K. Miu, H. Chiang and G. Darling, " Capacitor Placement, Replacement and Control in Large-Scale Distribution Systems by a A-Based Two-Stage Algorithm," *IEEE Trans. Power Systems*, vol. 12, n° 3, pp. 1160-1166, Agosto 1997.
- [2] J. Carlisle, A. El-Keib, D. Boyd and K. Nolan, " A Review of Capacitor Placement Techniques on Distribution Feeders," en *Proc. 1997 IEEE 29th Southeastern Symposium on System Theory (SSST '97)*.
- [3] M. Delfanti, G. Granelli, P. Marannino and M. Montagna, " Optimal Capacitor Placement Using Deterministic and Genetic Algorithms," *IEEE Trans. Power Systems*, vol. 15, n° 3, pp. 1041-1046, Agosto 2000.
- [4] P. Kundur, *Power System Stability and Control*. New York: Mc Graw-Hill, 1993.
- [5] D. Van Veldhuizen, "Multiobjective Evolutionary Algorithms: Classifications, Analysis, and New Innovations," *Disertación Ph.D.*, Faculty of the Graduate School of Engineering , Air Force Institute of Technology, 1997.
- [6] B. Venkatesh, G. Sadasivam and M. Abdullah Khan, " A New Optimal Power Scheduling Method for Loss Minimization and Voltage Stability Margin Maximization Using Successive Multiobjective Fuzzy LP Technique," *IEEE Trans. Power Systems*, vol. 15, n° 2, pp. 844-851, Mayo 2000.
- [7] E. Zitzler and L. Thiele, " Multiobjective Evolutionary Algorithms: A comparative Case Study and the Strength Pareto Approach," *IEEE Trans. Evolutionary Computation*, vol. 3, n° 4, pp. 257-271, Noviembre 1999.
- [8] H. Dommel and W. Tinney, " Optimal Power Flow Solutions, " *IEEE Trans. Power Apparatus and Systems*, vol. PAS-87, n° 10, pp. 1866-1876, Octubre 1968.
- [9] J. D. Glover and M. Sarma, *Power System Analysis and Design*. Boston: PWS Publishing Company, 1994.
- [10] D. Goldberg, *Genetic Algorithm is Search, Optimization & Machine Learning*. New York: Addison Wesley, 1989.
- [11] Z. Dong, Y. Wang, D. Hill and Y. Makerov, " A New Approach to Power System VAR Planning Aimed at Voltage Stability Enhancement with Feedback

- Control," in *Proc. 1999 IEEE Powertech Conference*, paper BPT-212-24.
- [12] R. Christie, " Power Systems Test Case Archive," Electrical Engineering dept., University of Washington, Abril. 2000.
- [Online] <http://www.ee.washington.edu/research/pstca>.

