

ALGORITMO EVOLUTIVO MULTI OBJETIVO CON CORRECCIÓN DE RADIALIDAD PARA LA RECONFIGURACIÓN DE SISTEMAS ELÉCTRICOS DE DISTRIBUCIÓN

NÉSTOR CÁCERES[†], BENJAMÍN BARÁN[†], ENRIQUE C. VIVEROS[‡]

[†] *Centro Nacional de Computación, Universidad Nacional de Asunción
Casilla de Correos 1439, San Lorenzo – Paraguay*

[‡] *Departamento de Engenharia Elétrica, Universidade Federal do Rio de Janeiro COPPE/UFRJ
Casilla de Correos 68516, CEP 21945 – 970, Rio de Janeiro – Brasil*

E-mails: ncaceres@cba.com.py, bbaran@cnc.una.py, eviveros@vishnu.coep.ufrj.br

Resumen— La Reconfiguración de Sistemas de Distribución de energía eléctrica se realiza a través de la abertura o cierre de llaves de interconexión con el propósito de minimizar las pérdidas activas y mejorar el perfil de tensión de los nodos de la red. Para obtener las configuraciones más adecuadas, el presente trabajo propone la utilización de un Algoritmo Evolutivo Multiobjetivo que optimice simultáneamente las pérdidas de energía y el perfil de tensión de la red. Las nuevas configuraciones obtenidas son evaluadas usando el método de Flujo de Potencia tipo barradura de Suma de Potencias con el que son calculados: la pérdida de potencia activa y los desvíos de tensión. Para asegurar que las configuraciones obtenidas sean radiales se propone un Algoritmo de Corrección de la Radialidad. La nueva propuesta del algoritmo de reconfiguración así conformada fue implementada y exitosamente probada mediante su aplicación a dos sistemas de distribución, utilizados con frecuencia en trabajos del área. Los resultados obtenidos con el método propuesto muestran un excelente desempeño cuando son comparados con los obtenidos por un Algoritmo Genético, actualmente utilizado en problemas de planificación y expansión de redes de distribución.

Palabras clave— Reconfiguración de Redes, Minimización de Pérdidas, Algoritmo Genético, Algoritmo Evolutivo Multiobjetivo, Árboles Abarcadores.

Abstract— The reconfiguration of power distribution systems is accomplished with the operation of on/off switches with the purpose of minimizing active power losses and improving voltage profile. To obtain appropriated configurations, the present work proposes an evolutionary multiobjective algorithm (MOEA) that simultaneously optimizes active power losses and voltage profile of the network. These new configurations are evaluated using a load flow sweep method to calculate active power losses, and voltage deviations. To make sure the configurations are radial systems, an algorithm for radiality-correction is proposed. The new proposal was implemented and successfully tested using two well-known power distribution systems, used in other publications. Experimental results prove the advantages of the proposed MOEA over traditional Genetic Algorithms nowadays used for planning and expansion of power distribution systems.

Keywords— Network Reconfiguration, Lost Minimization, Genetic Algorithm, Multiobjective Evolutionary Algorithm, Spanning Tree.

1 Introducción

Los Sistemas de distribución de energía eléctrica son, en su gran mayoría, configurados radialmente con el propósito de facilitar la coordinación de la protección y mejorar el perfil de tensión del sistema post-falta. En general, estos sistemas presentan posibilidades de alteración de la topología a través de la abertura/cierre de llaves (dispositivos de protección/interrupción). La alteración de la topología, manteniéndose la radialidad, se realiza con el objeto de reducir las pérdidas activas en los alimentadores y mejorar el perfil de tensión para los consumidores, aumentando los niveles de confiabilidad eliminando y/o aislando las faltas, restaurando rápidamente el servicio de suministro de energía (Baran, 1989).

Así, la reconfiguración de redes de distribución constituye un problema de optimización combinatoria no lineal en el cual se debe escoger la solución de un conjunto finito de configuraciones posibles sujeto a restricciones no lineales. En aplicaciones prácticas, este tipo de problema resulta difícil de resolver cuando se utilizan métodos convencionales (Barán, 1989). Recientemente, métodos de optimización conocidos como meta-heurísticos, entre los que se encuentran los Algoritmos Genéticos (AG) (Goldberg, 1989), han sido utilizados con éxito (Miranda, 1988) y (Borges, 2002). En estos casos,

una determinada topología se representa como un *cromosoma* (o candidato a solución), de dimensión igual al número de llaves existentes en el sistema y el estado de cada llave es representado por un número binario (1 ó 0). Típicamente, la adaptabilidad o *Fitness* se obtiene considerando la minimización de las pérdidas de potencia activa aunque alternatively se lo podría definir como una suma ponderada de las funciones objetivos que se desean optimizar (pérdidas de potencia y desvíos de tensión).

A diferencia de anteriores publicaciones, el presente trabajo propone la utilización de un Algoritmo Evolutivo de Optimización Multiobjetivo (MOEA) (Veldhuizen, 1998) que permite la optimización simultánea de varios objetivos, aunque estos sean contradictorios entre sí, dando generalmente como resultado una familia de soluciones óptimas, en lugar de la solución única que provee el AG, lo cual conlleva una mayor flexibilidad para la toma de decisiones, pues resulta posible analizar una variedad de soluciones de compromiso.

Mantener la topología radial después de aplicar sucesivamente los operadores genéticos es una de las principales dificultades que presenta un AG cuando se aplica al problema de reconfiguración (Kagan, 1999). Habitualmente, se sobrelleva esta dificultad utilizando técnicas de penalización en el cálculo del *Fitness* de las topologías no viables

(Nara, 1992). Sin embargo, el presente trabajo logra evitar este problema al utilizar un novedoso Algoritmo de Corrección de la Radialidad (ACR) inspirado en los algoritmos de Kruskal y Prim (Tanenbaum, 1989) y (Joyanes, 1998) para la obtención de *Árboles Abarcadores* o *Spanning Tree*. Con esto, todas las configuraciones analizadas resultan necesariamente radiales.

Para la evaluación de las nuevas configuraciones obtenidas en cada generación (iteración), se utiliza un algoritmo de flujo de potencia tipo barradura de suma de potencias, dadas sus reconocidas ventajas con sistemas radiales (Cespedes, 1990).

2 Formulación Matemática

2.1 Reconfiguración de Sistemas de Distribución

Cada posible topología del sistema de distribución puede representarse como una variable multidimensional o *vector de decisión* x :

$$x = [x_1, x_2, \dots, x_\mu] \in B^\mu; B \in \{0,1\}$$

donde μ es la cantidad de llaves del sistema y cada componente x_i representa una llave abierta o cerrada según sea su valor 0 ó 1, respectivamente.

Definiendo el conjunto $\Omega_x \subset B^\mu$ como el conjunto de configuraciones radiales, el problema de Reconfiguración de Sistemas Radiales de Distribución puede ser formulado como un problema de programación entera no lineal (Borges, 2002), conforme se describe a continuación:

$$\text{Minimizar } \sum_{j \in \Omega_A} L_j \quad (1)$$

sujeto a :

$$\sum_{j \in \Omega_i} S_{ij} = D_i, \quad i \in \Omega_{Nc} \quad (2)$$

$$S_j \leq S_{j, \max}, \quad j \in \Omega_A \quad (3)$$

$$\Delta V_i \leq \Delta V_{\max}, \quad i \in \Omega_{Nc} \quad (4)$$

$$\frac{1}{Nc} \times \sum_{i \in \Omega_{Nc}} |\Delta V_i| \leq \Delta V_{\max} \quad (5)$$

$$S_f \leq S_{f, \max}, \quad f \in \Omega_F \quad (6)$$

$$\prod_{i \in \Omega_{Nc}} \delta_i = 1 \quad (7)$$

donde:

Ω_A : conjunto de trechos de alimentadores entre puntos de carga;

Nc : cantidad de puntos de carga de la red

Ω_{Nc} : conjunto de puntos de carga de la red;

Ω_i : conjunto de trechos de alimentadores conectados al punto de carga i ;

Ω_F : conjunto de alimentadores principales conectados a las subestaciones;

L_j : pérdidas activas en el trecho j ;

D_i : demanda del nodo i ;

S_{ij} : flujo de potencia en el trecho $i-j$;

ΔV_i : caída de tensión entre la subestación y el punto de carga i ;

S_f : flujo de potencia en el alimentador principal (f) conectado a las subestaciones;

δ_i : variable binaria que indica si el punto de carga i está energizado (1) o no (0);

S_j : flujo de potencia en trecho del alimentador j ;

$S_{j, \max}$: capacidad del trecho de alimentador j ;

ΔV_{\max} : caída de tensión máxima admisible en cualquier punto de carga;

$S_{f, \max}$: capacidad máxima del alimentador principal f ;

A partir de la ecuación (1) se puede notar que el problema de reconfiguración, donde se busca minimizar las pérdidas activas totales, es claramente de tipo mono-objetivo. Sin embargo, las restricciones (4) y (5) involucran una métrica para la calidad del servicio, la cual también debería ser optimizada, por ejemplo, para escoger la configuración con mejor perfil de tensión cuando las pérdidas de potencia son similares. De esta manera, se deriva a un Problema de Optimización Multi-Objetivo (MOP) (Veldhuizen, 1998).

2.2 Formulación Multi-Objetivo del Problema

Si se desea optimizar simultáneamente las pérdidas activas y el perfil de tensión, se puede definir el problema de reconfiguración de sistemas de distribución como un problema multiobjetivo donde se desean minimizar los siguientes 3 objetivos:

$$f_1(x) = \sum_{j \in \Omega_A} L_j, \quad x \in \Omega_x \quad (8)$$

$$f_2(x) = \max_{i \in \Omega_{Nc}} (\Delta V_i), \quad x \in \Omega_x \quad (9)$$

$$f_3(x) = \frac{1}{Nc} \times \sum_{i \in \Omega_{Nc}} |\Delta V_i|, \quad x \in \Omega_x \quad (10)$$

sujeto a las restricciones (2), (3), (6) y (7), dado que las restricciones (4) y (5) son ahora consideradas como objetivos de la minimización.

Cabe mencionar que según sean las necesidades y requerimientos, se podrían agregar otras funciones objetivos tales como, el costo de implementación, la cantidad de operaciones (cambios de estado de las llaves), etc., sin mayores variaciones al planteamiento del problema y su método de resolución.

Como ya fuera mencionado, el problema multi-objetivo hasta aquí propuesto puede ser resuelto con tradicionales métodos de solución mono-objetivo, como los algoritmos genéticos, reformulando el problema. Por ejemplo, el método de la suma ponderada (Veldhuizen, 1998) plantea el problema como una minimización de una nueva función objetivo definida como:

$$\text{Minimizar } f_1(x) \cdot \omega_1 + f_2(x) \cdot \omega_2 + f_3(x) \cdot \omega_3 \quad (11)$$

sujeta a las restricciones que correspondan, donde ω_1 , ω_2 y ω_3 son coeficientes de peso para ponderar la importancia de cada objetivo. Típicamente estos

pesos están normalizados de forma que su suma sea siempre 1. Sin embargo, esta técnica ha demostrado no tener la misma capacidad de búsqueda de soluciones Pareto óptimas que los MOEAs (Veldhuizen, 1998), presentados en la siguiente sección. En consecuencia, este trabajo propone la utilización de técnicas basadas en los principios de Dominancia de Pareto (Cui, 2003).

La optimalidad de Pareto implica la optimización simultánea de todos los objetivos parciales, para lo cual se define un *vector objetivo* $F(x) = [f_1(x), \dots, f_p(x)]$, donde p es la cantidad de objetivos a considerar.

Para el caso del problema de reconfiguración, $p = 3$, $x \in \Omega_x$, y los objetivos parciales corresponden a (8), (9) y (10). La optimización, en este contexto, consiste en minimizar las componentes de $F(x)$, para lo cual se utilizan las siguientes definiciones (siempre, en un contexto de minimización):

Definición 1. Dominancia Pareto. Se dice que un vector $\mathbf{u} = (u_1, \dots, u_p)$ domina a otro vector $\mathbf{v} = (v_1, \dots, v_p)$ si y sólo si \mathbf{u} es parcialmente menor que \mathbf{v} , es decir:

$$\forall i \in \{1, \dots, p\}, u_i \leq v_i \wedge \exists i \in \{1, \dots, p\}: u_i < v_i$$

Definición 2. Optimalidad Pareto. Se dice que una solución $x_u \in \Omega_x$ es Pareto Óptima si y sólo si no existe un $x_v \in \Omega_x$ para el cual $\mathbf{v} = F(x_v) = (v_1, \dots, v_p)$ domine a $\mathbf{u} = F(x_u) = (u_1, \dots, u_p)$.

El conjunto de las soluciones Pareto Óptimas conforma un espacio que se denomina Frente de Pareto.

3 Algoritmos Evolutivos

3.1 Algoritmos Genéticos

Los AG son algoritmos de optimización que se inspiran en la teoría Darwiniana de la selección natural, según la cual los individuos más aptos tienen mayor probabilidad de transmitir sus genes a las generaciones posteriores (Goldberg, 1989).

Las principales características de un AG son:

1. Trabaja con una codificación de las variables del problema. Esta codificación se denomina *cromosoma* y define un punto en el espacio de búsqueda llamado *individuo* .
2. Realiza la búsqueda sobre un conjunto de soluciones factibles llamado *población* .
3. La única información que se requiere para la optimización es el valor de la función objetivo que modela el problema en estudio.
4. Utiliza reglas probabilísticas de transición.

Los AG utilizan operadores probabilísticos, llamados operadores genéticos, para generar nuevas *poblaciones* de *individuos* a partir de la *población* corriente. Los principales operadores genéticos son:

- *Selección* . Elige a los *individuos* más aptos para generar la siguiente *población* .

- *Cruzamiento* . Realiza un intercambio de características genéticas entre un par de *individuos* .
- *Mutación* . Ayuda a mantener la diversidad genética mediante la introducción aleatoria de pequeñas alteraciones de la codificación de algunos *individuos* .

En el problema de reconfiguración, un *individuo* corresponde a un elemento $x \in \Omega_x$.

3.2 Algoritmos Evolutivos Multi-objetivo

Los algoritmos evolutivos para optimización multi-objetivo (MOEA), han sido recientemente desarrollados para afrontar la optimización de MOPs (Veldhuizen, 1998) y (Cui, 2003). Un MOEA está estrechamente vinculados a los Algoritmos Genéticos y en general, difiere de estos en la forma como asigna el *Fitness* para la aplicación del operador de selección (utiliza criterios de dominancia Pareto), compartiendo los mismos conceptos de generación y los operadores de cruzamiento y mutación. Así, en el MOEA propuesto en este trabajo se define un *nivel de dominancia* de un *individuo* como la cantidad de *individuos* de la *población* que lo dominan. Así, cuando un *individuo* es no-dominado, su *Fitness* es máximo, en caso contrario, su *Fitness* decrece linealmente en la medida en que su nivel de dominancia aumenta hasta un cierto valor predefinido, a partir del cual, su *Fitness* es cero.

Un MOEA se caracteriza principalmente por buscar un conjunto de soluciones Pareto y no una solución única (como en el caso de un AG). En consecuencia, algunas propuestas, como la aquí presentada, mantienen una *población* externa con los mejores individuos (o soluciones no-dominadas) disponibles a cada generación (Veldhuizen, 1998).

4 Método propuesto

El presente trabajo propone la utilización de un MOEA con un algoritmo de corrección de la radialidad (ACR), aplicado al problema de reconfiguración de sistemas de distribución de energía eléctrica, considerando como objetivos de minimización (8), (9) y (10). El algoritmo propuesto es descrito detalladamente en las siguientes secciones.

4.1 Algoritmo de Corrección de la Radialidad

Dada su naturaleza probabilística, la generación de nuevos *individuos* mediante la aplicación de los operadores genéticos puede resultar en configuraciones no radiales. Para adecuar las configuraciones generadas, se propone un Algoritmo de Corrección de Radialidad (ACR). Este algoritmo consiste en cerrar y/o abrir algunas llaves de manera que la topología sea muy semejante a la original, y a la vez, asegurando la condición de radialidad del sistema.

El ACR, está inspirado en los algoritmos de Prim y Kruskal (Tanenbaum, 1989) y (Joyanes, 1998) para obtener árboles abarcadores mínimos

(*Spanning Trees*), es decir, grafos no dirigidos, acíclicos y conexos. Sin embargo, se tienen dos diferencias importantes en el ACR cuando comparados con el algoritmo de Prim y Kruskal. Esas diferencias son:

- 1- Grafos originales pueden ser no-conexos.
- 2- El algoritmo es no-determinístico.

La primera característica implica la existencia de un conjunto $\Omega_D \subset \Omega_{Nc}$ de nodos desconectados, es decir, no energizados. Luego, se define $\Omega_P \subset \Omega_D$ como el conjunto de nodos desconectados que pueden ser energizados mediante el cierre de una única llave de maniobra.

La componente no determinística del algoritmo es introducida en la selección aleatoria del siguiente nodo perteneciente al conjunto Ω_P que será energizado conectando alguna llave. Esto tiene por objetivo el mantenimiento de la diversidad genética en la *población*.

El ACR consiste básicamente en recorrer los nodos conectados a los alimentadores e ir “marcando” cada nodo visitado, para indicar que está energizado. Cuando ya no existen nodos conectados, se elige algún nodo de Ω_P , se lo conecta y se continúa recorriendo los nodos conectados al nodo elegido. Este proceso se repite hasta que Ω_P quede vacío.

El siguiente pseudocódigo describe una versión simplificada del ACR implementado.

```

Repetir para cada alimentador  $f \in \Omega_F$  del sistema
  ProcesarNodo(  $n \in \Omega_{Nc} : n$  está conectado a  $f$  )
Fin-Repetir
Calcular  $\Omega_P$ 
Mientras exista algún elemento en  $\Omega_P$ 
  Tomar aleatoriamente un nodo  $n_i \in \Omega_P$ 
  Cerrar la llave existente en  $n_i$  para que  $\delta_i = 1$ 
  ProcesarNodo(  $n_i$  )
  Recalcular  $\Omega_P$ 
Fin-Mientras
  
```

Pseudocódigo 1-Proceso principal del ACR

El algoritmo de la rutina recursiva **ProcesarNodo** es el siguiente:

```

ProcesarNodo(  $n$  )
  Marcar el Nodo  $n$ 
  Repetir para cada  $h \in \Omega_{Nc} : h$  está conectado a  $n$ 
    Si  $h$  ya está marcado
      Abrir la llave que conecta  $h$  con  $n$ 
    Sino
      ProcesarNodo(  $h$  )
  Fin-si
  Fin-Repetir
Fin-ProcesarNodo
  
```

Pseudocódigo 2 – Subrutina recursiva **ProcesarNodo**.

4.2 MOEA

Como ya fuera mencionado, el MOEA implementado utiliza una población externa de soluciones Pareto, asegurando la topología radial de las configuraciones mediante el ACR (tanto en la población inicial como a través de las generaciones), consiguiendo así un 100 % de soluciones factibles (configuraciones radiales y convergentes). Para evaluar cada configuración se utiliza un algoritmo de Flujo de Potencia tipo barradura de suma de potencias debido a que esta presenta, una mejor convergencia que los métodos convencionales como Newton-Raphson o Desacoplado Rápido (Monticelli, 1983), en sistemas radiales de distribución.

El Pseudocódigo 3 describe brevemente al MOEA implementado.

```

Generar población inicial aleatoria
Crear población extendida vacía
Aplicar ACR a cada individuo generado
Mientras no se cumpla el criterio de parada
  Aplicar Flujo de potencia a cada individuo
  Calcular nivel de dominancia de cada individuo
  Calcular Fitness de cada individuo
  Copiar no-dominados a población extendida
  Eliminar dominados de la población extendida
  Aplicar Selección y Cruzamiento
  Generar nueva población
  Aplicar mutación
  Aplicar ACR a cada nuevo individuo
  Establecer la nueva población como corriente
Fin-Mientras
  
```

Pseudocódigo 3 – Descripción del MOEA.

4.3 Algoritmo de Comparación (AG)

Con el propósito de contar con un algoritmo con el cual comparar el método propuesto, fue implementado un AG simple (Goldberg, 1989) para resolver el mismo problema de reconfiguración.

Los parámetros a optimizar son idénticos a aquellos correspondientes al MOEA, pero la función objetivo que se utiliza para calcular el *Fitness* es dada por (11). El AG implementado es descrito en el siguiente pseudocódigo:

```

Generar población inicial aleatoria
Aplicar ACR a cada individuo generado
Mientras no se cumpla el criterio de parada
  Aplicar Flujo de potencia a cada individuo
  Calcular Fitness de cada individuo
  Aplicar Selección y Cruzamiento
  Generar nueva población
  Aplicar mutación
  Aplicar ACR a cada nuevo individuo
  Establecer la nueva población como corriente
Fin-Mientras
  
```

Pseudocódigo 4 – Descripción del AG implementado.

5 Resultados Experimentales

Para evaluar el comportamiento del método propuesto, se utilizaron dos sistemas de distribución extraídos de (Kagan, 1999).

El *Sistema 1* está constituido de 5 alimentadores de distribución dispuestos en dos subestaciones. El conjunto posee 59 nodos de carga y 26 llaves de maniobra.

El *Sistema 2* cuenta con 3 subestaciones con un total de 8 alimentadores. El sistema posee, además, 119 nodos de carga y 28 llaves de maniobra.

Una *población* de 40 *individuos* fue utilizada para ejecutar tanto el AG como el MOEA. La probabilidad de cruzamiento fue de 80 % y la de mutación de 10 %. La cantidad de generaciones fue de 50. Los valores de ponderación utilizados para evaluar la función objetivo del AG descrito en (11) son:

$$\omega_1 = \omega_2 = \omega_3 = 1/3$$

Los valores de las 3 funciones objetivo así como el número de operaciones para reconfigurar el sistema son mostrados en las dos tablas que siguen (una por cada sistema de prueba). En dichas tablas, la solución óptima encontrada por el AG y también por el MOEA está resaltada en negrita e indicada por el símbolo '*'. Las demás soluciones solo son encontradas por el MOEA. Puede notarse que tanto en la Tabla 1 como en la Tabla 2, la solución con menor pérdida activa es encontrada por el AG así como por el MOEA propuesto, pero solo el MOEA encuentra en una sola corrida otras configuraciones de compromiso que mejoran el perfil de tensión y hasta el número de operaciones en la reconfiguración, a costa de ligeros incrementos en las pérdidas activas, conformando una gama completa de alternativas de operación con las soluciones Pareto, calculadas en una sola corrida que como se verá, utiliza prácticamente los mismos tiempos de cálculo.

Tabla 1 – Resultados del MOEA y del AG para el Sistema 1.

Soluciones	Pérdidas (kW)	Máximo.ΔV. (kV)	ΔV.Medio (kV)	Operaciones
1*	437,2269	1,1211	0,420	8
2	446,4607	1,1078	0,4367	8
3	449,5161	1,1147	0,436	6
4	452,4026	1,1211	0,4073	6
5	460,6154	1,1078	0,4239	6
6	468,6584	1,1147	0,4181	4
7	471,9789	1,1078	0,4183	8
8	477,1324	1,1078	0,415	8
9	499,9696	1,1147	0,4029	6
10	562,576	1,2234	0,3987	6
11	608,0804	1,2859	0,397	8

Tabla 2 – Resultados del MOEA y del AG para el Sistema 2.

Soluciones	Pérdidas (kW)	Máximo.ΔV. (kV)	ΔV.Medio (kV)	Operaciones
1*	1768,5217	1,3662	0,8618	4
2	1825,3799	1,3662	0,8293	6
3	1906,4224	13638	0,9171	2
4	1906,8976	1,3752	0,7713	4
5	1937,9275	1,3771	0,7630	4
6	1938,9375	1,3638	0,8636	4
7	1946,0233	1,3771	0,7524	6
8	2784,4846	2,4282	0,7501	8

En las Tablas 1 y 2, las columnas correspondientes a *Pérdidas*, *Max.ΔV.* y *ΔV.Med.* se refieren a la pérdida óhmica total (kW), al máximo desvío de tensión (kV) y al desvío medio de tensión (kV), respectivamente. Claramente, estas tres magnitudes corresponden a los tres objetivos a optimizar (8), (9) y (10).

La columna *operaciones*, muestra la cantidad de cambios de estado de llaves que se deben realizarse para llegar a la nueva topología evaluada, a partir de la configuración actual. Claramente, el contar con todo un conjunto de soluciones Pareto facilita la selección de aquella configuración de compromiso que requiera de un menor número de operaciones.

Las tablas 3 y 4 muestran la configuración inicial así como una de las soluciones encontradas, para el *Sistema 2*. Los resultados con el sistema 1 son similares, por lo se omite su presentación.

Tabla 3 – Configuración Inicial del Sistema 2.

AL	Demanda (kW/kVAr)	Pérdidas. (kW/kVAr)	Tensión mín. (kV)
AL-1	2687.862 1780.231	87.878 168.926	12.982
AL-2	3399.670 2323.694	166.440 319.944	12.478
AL-3	3188.21 2152.047	135.359 260.198	12.621
AL-4	5401.193 3650.524	232.939 447.775	12.436
AL-5	3902.584 2447.350	22.187 42.650	13.576
AL-6	4808.020 3145.790	127.528 245.145	12.747
AL-7	3982.071 2535.749	52.129 100.207	13.165
AL-8	1883.388 1262.823	73.485 141.258	12.958

La columna "AL" corresponde a los alimentadores existentes en el sistema. Para cada alimentador se describe la demanda, las pérdidas óhmicas totales y la correspondiente tensión mínima.

Tabla 4 – Sistema 2 después de la Reconfiguración.

AL	Demanda (kW/kVAr)	Pérdidas. (kW/kVAr)	Tensión mín. (kV)
AL-1	2687.862 1780.231	87.878 168.926	12.982
AL-2	2088.306 1365.60	54.857 105.450	13.043
AL-3	2425.76 1590.363	66.808 128.424	13.067
AL-4	6100.099 4090.057	237.848 457.21	12.434
AL-5	3902.584 2447.350	22.187 42.650	13.576
AL-6	4808.020 3145.790	127.528 245.145	12.747
AL-7	5275.184 3458.75	145.588 279.860	12.700
AL-8	1883.388 1262.823	73.485 141.258	12.958

Para las implementaciones realizadas, así como para las ejecuciones de los algoritmos AG y MOEA propuesto, fue utilizado un computador personal con procesador Pentium II de 400 MHz y 64 MB de memoria RAM. Sobre esta plataforma, se utilizaron

ambos algoritmos para resolver los dos sistemas de prueba. La Tabla 5 compara los tiempos de ejecución e incluye información sobre el tiempo que corresponde al ACR y que porcentaje del tiempo total representa. Como puede apreciarse, los tiempos de ejecución del AG y del MOEA propuesto son muy similares, con una leve ventaja comparativa para el MOEA: así mismo, puede notarse la eficiencia del algoritmo ACR propuesto que solo consume alrededor de 1 % del tiempo de cómputo para asegurar la radialidad de las configuraciones analizadas.

Tabla 5 – Tiempos de ejecución

Sistema	Algoritmo	Tiempo (segundos)		
		Total	ACR	%
Sist.1	AG	22,95	0,28	1,2
	MOEA	22,87	0,30	1,3
Sist.2	AG	65,42	0,55	0,8
	MOEA	65,20	0,60	0,9

6 Análisis de los resultados

El MOEA propuesto obtiene una familia completa de soluciones de compromiso Pareto óptimas en la que lógicamente también se encuentra la mejor solución encontrada por el AG (solución 1 en Tablas 1 y 2), dado que la configuración con menor pérdida activa es de hecho una solución Pareto. Considerando la Tabla 1, se puede notar el MOEA encuentra 11 soluciones, de las cuales, 5 requieren un menor número de operaciones, mejorando el perfil de tensión de la solución 1 (encontrada también por el AG). Véase por ejemplo, la solución 6, que con solo 4 operaciones mejora tanto el desvío medio como el desvío máximo de tensión.

Por su parte, la Tabla 2 muestra las 8 soluciones encontradas por el MOEA propuesto. En ella, llama la atención la solución 3 que con solo 2 operaciones logra disminuir la máxima desviación de tensión.

En la Tabla 3 puede observarse que determinados alimentadores poseen un nodo de tensión mínima por debajo del mínimo valor recomendado (-10% de la tensión nominal = 13,80 kV). Después de aplicar la reconfiguración, utilizando los algoritmos propuestos, vemos que las pérdidas óhmicas disminuyen así como la demanda en cada alimentador. El mínimo valor de tensión considerando todos los alimentadores es mayor. Así, cada nodo está dentro de los niveles de tensión permitidos, conforme puede observarse en la Tabla 4.

7 Conclusiones

El MOEA propuesto en este trabajo ha demostrado ser tan eficaz como el AG para encontrar la solución con menor pérdida activa, en tiempos similares (y hasta menores), con la ventaja adicional de proveer toda una familia de soluciones de compromiso con mejores perfiles de tensión y que requieren menos operaciones de reconfiguración, en lugar de una única solución. Esta característica permite una mayor flexibilidad en la selección de la solución que mejor se adapta a los requerimientos de la concesionaria. El algoritmo propuesto incluye un ACR que ha demostrado ser una alternativa válida para restringir el espacio de búsqueda de los algoritmos evolutivos a un conjunto de topologías viables (ra-

diales, con todos los nodos energizados), mejorando el desempeño de las implementaciones, pues solo consumen alrededor de 1 % del tiempo de ejecución.

Como trabajo futuro, las autores esperan incrementar el número de funciones objetivos, incluyendo por ejemplo al número de operaciones, y experimentar con otros algoritmos evolutivos multiobjetivos de segunda generación.

8 Agradecimientos

Especial agradecimiento al D.Sc. Alessandro Manzoni, catedrático de la Pontificia Universidad Católica de Río Grande do Sul, por su desinteresada colaboración.

Referencias

- Baran, M. y Wu, F. (1989). "Network Reconfiguration in Distribution Systems for Loss Reduction and Load Balancing". *IEEE*.
- Borges, C., Manzoni, A., Viveros, E., Falcão, D. y Henriques, H. (2002). "Uma Ferramenta Computacional Amigável para Reconfiguração Automática de Redes de Distribuição Baseada em Algoritmos Genéticos". *XV SENDI*.
- Cespedes, R. (1990). New method for the analysis of distribution networks, *IEEE*.
- Cui, X. (2003). A Multiobjective Model for QoS Multicast Routing Based on Genetic Algorithm. *IEEE*.
- Goldberg, D. (1989). Genetic Algorithms in Search, Optimization and Machine Learning, Addison – Wesley, MA.
- Joyanes, A. y Zahonero, M. (1998). Estructura de datos, McGraw-Hill, MA – España.
- Kagan, N. (1999). "Configuração de Redes de Distribuição através de Algoritmos Genéticos e Tomadas de Decisão Fuzzy". Dissertação da Tese apresentada à Escola Politécnica da Universidade de São Paulo para obtenção do título de Professor Livre Docente. São Paulo – Brasil.
- Miranda, V., Srinivasan, S. y Proença, L. (1998). "Evolutionary Computation in Power Systems". *International Journal of Electrical Power & Energy Systems*. 1998.
- Monticelli, A. (1983). "Fluxo de Carga em Redes de Energia Elétrica". Ed. Edgard Blucher.
- Nara, K., Shiose, A., Kitagawa, M. y Ishihara, T. (1992). "Implementation of Genetic Algorithm for the Distribution Systems Loss Minimum Re-Configuration". *IEEE*.
- Tanenbaum, S. (1989). Computer Networks, Prentice-Hall, NJ - Estados Unidos.
- Van Veldhuizen, D. y Lamont, G. (1998). Evolutionary Computation and Convergence to a Pareto Front. Genetic Programming Conference, Stanford University, California – Estados Unidos.