Comité Nacional Paraguayo

Unión de Ingenieros de ANDE

IX SEMINARIO DEL SECTOR ELECTRICO PARAGUAYO - CIGRÉ
13, 14 y 15 de Octubre de 2010

Flujo de Potencia Óptimo con Algoritmos Genéticos

Esteban F. Vargas Correa, Mario E López Acosta, Anastacio S. Arce Encina

Universidad Nacional del Este (UNE)

Paraguay

RESUMEN

Este trabajo trata sobre un Flujo de Potencia Óptimo cuyo objetivo es minimizar el costo de producción de las unidades generadoras, observando restricciones relacionadas al atendimiento de la demanda del sistema, límites operativos de las unidades de generación y del sistema eléctrico, al cual las unidades generadoras está conectadas. Como metodología de solución es aplicada algoritmos genéticos, en la cual se comparan los resultados obtenidos con dos tipos de representación de los individuos. Los estudios de caso fueron realizados sobre la red de prueba de 30 barras de la IEEE.

PALABRAS CLAVES

Flujo de Potencia Óptimo, Algoritmos Genéticos, Codificación real y binaria.

1. INTRODUCCIÓN

El flujo de potencia óptimo(FPO) consiste en definir el despacho de generación de unidades generadoras con el fin de maximizar o minimizar una función objetivo, sujeta a restricciones de igualdad o desigualdad, relacionadas a las características de las propias unidades generadoras y la red eléctrica en la cual están conectadas. Entre las funciones objetivos normalmente consideradas están la minimización de las pérdidas, minimización del costo de generación, etc.

El FPO es definido como un problema no lineal, no convexo y de gran porte, pudiendo ser resuelto hoy en día por muchos métodos. Básicamente estos métodos se pueden dividir en dos grandes categorías: los basados en optimización matemática clásica y los basados en algoritmos heurísticos. En el primer grupo se encuentran los métodos de programación no lineal, programación lineal, programación cuadrática, método de Newton y método del gradiente. En el segundo grupo se encuentran los algoritmos genéticos, métodos basados en inteligencia artificial, búsqueda de Tabú, entre otros.

Este trabajo resuelve el FPO con técnicas de Algoritmos genéticos, en el cual se aplica dos metodologías de solución. Estas metodologías aplican maneras diferentes de codificación del individuo y cruce entre individuos o soluciones del problema. .

2. FORMULACIÓN MATEMÁTICA

El FPO es un problema de optimización matemática. Las variantes del problema son numerosas, para cada modelo, el objetivo y las restricciones pueden presentarse de diferentes formas. En este trabajo, el FPO es descripto como un problema de minimización del costo total de generación de todas las plantas, sujetas a restricciones relacionadas a las características de las propias unidades generadoras y la red eléctrica en la cual están conectadas [1].

$$Minimizar \quad \sum_{i=1}^{n} F_i(P_i) \qquad (1)$$

La función costo de generación activa del generador i en [$] es representada como una función cuadrática de la siguiente forma:

$$F_i(P_i) = a_i P_i^2 + b_i P_i + c_i \qquad (2)$$

La restricción de desigualdad de límites físicos de generación máximos y mínimos a poder ser generado por los equipos se escribe como sigue:

$$P_i^{\min} \le P_i \le P_i^{\max} \qquad (3)$$

La ecuación de balance de potencia activa a ser respetado en el flujo de potencia es expresada como sigue:

$$\sum_{i=1}^{n} P_i = D + P_l \qquad (4)$$

$$P_l = real(\sum_{j}^{n} V_i Y_{ij} * V_j) \quad i = 1,2,...,n \qquad (5)$$

$$Q_l = imag(\sum_{j}^{n} V_i Y_{ij} * V_j) \quad i = 1,2,...,n \qquad (6)$$

3. METODOLOGÍA DE SOLUCIÓN

Si el FPO busca la minimización del costo total de producción y considerando que las inyecciones de potencia se dan a través de unidades generadoras con diferentes costos de producción, conectados en diferentes puntos de la red, se espera como resultado el despacho de generación de cada unidad observando al mismo tiempo el conjunto de restricciones del problema.

Los algoritmos genéticos por su robustez y características son una buena herramienta para resolver problemas de este porte.

La aplicación de técnicas de Algoritmos Genéticos implica antes que nada definir el tipo de codificación a ser utilizada para la representación de los individuos, el criterio de evaluación de los mismos y los tipos de operadores genéticos (selección, cruce y mutación) a ser aplicados, en la búsqueda de la solución del problema, observando al mismo tiempo que estas soluciones sean factibles y que el proceso evolutivo del algoritmo genético se pueda cumplir.

3.1 Técnicas de codificación

Serán analizadas las técnicas de codificación real y binaria, apuntando las ventajas y desventajas de cada una de estas.

3.1.1. Codificación real

Para la codificación real son considerados valores entre 0 y 1, que representan el porcentaje del rango de generación permitido para cada unidad generadora del sistema eléctrico. Por lo tanto, para un sistema eléctrico que posee N unidades generadoras, es decir N barras del tipo PV, la longitud del cromosoma seria igual a N-1 genes debido a que una barra se toma como referencia para el cálculo del flujo de potencia. En la Figura 1 se representa un individuo para la codificación real [3].

	P_{G2}	P_{G3}	P_{G4}	P_{G5}	P_{G6}
Indiv=	0,57	0,23	0,40	0,67	0,07

Figura 1: Codificación real

En este caso, la representación se refiere a un sistema con seis barras del tipo PV, en la cual la primera barra es considerada como base o referencia para el análisis de flujo de potencia, por lo tanto la longitud del individuo es igual a cinco.

Para obtener los niveles de generación de cada unidad (PG2,.., PG6), para introducirlos como datos del sistema antes de correr el flujo de potencia, se aplica la siguiente formulación:

$$P_G^u = P_{\min}^u + Indv(i) * (P_{\max}^u - P_{\min}^u) \qquad (7)$$

Donde:

P_G^u : Potencia generada en la barra u;

$P_{\max}^u$: Potencia o capacidad máxima de generación en la barra u;

$P_{\min}^u$: Potencia o capacidad mínima de generación en la barra u;

$Indiv(i)$: Valor del gen en la posición i;

u : Número de barra de generación;

La ecuación (7) asegura que los niveles de generación en las barras PV se mantengan dentro de valores permitidos y de esta manera no se crean individuos no factibles para el problema.

3.1.2. Codificación binaria

La codificación binaria genera una mayor diversidad en la población de individuos además de facilitar las operaciones, pero presenta algunos inconvenientes que serán vistos a continuación.

En esta representación cada gen del cromosoma posee una longitud y combinación de ceros y unos. Esta longitud puede ser igual para todos los genes o diferente uno de otro, dependiendo de la exactitud deseada. La decodificación de cada gen ya representa la generación de la unidad correspondiente a ese gen. En la Figura 2 se muestra un individuo para la codificación binaria [3].

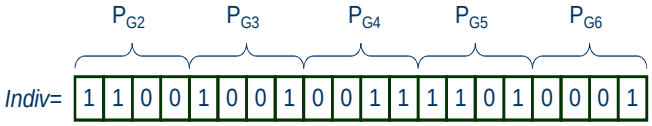

Figura 2: Codificación binaria

Para decodificar el cromosoma y obtener un valor de generación se aplica la siguiente expresión [3].

$$P_G^u = P_{\min}^u + \frac{(P_{\max}^u - P_{\min}^u)}{2^{LG_i} - 1}(gen_i)_{10} \qquad (8)$$

Donde:

P_G^u : Potencia generada en la barra u;

$P_{\max}^u$: Potencia o capacidad máxima de generación en la barra u;

$P_{\min}^u$: Potencia o capacidad mínima de generación en la barra u;

LG_i : Longitud del gen i;

$(gen_i)_{10}$: Valor decimal del gen i;

De la misma forma que la ecuación (7), la ecuación (8) asegura la obtención de niveles de generación factibles para cada unidad generadora.

La longitud de cada individuo para este tipo de representación es igual a la suma de las longitudes de cada gen. Para el ejemplo en la figura 2, como todos los genes tienen longitudes iguales, la longitud del individuo es igual a 4x5=20 bit.

3.2 Función de evaluación

Los algoritmos genéticos tienen la característica de maximizar la función fitness, que es una medida de la calidad de cada solución candidata. El objetivo de este trabajo es minimizar el costo total de producción de energía del sistema.

Por lo tanto, es necesario aplicar un artificio matemático para convertir el objetivo del problema de flujo de potencia óptimo de manera que el algoritmo genético minimice la función de evaluación.

La función fitness además de la función costo de producción posee una función de penalidad, dado por el balance de potencia. La función fitness es formada como sigue:

$$Fitness = \left[\sum_{u=1}^{n} F_u(P_u) + 1000 * abs(\sum_{u=1}^{n} P^u_{generada} - D - P_{perdida}) \right]^{-1} \quad (9)$$

Donde:

$\sum_{u=1}^{n} P^u_{genearda}$: Suma de todas las potencias generadas en el sistema;

D : Demanda de carga a ser atendida;

$P_{perdida}$: Pérdida en la transmisión;

La función de penalidad es dada por la segunda expresión de la ecuación (9), la cual se multiplica por un factor considerable para asegurar el balance de potencia.

3.3 Operadores

En la selección de los padres para el cruzamiento fue implementada la selección por ruleta, donde se imita el giro de una ruleta en el cual los individuos con mayores proporciones en la ruleta tienen mayores probabilidades de ser seleccionado.

Para los dos tipos de representación visto anteriormente es necesario aplicar operadores de cruce específico. En el caso de la representación real no es conveniente aplicar cruce en un punto o más puntos porque con estos se pierde información de cada unidad de generación. Un operador de cruce útil sería el cruce uniforme, ya que esté realiza el intercambio de información en forma paralela.

En el caso de la representación binaria, el cruce se vuelve más flexible y factible de ser aplicado, por ejemplo, se podría aplicar cruce uniforme a todo el individuo o cruce en un punto para cada gen del individuo. Este último operador de cruce contribuye a la pronta convergencia del problema y ataca particularmente cada generación.

Para la metodología con representación real se opto por el cruce uniforme para conservar las características de genes buenos y para el caso de representación binaria se opto por aplicar las metodologías mencionadas anteriormente. En las Figuras 3 y 4 se observan ejemplos de operador de cruce adoptado para cada representación.

	P_{G2}	P_{G3}	P_{G4}	P_{G5}	P_{G6}
padre1=	0,57	0,23	0,40	0,67	0,07
padre2=	0,47	0,16	0,27	0,07	0,63
String=	0	1	1	0	1
hijo1=	0,47	0,23	0,40	0,07	0,07
hijo2=	0,57	0,16	0,27	0,67	0,63

Figura 3. Cruce Uniforme

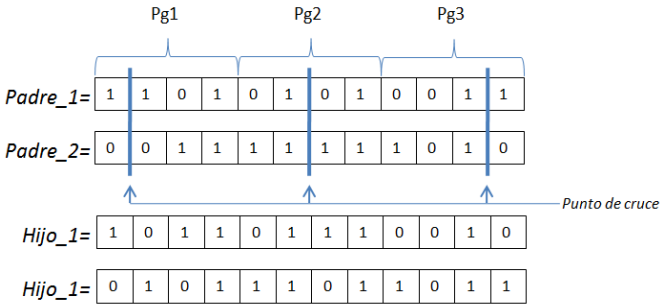

Figura 4. Cruce binario

El operador de mutación cuando actúa toma un nuevo valor para el gen entre 0 y 1 en el caso de codificación real y en el caso de codificación binaria cambia un 0 por 1 y viceversa.

3.4 Procedimiento de solución

El procedimiento del algoritmo genético implementado se puede resumir en el siguiente esquema mostrado en la Figura 5.

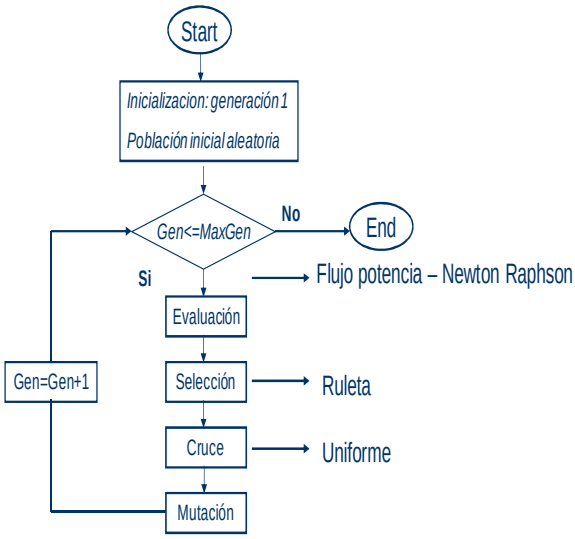

Figura 5. Esquema del AG

El proceso de evaluación se puede sintetizar con los siguientes pasos:

i. Para la primera generación del AG se crea la población de individuos de manera aleatoria, como se muestran en las Figuras 1 y 2;

ii. Para cada individuo se calculan los valores de potencia generada por cada unidad a través de la ecuación (7) u (8) y se introducen en la base de datos de barras del sistema;

iii. Se evalúa el problema de flujo de potencia y se obtienen los valores de generación para las barras del sistema, nivel de tensión en cada barra y pérdida de potencia del sistema de transmisión [2];

iv. Se calcula la función fitness de acuerdo a la ecuación (9) y se vuelve al paso ii para evaluar los demás individuos;

v. Una vez evaluada toda la población, el algoritmo genético sigue su proceso evolutivo (selección, cruce y mutación);

Para la reposición de la nueva generación de individuos se aplico elitismo, en el cual el mejor individuo de la generación anterior es introducido en la nueva generación en lugar del peor individuo. Con esto se logra que la evaluación del mejor individuo en las sucesivas generaciones no empeore, en todo caso, se mantendría la misma. Además, con el elitismo se consigue una convergencia más rápida, ya que contribuye a la disminución de la media de las evaluaciones.

4. RESULTADOS

Para las pruebas fue considerado el sistema de 30 barras de la IEEE por la complejidad del sistema y porque actualmente existe gran cantidad de publicaciones que realizan sus pruebas con este sistema. Por lo tanto, para validar la metodología aplicada se compara los resultados obtenidos con los resultados obtenidos por otros trabajos, como el publicado por Bakirtzis [1].

En [1] se presenta la solución del flujo de potencia óptimo con variables de control continuo y discreto. Las variables de control continuo son la potencia activa generada y las magnitudes de tensión en las barras PV, mientras que las discretas son los valores del tap de los transformadores y los dispositivos shunt. Un número de restricciones operativas como los limites de transmisión, limites de magnitud de tensión en las barras PQ y capacidad de generación de reactivos, son incluidos como penalidades en la función fitness del AG.

Los resultados obtenidos en las dos metodologías propuesta son muy similares una a la otra. En cuanto a tiempo computacional, el AG que implementa codificación binaria es un poco más lento debido a la mayor cantidad de procesos y cálculos que el AG con codificación real. En cuanto a comparación de resultados, como era de esperar, el AG con codificación binaria puede ajustarse mejor a un resultado a diferencia de la codificación real que va tender a mantener un nivel de generación (gen) bueno encontrado durante el proceso de evolución siempre y cuando no se tenga mutación. De esta manera, los resultados dados por la codificación binaria se pueden dar en los niveles mínimos y máximos de cada unidad de generación.

Los resultados obtenidos en [1] y los obtenidos por esta metodología se puede observar en la Tabla I, donde la columna OPF EGA corresponde a los resultados obtenidos en [1] y la columna OPF SGA corresponde a los resultados obtenidos por esta metodología.

Tabla I. Resultado para el sistema de 30 barras de la IEE

	OPF EGA				**OPF SGA**			
Barra Nº	V_G [pu]	P_G [MW]	Cost [$/h]	Cost Marg. [$/MWh]	V_G [pu]	P_G [MW]	Cost [$/h]	Cost Marg. [$/MWh]
1	1.05	176.20	468.84	3.322	1.06	183.678	493.87	3.38
2	1.038	48.75	126.89	3.456	1.043	43.195	108.24	3.26
5	1.012	21.44	50.19	3.681	1.01	19.354	42.76	3.42
8	1.02	21.95	75.35	3.616	1.01	20.486	70.06	3.59
11	1.082	12.42	41.13	3.621	1.082	12.986	43.17	3.65
13	1.067	12.02	39.67	3.601	1.071	13.168	43.83	3.66
	Total:	292.79	802.06		Total:	292.86	801.93	

La Tabla I sintetiza los resultados de tensión, potencia generada y costo asociado a esa generación para las barras PV del sistema.

La comparación de los resultados obtenidos en términos de niveles de generación y costo, muestra pequeñas diferencias, conforme se puede apreciar en los gráficos de la figura 6..

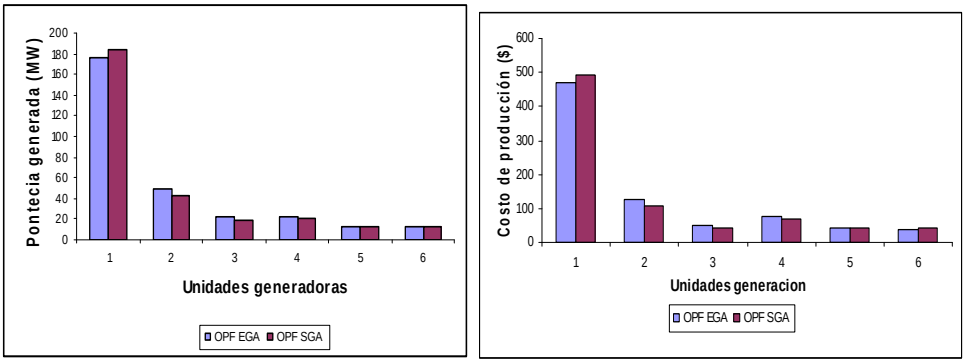

Figura 6. **a) Niveles de generación** **b) Costo de generación**

El costo total de producción que es el objetivo fijado para el problema de flujo de potencia óptimo resultó para el caso de OPF EGA en 802,06 $/h, mientras que para el caso de OPF SGA resulto en 801,93 $/h, que equivale a 0,016% menos que el costo total obtenido en OPF EGA.

Analizando la columna de costo de producción, se observa que para tres niveles de generación se obtuvo economía significativa, contribuyendo bastante al costo de producción total obtenido en OPF SGA.

5. CONCLUSIÓN

Dos metodologías de solución al problema de flujo de potencia óptimo fueron aplicadas para un sistema de medio porte utilizando un algoritmo genético simple, en el cual se consideró como la minimización del costo de producción. El flujo de potencia fue resuelto por el método de Newton-Raphson.

Los algoritmos genéticos simples resultaron en una buena herramienta para resolver el problema de flujo de potencia óptimo, la única desventaja, como en la mayoría de las metodologías que utilizan AG, fue el tiempo computacional. Para disminuir este tiempo se podría aplicar el método de Desacoplado Rápido para la obtención del flujo de carga, así como también aplicar doble reposición elitismo y aplicar otro tipo de selección al algoritmo genético.

.

BIBLIOGRAFIA

[1] A. G. Bakirtzis, P. N. Biskas, C. E. Zoumas and V. Petridis, “Optimal Power Flow by Enhanced Genetic Algorithm”, IEEE Trans. Power Syst., vol. 17, pp. 229-236, May 2002.

[2] Stevenson W., “Analisis de Sistemas de Potencia”, McGrawHill 1890.

[3] Linden, Ricardo; 2006. Algoritmos Genéticos. 1. ed. Rio de Janeiro: Brasport, 2006.