

Aplicación del Ómicron ACO al problema de Compensación de Potencia Reactiva en un Contexto Multiobjetivo.

Pedro Gardel, Benjamin Barán, Hugo Estigarribia, Ubaldo Fernández.

Centro Nacional de Computación, Universidad Nacional de Asunción.

Asunción, Paraguay.

{pgardel, bbaran, hestigarribia}@cnc.una.py, ufernandez@fulbrightweb.org.

Resumen.

En este trabajo se presenta una variante del Ómicron ACO (*Ant Colony Optimization*), un algoritmo de Optimización por Colonia de Hormiga. Esta variante fue desarrollada para resolver el problema de Compensación de Potencia Reactiva en redes de transmisión eléctricas, considerando un contexto multiobjetivo. Los objetivos seleccionados para este trabajo fueron la minimización de la inversión en los dispositivos de compensación de reactivos y la minimización del promedio de la desviación de tensión. Para verificar el comportamiento del Ómicron ACO se utilizó como caso de estudio el sistema estandarizado *IEEE 118*. A fin de evaluar el desempeño del algoritmo propuesto se lo comparó con el *SPEA (Strength Pareto Evolutionary Algorithm)*, un reconocido algoritmo evolutivo de segunda generación. Los resultados experimentales muestran un mejor desempeño del Ómicron ACO para el caso de estudio considerado.

Palabras Claves: Optimización Multiobjetivo, Optimización por Colonias de Hormigas, Compensación de Potencia Reactiva, Algoritmos Evolutivos.

VI Workshop de Agentes y Sistemas Inteligentes (WASI)

1 Introducción.

La Compensación de Potencia Reactiva en Sistemas de Potencia usualmente es estudiada como un problema de optimización de un solo objetivo, con restricciones [3], [4], [8]. La función objetivo la constituye una combinación lineal de los factores de interés como, por ejemplo, los gastos en inversión y pérdidas de transmisión. El perfil de tensión es considerado como una restricción.

Solamente en años recientes se han hecho esfuerzos por resolver este problema en un contexto multiobjetivo utilizando para ello un Algoritmo Evolutivo de Optimización Multiobjetivo - MOEA (*Multi-Objective Evolutionary Algorithm*) [1], [2], [9]. En estos antecedentes, el MOEA más utilizado fue el SPEA, un reconocido MOEA de segunda generación [11].

Los algoritmos tradicionales de optimización generalmente obtienen sólo una solución. Sin embargo, los MOEAs optimizan simultánea e independientemente varios parámetros dando como resultado un grupo de soluciones óptimas denominado conjunto Pareto óptimo. De esta forma, se le presenta a la persona encargada de tomar la decisión final una amplia gama de alternativas para decidir cual es, a su criterio, la mejor solución de compromiso. Esto obedece a que en problemas prácticos, como el de la compensación de reactivos, generalmente no existe una única solución óptima del problema.

El resto del presente trabajo está organizado de la siguiente manera: en el capítulo 2 se presentan los problemas de optimización multiobjetivos. Seguidamente, se enuncia el problema y su correspondiente formulación matemática en el capítulo 3. En el capítulo 4 se describen el método propuesto OE (*Ómicron Eléctrico*) y el SPEA. En el capítulo 5 se muestran los resultados experimentales. Finalmente, se exponen las conclusiones y las referencias correspondientes.

2 Problemas de Optimización Multiobjetivos.

Un problema de optimización multiobjetivo – MOP (*Multi-Objective Problem*) [2], incluye a un conjunto de n variables de decisión, un conjunto de k funciones objetivo y un conjunto de m restricciones. Los objetivos y las restricciones son funciones de las variables de decisión [10]. Esto puede ser expresado de la siguiente manera:

$$\begin{aligned} &\text{Optimizar la función} && \mathbf{y} = F(\mathbf{x}) = [F_1(\mathbf{x}), F_2(\mathbf{x}), \dots, F_k(\mathbf{x})] \\ &\text{sujeto a las restricciones} && E(\mathbf{x}) = [e_1(\mathbf{x}), e_2(\mathbf{x}), \dots, e_m(\mathbf{x})] > 0 \\ &\text{donde el vector de decisión es} && \mathbf{x} = [x_1, x_2, \dots, x_n] \in X_f \\ &\text{siendo el vector objetivo} && \mathbf{y} = [y_1, y_2, \dots, y_k] \in Y_f \end{aligned}$$

En estas expresiones, \mathbf{x} es conocido como el vector de decisión y el espacio de decisión está denotado por X ; \mathbf{y} es el vector objetivo perteneciente al espacio objetivo Y . El conjunto de restricciones $E(\mathbf{x}) > 0$ determina el conjunto de soluciones factibles $X_f \subseteq X$, donde su correspondiente conjunto de vectores objetivo factibles se denota por Y_f .

Para comparar dos soluciones en un contexto multiobjetivo, se utiliza el concepto de dominancia [10]. En un contexto de minimización, dados dos vectores de decisión \mathbf{u} y $\mathbf{v} \in X_f$, se dice que \mathbf{u} domina a \mathbf{v} , denotado por $\mathbf{u} \succ \mathbf{v}$ si:

- 1- \mathbf{u} es menor o igual a \mathbf{v} en cada objetivo, o sea, $F_i(\mathbf{u}) \leq F_i(\mathbf{v})$, $i \in \{1, 2, \dots, k\}$
- 2- \mathbf{u} es estrictamente menor que \mathbf{v} en al menos un objetivo.

La dominancia en un contexto de maximización se define de forma análoga.

Se dice que \mathbf{u} es no comparable con \mathbf{v} si \mathbf{u} no domina a \mathbf{v} ni \mathbf{v} domina a \mathbf{u} , lo que habitualmente se denota como $\mathbf{u} \sim \mathbf{v}$.

El criterio de optimabilidad Pareto establece que una solución es Pareto óptima si no existe otra solución que la domine. Matemáticamente, el concepto de optimabilidad Pareto puede ser definido en los siguientes términos:

Dado un vector de decisión $\mathbf{x} \in X_f$ y su correspondiente vector objetivo $\mathbf{y} = F(\mathbf{x}) \in Y_f$, se dice que \mathbf{x} es no dominado respecto a un conjunto $A \subseteq X_f$ si y solo si

$$\forall \mathbf{a} \in A : (\mathbf{x} \succ \mathbf{a} \vee \mathbf{x} \sim \mathbf{a})$$

donde \vee denota al operador *or* lógico.

En caso que \mathbf{x} sea no dominado respecto a todo el conjunto X_f , y sólo en ese caso, se dice que \mathbf{x} es una solución Pareto óptima ($\mathbf{x} \in \mathbf{P}$ –el conjunto Pareto óptimo), mientras que la correspondiente solución \mathbf{y} es parte del frente Pareto óptimo real FP .

Matemáticamente el conjunto Pareto óptimo, \mathbf{P} , se define de la siguiente forma:

Dado el conjunto de vectores de decisión factibles X_f , se denomina \mathbf{P} al conjunto de vectores de decisión no dominados que pertenecen a X_f , es decir:

$$\mathbf{P} = \{ \mathbf{x} \in X_f \mid \mathbf{x} \text{ es no dominado con respecto a } X_f \}$$

Basado en esto, el frente Pareto óptimo está dado por: $FP = F(\mathbf{P})$

3 Descripción del Problema.

Los sistemas de transmisión y distribución de energía eléctrica emplean dispositivos de compensación de potencia reactiva, tanto capacitiva como inductiva, para regular el nivel de tensión en las barras de subestaciones de los mismos. Por ejemplo, en condiciones de carga leve se insertan reactores (compensación inductiva) de forma a evitar sobretensiones en el sistema. Análogamente, los bancos de capacitores (compensación capacitiva) son empleados para elevar la tensión ante subtensiones.

Adicionalmente, se comprueba [1],[2] el efecto que tiene una compensación reactiva adecuada en la reducción de las pérdidas del sistema y en el aumento de la capacidad de transmisión del mismo. Por ello se hace interesante contar con un algoritmo de optimización por el cual se determine la cantidad, dimensión y ubicación de los elementos de compensación, tanto reactores como capacitores, con la que se obtengan los mayores beneficios posibles a la vez que se minimice la inversión requerida.

3.1 Formulación Matemática del Problema.

Para la formulación matemática del problema, se han hecho las siguientes consideraciones:

1. El costo unitario de los bancos de reactivos es el mismo para todas las barras del sistema, tanto para los bancos de carácter capacitivo como inductivo.
2. Se considera solamente la red eléctrica cargada con la demanda de potencia en el horario de mayor consumo, lo que se conoce como carga pico o carga en punta.
3. Se consideran solamente valores discretos para los bancos de reactivos.

Basados en estas consideraciones, se han identificado dos funciones objetivo, F_1 y F_2 , a ser minimizadas, tal como:

- a) F_1 : Inversión en dispositivos de compensación reactiva.

$$F_1 = \sum_{i=1}^n |B_i|$$

sujeto a las siguientes restricciones: $F_1 \leq F_{1max}$
 $B_i \leq B_{imax}$

donde F_1 es la inversión total requerida; F_{1max} es la máxima inversión disponible para todo el sistema; B_i es la compensación en la barra i medida en MVAR; B_{imax} es el máximo valor absoluto de compensación reactiva posible dicha barra del sistema y n es el número de barras en el sistema.

- b) F_2 : Desviación promedio de voltaje.

$$F_2 = \frac{\sum_{i=1}^n |V_i^* - V_i|}{n}$$

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.

3.2 Codificación de la solución y espacio de búsqueda.

Para la minimización de F_1 y F_2 el vector objetivo es codificado como una n-tupla. A cada barra del sistema eléctrico se le asocia una entrada de esta n-tupla donde el valor de dicha entrada representa el tamaño del banco reactivo, en MVAR, que está ubicado en la misma. Es decir, cada solución generada, conocida también como individuo, corresponde a una forma de distribución de los bancos de reactivos en la red. Como ejemplo, en un sistema eléctrico de 3 barras, $\mathbf{B} = [1,0,-2]$ sería una solución. Estos valores indican que en la primera barra existe un banco capacitivo de 1 MVAR, que la segunda barra no tiene ninguna compensación y que la tercera barra tiene un banco inductivo de 2 MVAR. Nótese que el signo positivo indica un banco de capacitores y el signo negativo un banco de reactores.

El espacio de búsqueda para cada barra está restringido de acuerdo a $\mathbf{B}_i \in \mathbf{SP}_i = [b_{i1}, \dots, b_{ij}, \dots, b_{ic}]$. Cada b_{ij} representa un valor de compensación posible. A b_{i1} le corresponde la máxima compensación inductiva, a b_{ic} la máxima compensación capacitiva y a un b_{ij} central la compensación nula. La cantidad de valores que puede tomar b_{ij} queda determinado por los límites

de compensación, B_{imax} , y por el nivel de discretización adoptado. Esta cantidad de valores de compensación posibles para cada barra se denota por c . En este trabajo se adoptó el mismo valor de c para todas las barras, pero este podría variar de acuerdo a la tensión y a las características de cada barra en particular.

Los valores de B_m y del módulo incremental son elegidos de acuerdo a las características eléctricas y topológicas de la red eléctrica. El conocimiento del sistema es importante para definir los valores iniciales adecuados. Si los mismos no pueden ser definidos a priori, dichos valores son determinados por pruebas sucesivas.

4 Descripción de los algoritmos, OE y SPEA.

4.1 Ómicron Eléctrico (OE) .

El algoritmo de Optimización por Colonia de Hormigas (*Ant Colony Optimization - ACO*) está inspirado en el comportamiento de búsqueda de alimento de las hormigas naturales [5]. El ACO usa una matriz de feromonas $\tau = \{\tau_{ij}\}$ para la construcción de soluciones potencialmente buenas [5]. Los valores iniciales de τ son fijados a un valor constante: $\tau_{ij} = \tau_0 > 0 \forall (i,j)$. El ACO también aprovecha información heurística, dependiente de las características propias de cada problema, utilizando el parámetro η conocido como visibilidad, que será explicado posteriormente.

El OE utiliza el concepto del ACO para generar soluciones o individuos [6] y [7].

El conjunto de soluciones no dominadas encontradas son agrupadas en la población Pob . Cada nueva solución generada es comparada con Pob , conservándose solamente las no dominadas.

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

Todas las soluciones de Pob 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_{ij} para ser ubicado en la barra i está definida por la siguiente ecuación:

$$Pr_{ij} = \left\{ \frac{\tau_{ij}^{\alpha} \times \eta_{ij}^{\beta}}{\sum \tau_{ij}^{\alpha} \times \eta_{ij}^{\beta}} \right. \quad (1)$$

donde 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 sorteado y asignado a B_i . Al final del recorrido la hormiga genera la n-tupla B .

La matriz de feromonas τ tiene 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 SP_i . De esta manera cada fila de τ tiene asociada una barra del sistema y cada columna un valor de SP_i . La primera columna de τ representa el mayor valor del reactor b_{il} permitido y la última columna corresponde al mayor valor de capacitancia b_{ic} .

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

En la actualización de τ se utilizan todos los individuos de Pob . El número de individuos en Pob es denotado por m . Para la actualización de la matriz de feromonas la hormiga realiza los siguientes pasos:

- 1- Igualar τ a la matriz unitaria.
- 2- Selecciona un individuo de Pob .
- 3- Detectar el valor b_{lj} de reactivo asignado a la primera barra del sistema.
- 4- Depositar un cantidad de O/m 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 Pob .

4.1.1 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 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.

Debe tenerse en cuenta 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 [4],[8].

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

$$\eta[ij] = w_1 * \eta_1[ij] + w_2 * \eta_2[j] \quad (2)$$

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

La función η_1 otorga mayor probabilidad a las soluciones con gran compensación y η_2 a las soluciones con poca compensación.

Los pasos a seguir para calcular la visibilidad son presentados a continuación y con un ejemplo de una red de 3 barras para su mejor comprensión:

- (1) **Calcular las tensiones en las barras sin ninguna compensación de reactivos en la red.** En nuestro ejemplo supongamos que las tensiones son: $V = [1.1 \ 0.82 \ 0.98]$, es decir, la primera barra tiene el 110% de la tensión ideal, la segunda el 82% y la tercera el 98%.
- (2) **Calcular la desviación de tensión en las barras.** En el ejemplo sería $V = [0.1 \ -0.18 \ -0.02]$. Nótese que la primera barra necesita compensación inductiva y las otras dos capacitiva.
- (3) **Asignar probabilidades crecientes a los distintos valores de compensación de acuerdo a la necesidad de cada barra con 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 “ a ”, hallado empíricamente. Los valores asignados por η_1 siguen una progresión aritmética creciente o decreciente de acuerdo a si es necesaria una compensación capacitiva o inductiva. En el ejemplo, suponiendo que elegimos valores de ± 2 MVar como máximas compensaciones admisibles por barra y un factor de proporcionalidad $a = 10$, se obtiene:

Barra N°	-2MVar	-1MVar	0 MVar	1MVar	2MVar
1	101	76	51	26	1
2	1	46	91	136	181
3	1	6	11	16	21

$\eta_1 =$

Tabla 1: Ejemplo de asignación de probabilidades de visibilidad de la función η_1

- (4) **Asignar probabilidades mayores a los bancos de reactivos de poco valor a través de la función η_2 .** Esta que tiene como objetivo guiar a las hormigas a encontrar soluciones con poca compensación. Los valores de probabilidad asignados por η_2 siguen una progresión aritmética, primero creciente y luego decreciente teniendo un pico en la probabilidad 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 "b". En el ejemplo $\overline{\Delta V} = 10\%$ y para una constante de proporcionalidad $b = 10$ se obtiene:

$$\eta_2 = \begin{array}{c|ccccc} & \mathbf{-2MVar} & \mathbf{-1MVar} & \mathbf{0 MVar} & \mathbf{1MVar} & \mathbf{2MVar} \\ \hline & 1 & 51 & 101 & 51 & 1 \end{array}$$

Tabla 2: Ejemplo de asignación de probabilidades de visibilidad de la función η_2

- (5) **Los valores de $\eta[ij]$ para cada iteración son calculados mediante la fórmula (2),** 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 1 para hallar la probabilidad final que guiará a las hormigas para la construcción de buenas soluciones.

Los valores de $\eta[ij]$ para tres iteraciones del ejemplo considerado se presentan en la tabla 3, donde en la primera iteración $w_1 = 1$ y $w_2 = 0$, en una iteración intermedia $w_1 = 0.5$ y $w_2 = 0.5$ y en la última iteración de una generación $w_1 = 0$ y $w_2 = 1$:

MVar	-2	-1	0	1	2	-2	-1	0	1	2	-2	-1	0	1	2
	$\eta[ij]$	101	76	51	26	1	51	63.5	76	40.5	1	1	51	101	51
	1	46	91	136	181	1	48.5	96	93.5	91	1	51	101	51	1
	1	6	11	16	21	1	28.5	56	33.5	11	1	51	101	51	1
	a)					b)					c)				

Tabla 3: Ejemplos de asignación de probabilidades de visibilidad 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.

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. A continuación se presenta el pseudocódigo del Ómicron ACO propuesto.

Pseudocódigo del Ómicron Eléctrico:

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

Parámetros de salida: Pob.

Calcular visibilidad.

Cargar población inicial.

Mientras no se cumpla con la condición de parada.

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 Pob .

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

Fin mientras, de la generación.

Fin mientras, del algoritmo.

Calcular visibilidad.

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

Calculo de η_1 :

Para $i = 1$ hasta n .

$$\Delta V_i = V_i - V_i^*$$

Si $\Delta V_i > 0$

Para $j = 1$ hasta c

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

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

Fin para

Fin si.

Si $\Delta V_i < 0$

Para $j = 1$ hasta c

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

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

Fin para

Fin si.

Fin para.

Calculo de η_2 :

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

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

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

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

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

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

Fin para.

Actualizar τ .

Inicializar τ como matriz de unos de $n * c$.

Para cada individuo (Pob_{ind}) de Pob .

Para $i = 1$ hasta n

$$\tau(i, Pob_{ind}(j)) = \tau(i, Pob_{ind}(j)) + O/m.$$

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

Fin para.

Fin para.

Crear nuevo individuo.

Para $i = 1$ hasta n .

Para $j = 1$ hasta c .

$$\eta_{ij} = w_1 * \eta_1[j] + w_2 * \eta_2[j]$$

$$\Pr_{ij} = \begin{cases} \frac{\tau_{ij}^\alpha \times \eta_{ij}^\beta}{\sum \tau_{ij}^\alpha \times \eta_{ij}^\beta} \end{cases}$$

Se escoge el banco de correspondiente a cada barra de $P_{new}(i)$ probabilísticamente de acuerdo a \Pr_i y η_i

Fin para.

Fin para.

4.2 SPEA.

El algoritmo implementado por Barán et al. está basado en el *SPEA* [11], con las siguientes modificaciones:

(a) *Inicialización Heurística.* Un método heurístico especialmente concebido es utilizado para generar la población inicial de modo tal a obtener individuos eléctricamente 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:

a.1 Determine un valor de la compensación global B_{tot} .

a.2 Para cada barra i en el sistema, calcular un factor K_i según:

$$K_i = \begin{cases} (V_i - V_i^*)l_i & \text{si } V_i < V_i^* \\ 0 & \text{si } V_i \geq V_i^* \end{cases} \quad (3)$$

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 .

a.3 Normalizar K_i usando:

$$K_i' = \frac{K_i}{\sum_{i=1}^n K_i} \quad (4)$$

a.4 Compensar cada barra i con B_i calculado según:

$$B_i = K_i' B_{tot} \quad (5)$$

(b) *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 según:

$$\begin{bmatrix} \Delta P \\ \Delta Q \end{bmatrix} = \begin{bmatrix} J_1 & J_2 \\ J_3 & J_4 \end{bmatrix} \begin{bmatrix} \Delta \delta \\ \Delta V \end{bmatrix} \quad (6)$$

De (6) y despreciando J_3 así también como los elementos no diagonales de $J_4 = \{J_{4ij}\}$, se deriva la siguiente expresión:

$$\Delta Q \approx J_{4ij} \Delta V_i = J_{4ij} (V_i^* - V_i) \quad (7)$$

donde ΔQ_i es la cantidad de compensación reactiva a ser adicionada a la barra i .

- (c) *Criterio de parada*. Los cálculos se detienen cuando ninguna nueva solución no dominada se encuentre luego de un número dado N_{stop} de iteraciones sucesivas.
- (d) *Freezing*. Inspirado en la técnica del Templado Simulado, las probabilidades (de mutación P_m , cruzamiento P_c y de aplicación del optimizador local P_{to}) cambian con el número de generaciones y valor de la adaptabilidad, quedando eventualmente invariables al final para mejorar la convergencia.

El método propuesto por Barán et al. [1], [2], [9], puede ser resumido según los siguientes pasos:

- 1- Generar una población inicial Pop usando el método heurístico expuesto en [1], [2] y [9], creando, además, dos conjuntos externos no dominados P_{known} y S_{Pknown} (población externa almacenada).
- 2- Copiar los miembros no dominados de Pop en P_{known} y S_{Pknown} .
- 3- Remover los individuos en S_{Pknown} que sean dominados por algún miembro de S_{Pknown} .
- 4- Remover los individuos en P_{known} que sean dominados por algún miembro de S_{Pknown} .
- 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 de los individuos de P_{known} usando procedimientos de evaluación de adaptabilidad del SPEA.
- 7- Seleccionar individuos de $Pop + P_{known}$ (unión multigrupo) hasta que el conjunto de cruzamiento esté completo. Se utiliza la ruleta como método de selección.
- 8- Aplicar las probabilidades de mutación P_m , cruzamiento P_c y de aplicación del optimizador local P_{to} 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 es verificado.

5 Resultados experimentales.

Para comparar el desempeño de los dos algoritmos (*OE* y *SPEA*) se hicieron 5 corridas de ambos algoritmos. La población inicial fue hallada de la misma manera que lo hicieron Barán et al. [1], [2], [9]. Se creó una única población inicial para todas las corridas tanto del *OE* como del *SPEA*.

- Para el *SPEA* se determinó un número de generaciones máxima de 120 con una cantidad de individuos de 100. Como el concepto de generación no es el mismo para ambos algoritmos se decidió utilizar una condición de término de 10.000 individuos construidos por Ómicron *ACO*, ya que esto toma aproximadamente el mismo tiempo que las realizadas con el *SPEA*. Para el Ómicron *ACO* se utilizó $K = 1000$ y $O = 1500$, determinados experimentalmente por medio de pruebas sucesivas.
- Los resultados de las corridas del Ómicron *ACO* fueron denotados como H, numeradas del 1 al 5 y los del *SPEA* como S, también numeradas del 1 al 5.
- En la tabla 4 se muestran los resultados comparando ambos algoritmos. En la primera columna se indica, entre paréntesis, la cantidad de soluciones halladas por cada corrida del Ómicron *ACO* mientras que en la primera fila se hace lo propio con el *SPEA*. Así en la primera columna se observa que la primera corrida del Ómicron *ACO* (H1) halló 75 individuos y la última 71 y en la primera fila se observa que la primera corrida del *SPEA* (S1) halló 95 soluciones.

En la parte media de la intersección de una fila con una columna encabezada por una corrida del *SPEA* se halla la cantidad de individuos no dominados de la unión de ambas corridas. Así, en la unión de las corridas H1 y S1 (denotado genéricamente por S1 H) hay **76** individuos no dominados para H1, pero solo 74 para H5. Estos resultados están en negrita para su mejor

visualización. A la izquierda de este valor se muestra la cantidad de estos individuos que fueron hallados por el Ómicron ACO y a la derecha los hallados por el SPEA, o sea, que H1 encontró 75 y el S1 solo 1 individuo del conjunto de no dominados de la unión de ambos conjuntos, mientras que al considerar el conjunto S1 H5, se tiene 74 soluciones, de las cuales, 71 fueron encontradas por H5 y solo 3 por S1.

	S1(95)			S2(110)			S3(129)			S4(100)			S5(84)		
	H*	S1UH	S*	H*	S2UH	S*	H*	S3UH	S*	H*	S4UH	S*	H*	S5UH	S*
H1(75)	75	76	1	75	82	7	75	77	2	75	83	8	75	76	1
H2(80)	80	87	7	79	97	18	78	89	11	79	89	10	80	83	3
H3(84)	84	85	1	84	90	6	84	85	1	84	85	1	84	85	1
H4(77)	77	77	0	77	77	0	77	77	0	77	78	1	77	77	0
H5(71)	71	74	3	71	84	13	71	75	4	69	75	6	71	74	3

Tabla 4 . Resumen de las corridas. Las columnas SUH indican la cantidad de individuos del conjunto Pareto de la unión de dos corridas, una del Ómicron ACO(H) y otra del SPEA(S), las columnas H* indican cuantos individuos de dicho conjunto Pareto fueron hallados por el Ómicron ACO y las columnas S* los hallados por el SPEA.

- En la tabla 5 se muestra la cantidad de individuos de las corridas del *OE* dominados por algún miembro de las corridas del SPEA. Así, en la segunda fila, segunda columna se muestra que ningún elemento de H1 es dominado por alguna solución generada por el SPEA y sólo algunos pocos individuos de H2 y H5 son dominados por algún individuo hallados por el SPEA.

	S1	S2	S3	S4	S5
H1	0	0	0	0	0
H2	0	1	2	1	0
H3	0	0	0	0	0
H4	0	0	0	0	0
H5	0	0	0	2	0

Tabla 5 Individuos hallados por el Ómicron ACO dominados por algún individuos hallado por el SPEA.

- La tabla 6 es análoga a la 5 sólo que muestra los individuos hallados por el SPEA dominados por algún individuo hallado por el *OE*.

	H1	H2	H3	H4	H5
S1	94	88	94	95	92
S2	103	92	104	110	97
S3	127	118	128	129	125
S4	92	90	99	99	94
S5	83	81	83	84	81

Tabla 6 Individuos hallados por el SPEA dominados por algún individuo hallado por el Ómicron ACO.

- Finalmente, en la tabla 7 se muestra la contribución de cada corrida para el Frente Pareto obtenido de la unión de las 10 corridas, 5 de cada algoritmo. En la columna encabezada por FPh se muestra la cantidad de individuos hallados por cada corrida del *OE* que pertenecen al Frente Pareto, análogamente en la columna encabezada por FPs se muestra la cantidad de individuos hallados por cada corrida del SPEA pertenecientes al Frente Pareto.

	FPh	FPs
1	14	0
2	10	0
3	30	0
4	32	0
5	19	0
Total:	104	0

Tabla 7. Contribución de cada corrida de ambos algoritmos al Frente Pareto.

A continuación se presenta la figura 1 donde están representados los conjuntos de soluciones no dominadas de las corridas del OE y del SPEA por separado.




Figura 1. Gráfica de los conjuntos Pareto obtenidos de la unión de las 5 corridas de cada algoritmo.

6 Conclusiones y trabajos futuros.

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. A conocimiento de los autores, este algoritmo es el primer Algoritmo de Optimización por Colonia de Hormigas aplicado al problema de compensación de potencia reactiva, en un contexto multiobjetivo. Se creó, a tal efecto, un nuevo enfoque de la visibilidad especialmente pensado para un algoritmo ACO multiobjetivo aplicado al problema en estudio.

De los resultados obtenidos se concluye que el Ómicron Eléctrico es una alternativa muy promisoría para la solución de este problema, 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. Esto es por demás alentador 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.

En trabajos futuros se probará al Ómicron ACO con más objetivos y se limitarán las soluciones a bancos de tamaños que se hallen comercialmente. Además se harán pruebas en otros casos de estudio.

Otra modificación que se podría introducir al algoritmo es la utilización de más de una matriz de feromonas, para guardar agrupar en cada matriz soluciones semejantes, y más de un frente para guardar no solamente las soluciones no dominadas.

Referencias.

- [1] Barán B., Vallejos J., Ramos R. y Fernández U. , "Multi-Objective Reactive Power Compensation". *in Proc. IEEE Transmission and Distribution Conference and Exposition, Atlanta, USA. 2001.*
- [2] Barán B., Vallejos J., Ramos R. y Fernández U. "Reactive Power Compensation using a Multi-Objective Evolutionary Algorithm". *in Proc. IEEE Porto PowerTech'2001. Porto - Portugal. 2001.*
- [3] Carlisle J., El-Keib A., Boyd D. y Nolan K., "A Review of Capacitor Placement Techniques on Distribution Feeders", en Proc. 1997 IEEE 29° Southeastern Symp. on System Theory (SSST'97).
- [4] Delfanti M., Granelli G., Marannino P. y Montagna M., "Optimal Capacitor Placement Using Deterministic and Genetic Algorithms", *IEEE Trans. Power System*, vol. 15, n°3, pp. 1041-1046, Agosto 2000.
- [5] Dorigo M. y Di Caro G., "The Ant Colony Optimization Meta-heuristic." En David Corne, Marco Dorigo y Fred Glover, editors, *New Ideas in Optimization*, páginas 11-32. McGraw-Hill, Londres, 1999.
- [6] Gómez O. y Benjamín Barán B. "Arguments for ACO's Success", Osvaldo Gómez y Benjamín Barán. *Lecture Notes in Computer Science (LNCS)*. Springer-Verlag. Genetic and Evolutionary Computing Conference (GECCO 2004). Seattle. United States. 2004.
- [7] Gómez O. y Benjamín Barán B., "Reasons of ACO's Success in TSP", *Lecture Notes in Computer Science (LNCS)*. Springer-Verlag. ANTS 2004 Conference. Brussels. Belgium. 2004.
- [8] Miu K., Chiang H. y Darling G., "Capacitor Placement, Replacement and Control in Large-Scale Distribution Systems by a A-Based Two-Stage Algorithms", *IEEE Trans. Powers Systems*, vol. 12, n°3, pp. 1160-1166, Agosto 1997.
- [9] Vallejos J., Ramos R. y Barán B. "Multi-Objective Optimization in Reactive Power Compensation". *Jornadas de Informática y Telecomunicaciones - Conferencia de Informática y Tecnología Aplicada (JIT-CITA 2001)*. Asunción-Paraguay. 2001 .
- [10] Van Veldhuizen D., "Multiobjective Evolutionary Algorithms: Classifications, Analysis and New Innovations" *Disertación Ph.D.*, Faculty of the Graduate School of Engineering, Air Force Institute of Technology, 1997.
- [11] Zitzler E. y Thiele L., "Multi-Objective Evolutionary Algorithms: A comparative Case Study and the Strength Pareto Approach", *IEEE Trans. Evolutionary Computation*, vol 3, n° 4, pp. 257-271, Noviembre 1999.