



# Eficiencia energética mediante el balance de fases en sistemas de distribución en baja tensión. Solución desde un enfoque metaheurístico

## Energy Efficiency by Phase Balancing in Low Voltage Distribution Systems. Solution From a Metaheuristic Approach

Gustavo Schweickardt<sup>a\*</sup>

Recibido: agosto 27 de 2014  
Recibido con revisión: septiembre 3 de 2014  
Aceptado: septiembre 6 de 2014

<sup>a\*</sup>Universidad Tecnológica Nacional, Facultad Regional Concepción del Uruguay, Ing. Pereira 676 - 3260, Concepción del Uruguay, Argentina  
Tel.: +(54) 3442 423898  
gustavoschweickardt@conicet.gov.ar

Energética 44, diciembre (2014), pp. 5-17

ISSN 0120-9833 (impreso)  
ISSN 2357 - 612X (en línea)  
www.revistas.unal.edu.co/energetica  
© Derechos Patrimoniales  
Universidad Nacional de Colombia



### RESUMEN

Los Algoritmos Metaheurísticos son ampliamente reconocidos como uno de los más exitosos enfoques para la solución de problemas de optimización combinatoria. Una de las más interesantes áreas de aplicación la constituyen los Sistemas de Potencia. En particular, los sistemas de distribución de energía eléctrica en términos de su planificación y operación. Este Artículo presenta dos enfoques metaheurísticos para resolver un típico problema de optimización combinatoria vinculado a la eficiencia energética: el balance de fases en un sistema de distribución en baja tensión. Primero es introducida una nueva metaheurística, denominada por el autor *Optimización Evolucionaria Difusa por Enjambre de Partículas con Topología Estrella Global/Individual*, sustentada en los principios de la inteligencia de grupo y estrategias de evolución, y que se extiende al dominio difuso para modelar una optimización multi-objetivo, apelando a una función de aptitud difusa. Luego, se presenta una simulación sobre un sistema real, y sus resultados son comparados con otro nuevo enfoque metaheurístico propuesto por el autor, denominado recocido simulado difuso, evidenciándose las ventajas de la *Optimización Evolucionaria Difusa por Enjambre de Partículas con Topología Estrella Global/Individual*.

### PALABRAS CLAVE

Desbalance de cargas; distribución eléctrica; conjuntos difusos; eficiencia energética; enjambre de partículas; optimización.

### ABSTRACT

Metaheuristics Algorithms are widely recognized as one of most practical approaches for combinatorial optimization problems. One the most interesting areas of application are the power systems. In particular, distribution systems planning and operation. This paper presents two metaheuristics approaches to solve a typical combinatorial optimization problem: the phase balancing in low voltage electric distribution systems. first, a new metaheuristic is introduced, called *Fuzzy Evolutionary Particle Swarm Optimization with Global/Individual Star Topology*, based in the swarm intelligence principles and evolution strategies, which is extended to fuzzy domain to modelling a multi-objective optimization, by means of a fuzzy fitness function. A simulation on a real system is presented, and advantages of this approach *Fuzzy Evolutionary Particle Swarm Optimization with Global/Individual Star Topology* with respect to another new metaheuristic, called simulated annealing, extended to fuzzy domain too (*FSA*) and proposed in this work, are evidenced.

### KEYWORDS

Load Unbalance; Electric Distribution; Fuzzy Sets; Energy Efficiency; Particle Swarm; Optimization.

## 1. INTRODUCCIÓN

Los Algoritmos Metaheurísticos son ampliamente reconocidos en cuanto a su capacidad para resolver problemas de Optimización Combinatoria. Sin embargo, las formulaciones originales han sido orientadas a optimizaciones de un único objetivo o Mono-Objetivo. Diversas propuestas para su extensión al dominio Multi-Objetivo han sido introducidas en la literatura especializada, pero cada formulación exhibe ciertas desventajas particulares, así como limitaciones en todo intento de generalización, cuanto menos en los problemas asociados a los sistemas de potencia. Tal es el caso del abordado, para la aplicación de los algoritmos propuestos en el presente artículo: El balance de fases en los Sistemas de Distribución Eléctrica de Baja Tensión (SDEE BT). Como se ha demostrado en el artículo [Schweickardt G. & Miranda V., 2010], un enfoque clásico, aplicando programación lineal entera mixta, no es capaz de resolver un problema real de este tipo, aún planteado Mono-Objetivo, como se propone en [Zhu J., et. al., 1998]. Por esta razón, un enfoque desde los algoritmos metaheurísticos, podría constituir una excelente alternativa, tal y como resultó ser según los resultados que se presentan en la referencia citada, y que se mejoran en este artículo. Existe un significativo número de metaheurísticas o algoritmos metaheurísticos (términos que, en el contexto del presente escrito, serán empleados de manera indistinta) ampliamente difundidos en el estado del arte. Entre ellas pueden referirse, preservando su denominación en inglés, Genetic Algorithms (*GA*), Tabu Search (*TS*), Simulated Annealing (*SA*), Ant Colony Optimization (*ACO*) y Particle Swarm Optimization (*PSO*). Todas ellas han demostrado ser exitosas en la búsqueda de soluciones satisfactorias de problemas combinatorios Mono-Objetivo. Sin embargo, se tienen al menos dos aspectos de relevancia sometidos a discusión: **a)** Cómo modelar la mejor metaheurística Multi-Objetivo y **b)** Cómo diseñar una metaheurística auto-adaptativa, la cual suponga el menor número de parámetros a ser definidos externamente.

En este trabajo se presenta, siguiendo los lineamientos de las investigaciones desarrolladas en la referencia mencionada, una nueva metaheurística Multi-Objetivo, sustentada en los principios de los enjambres de partículas, *PSO*. Se sostienen, como se explicará, las ideas evolucionarias y auto-adaptativas introducidas en la *EPSO*, al igual que el modelado de una función Multi-Objetivo a optimizar empleando conjuntos difusos (*FEPSO*), ya empleados con éxito. La variante, de sustancial importancia en la mejora de la aptitud operativa del algoritmo, estriba en la Topología del Sistema de Partículas, al efecto de compartir información conforme los principios de la Inteligencia de Grupo. Aquí se introduce la idea de Topología Global/Individual, sosteniéndose la denominación en inglés al efecto de


preservar las siglas ya empleadas para identificar la metaheurística base, (*FEPSO*), por *Fuzzy Evolutionary Particle Swarm Optimization with Global/Individual Star Topology (FEPSO GIST)*, cuya traducción se corresponde con la denominación: *Optimización Evolucionaria Difusa por Enjambre de Partículas con Topología Estrella Global/Individual*. La misma se direcciona en el sentido general buscado: un algoritmo de optimización Multi-Objetivo y auto-adaptativo, con capacidades mejoradas respecto del *FEPSO*, en estos dos aspectos, que, como se dijo, constituyen parte de la discusión en el estado del arte. Adicionalmente a esta nueva metaheurística, y aquí por nueva debe entenderse que se altera la topología de comunicación del enjambre respecto de una metaheurística ya propuesta por el autor (*FEPSO*), se introduce una variante Multi-Objetivo de la metaheurística Simulated Annealing o Recocido Simulado, SA, extendida al dominio difuso para tratar con funciones Multi-Objetivo. La misma se identifica, por tanto, con la denominación *FSA (Fuzzy Simulated Annealing)*, que se corresponde con la traducción *Recocido Simulado Difuso*. La metaheurística SA, Mono-Objetivo, ha sido muy aplicada (Schweickardt G. y Miranda V., 2010), (Miranda et.al, 2008), en diferentes problemas de optimización vinculados a los SDEE. Por tanto, se la juzgó como pertinente a efecto de comparar resultados entre ambas: la *FEPSO GIST* y la *FSA*, en un problema de solución conocida: el balance de fases en un SDEEBT, de solución muy satisfactoria proporcionada por las metaheurísticas *FEPSO* y *FEPSO*, introducidas por el autor en la referencia citada.

El trabajo, entonces, está organizado del modo siguiente: En primer lugar se describe el problema a abordar (Balance de Fases (BF) en un SDEE BT), dejando al lector referencias adecuadas para complementar ideas sobre las limitaciones que exhiben enfoques de optimización clásica, por caso, la Programación Lineal Entera Mixta, más algunas referencias bibliográficas relativas a los aspectos físicos-electrotécnicos del problema BF. En segundo lugar se presenta la metaheurística SA, su estrategia de búsqueda y elementos característicos. Luego se presenta el desarrollo que va desde la metaheurística *PSO Canónica* hasta la *EPSO*, de características auto-adaptativas. A partir de allí, se describe la modificación introducida en la Topología de Comunicación del Enjambre, al efecto de concebir la metaheurística, aún Mono-Objetivo, *EPSO GIST*. Posteriormente, se presentan las condiciones para extender estas dos metaheurísticas al *dominio difuso*, tomando como referencia los objetivos a optimizar en el problema de BF, propendiendo a optimizar funciones Multi-Objetivo. Son obtenidas las formulaciones de las metaheurísticas *FEPSO GIST* y *FSA*, según la Función de Aptitud Difusa concebida para el problema BF, sin pérdida de generalidad. Seguidamente, ambas metaheurísticas se aplican en un SDEE BT real, y sus resultados son comparados. Por último, se desarrollan las conclusiones más relevantes sobre los desarrollos presentados.

## 2. EL PROBLEMA DE DESBALANCE DE FASES EN LOS SISTEMAS DE DISTRIBUCIÓN ELÉCTRICA DE BAJA TENSIÓN

El SDEE BT parte de Centros de Transformación de Media Tensión a Baja Tensión (CT MT/BT), en los que se emplazan uno o más

transformadores, que presentan cierto número de salidas en BT. Dicho número aumenta con la potencia instalada. Desde cada salida (en un transformador para un CT tipo plataforma, de 315 [kVA], se tienen 4-6 salidas), parte un alimentador que, a su vez, tiene ramales en derivación, llamados secundarios (los cuales pueden tener derivaciones terciarias, y así siguiendo), conformándose una red independiente cuya topología de operación es radial. El sistema es trifásico, pero las cargas conectadas en los diferentes nodos, resultan, en su mayoría, monofásicas. Esto le confiere un carácter, si bien simétrico, desbalanceado. Significa que el sistema de BT, opera con cierto grado de desbalance en sus tres fases. En la Figura 1 a) se presenta un sistema trifásico de corrientes simétrico balanceado y en la b) un sistema simétrico desbalanceado.




**Figura 1a):** Sistema Trifásico de Intensidades Simétrico y Balanceado (Perfecto)

**Fuente.** Elaboración propia

Sin embargo, en la medida que tal desbalance exhiba un grado más pronunciado, se presentan, al menos, tres problemas relacionados con las pérdidas, la calidad del suministro y la confiabilidad del sistema:

**a)** Existe un aumento en las pérdidas técnicas (potencia y energía) del sistema. En segmentos urbanos/suburbanos, para sistemas de BT que utilizan 0.38 [kV] de tensión nominal de suministro, el nivel de pérdidas técnicas de potencia se sitúa entre un 5 a 10%. El último valor se observa, mayormente, en zonas carenciadas, debido al tipo constructivo de red que se emplea (frecuentemente, conductores desnudos referidos como convencionales);



**Figura 1b):** Sistema Trifásico de Intensidades Simétrico y Desbalanceado

**Fuente.** Elaboración propia.

**b)** La calidad del producto técnico tensión de suministro, controlada por la regulación, disminuye. La tolerancia en tensión para redes como las descritas en el ítem anterior, está entre un 5% a 7% respecto de la tensión de suministro nominal.

**c)** El desbalance de intensidades, para sistemas con neutro puesto a tierra, genera una corriente de secuencia cero,  $I^{[0]}$  (suma de las intensidades de las tres fases, que circulará por tierra) de un valor tal que puede accionar las protecciones contra cortocircuitos. Particularmente, el monofásico/fase a tierra (el más frecuente: un 80% de las fallas son de este tipo). Se observa que en la Figura 1 a) la suma fasorial (vectorial) de las intensidades es nula, mientras que en la 1 b) no lo es. El sistema pierde así confiabilidad, puesto que las protecciones interpretan los fuertes desbalances como una señal de cortocircuito, interrumpiendo el servicio. Esto adquiere mayor relevancia en el subsistema de MT: las cargas para el mismo resultan ser los CT MT/BT (sin considerar los grandes usuarios en MT, que son pocos, relativamente). Los desbalances en BT, se reflejan, entonces, “aguas arriba” como cargas desbalanceadas en MT. En este subsistema existen protecciones accionadas por componente homopolar mayor que cierto nivel de disparo, requiriéndose especial cuidado con su ajuste.

Entonces, el problema de optimización en el grado de desbalance de fases, es definido como *la búsqueda de aquella configuración de conexiones de las cargas a las fases [R, S, T] en el sistema, tal que propenda a evitar, en el mayor nivel posible, los inconvenientes descritos en a), b) y c)*. Como cada carga del sistema tiene tres opciones de conexión, se trata de un problema combinatorio, en rigor dado por las variaciones con repetición de las 3 fases tomadas de a  $n^C$  cargas. El espacio de búsqueda tendrá, entonces,  $NE = 3^{n^C}$  estados. Para un sistema como el considerado en la simulación del presente trabajo, con  $n^C = 115$  cargas, se tiene un espacio de búsqueda de  $NE = 3^{115}$  estados.

Para las simulaciones de Flujos de Potencia Trifásico (Radial) y detalles físicos del problema, pueden consultarse las referencias [Schweickardt G. & Miranda V., 2010; Arrillaga J., et. al., 1991; Grainger J. & Stevenson W., 1996; Fortescue, C.L., 1918].

### 3. LA METAHEURÍSTICA SIMULATED ANNEALING

#### 3.1. Simulated Annealing (SA) o Recocido Simulado.

El concepto de Simulated Annealing o Recocido Simulado, fue introducido en la Optimización Combinatoria por Kirkpatrick [Kirkpatrick, et. al., 1995]. SA se muestra como una metaheurística

flexible, una herramienta muy adecuada para resolver satisfactoriamente una gran variedad de problemas de optimización combinatoria. Se sustenta en la emulación o analogía del recocido de sólidos, conforme la idea de un modelo propuesto en un artículo publicado por Metropolis [Metropolis, et. al., 1953]. El algoritmo de Metrópolis, simula el enfriamiento de un material en un recipiente en alta temperatura. A este procedimiento se lo conoce como recocido (annealing). El mismo consiste en dos pasos: **a)** Primero, la temperatura del sistema es llevada a un estado de *máxima energía*; y **b)** Luego, la temperatura del sistema se disminuye lentamente hasta que se arriba a un estado de *minima energía*, alcanzando el equilibrio térmico del sistema en cuestión. Las propiedades estructurales que finalmente adquiere el sistema en tal proceso, dependen, fundamentalmente, de la velocidad de enfriamiento. Si el mismo es suficientemente lento, se forman largos cristales identificatorios de cierta perfección estructural. Por el contrario, si el mismo es muy rápido, los cristales contendrán imperfecciones y la estructura resultará más vulnerable.

Cabe destacar que, sin introducir mayores detalles de tipo físico, el algoritmo de Metropolis trata al sistema como un conjunto de partículas, y éste es un punto común con la metaheurística *PSO Canónica* desde el cual serán comparadas las metaheurística *FEPSO GIST* y *FSA* aquí propuestas.

### 3.2. El algoritmo metaheurístico (SA)

Con el objeto de explicar cómo es concebida una metaheurística desde tal proceso de recocido, es aplicable una analogía entre el sistema físico, con un gran número de partículas sometidas a diferentes estados de energía, y un problema de optimización combinatoria. Se establece del modo siguiente:

- Las soluciones del problema de optimización combinatoria, son equivalentes a los estados del sistema físico.
- La aptitud asociada a los atributos sobre los que se mide el mérito de las soluciones, se corresponden con la energía asociada a los diferentes estados.
- El parámetro de control en el Problema Combinatorio, es equivalente a la temperatura del sistema físico; y **d.-** La evolución de las soluciones en el algoritmo, es simulada utilizando técnicas de muestreo probabilístico, que se soportan mediante la sucesiva generación de estados de energía.

El proceso, comienza, entonces, con un estado inicial,  $i$ , que es evaluado mediante una función de Energía,  $E(i)$ . Luego, mediante la generación y análisis de un segundo estado,  $j$ , cuya energía resultará  $E(j)$ , se ejecuta un *test de aceptación*. La aceptación del nuevo estado,  $j$ , depende de la probabilidad computada mediante la

expresión siguiente:

$$p(\text{accept } j) = \begin{cases} 1; & \text{si } E(j) \leq E(i) \\ e^{-\frac{E(j)-E(i)}{c}}; & \text{si } E(j) > E(i) \end{cases} \quad (1)$$

Donde  $c$  es un número real positivo expresado por  $c = kBx T$ ;  $kB$  es una constante (llamada Constante de Boltzmann en el Algoritmo de Metropolis) y  $T$  es la temperatura del sistema.

Un procedimiento para el Algoritmo metaheurístico *SA*, puede ser expresado, en lenguaje de pseudo-codificación, como sigue (ver explicación de parámetros al finalizar el procedimiento):

*Minimizar  $f(i)$  para  $i \in S \rightarrow$  Espacio de Búsqueda*

#### Comienzo Procedimiento SA

- Establecer un punto de referencia o partida (estado) =  $i_0$
- Establecer una Temperatura de Partida  $T = T_0$  y una Tasa de Enfriamiento:  $0 < \alpha < 1$ ;
- Establecer  $NT$  (Número de Pruebas/Iteraciones por Nivel de Temperatura);
- Mientras** la *Condición de Parada* no sea satisfecha, hacer
- Para**  $k \leftarrow 1$  hasta  $NT$  hacer
- Generar puntos de prueba,  $j$ , desde  $S_i$  (vecinos a la solución  $i$ ) utilizando la función  $q(i, j)$ ;
- Aceptar la solución  $j$ -ésima con una probabilidad  $p$  (*accept  $j$* ) dada por la expresión (1); **Fin Para** Reducir la Temperatura mediante la regla  $T \leftarrow T \times \alpha$ ;
- Fin Mientras**

#### Fin Procedimiento SA

$S_i$ , es una Vecindad de la Solución  $i$ : un conjunto de puntos discretos,  $\{j\}$ , que satisfacen:  $j \in S_i \Leftrightarrow i \in S_j$  (están arbitrariamente próximos). La Función de Generación de tal vecindad en  $S_i$ , especificada externamente conforme el problema abordado, es designada mediante  $q(i, j)$ .

## 4. INTELIGENCIA DE GRUPO (SWARM INTELLIGENCE - SI)

La Inteligencia de Grupo o (*Swarm Intelligence*), SI, refiere un tipo de inteligencia artificial, basado en el comportamiento de sistemas colectivos, auto-organizados. La expresión fue introducida en [Beni, G. & Wang, J., 1989]. El término *swarm* describió, a entender de Beni, el comportamiento de los autómatas celulares, los cuales exhiben características similares a las observables en ciertos sistemas biológicos, tales como los insectos. De esas características, Beni mencionó: la descentralización, no-sincronización y simplicidad en los movimientos de los miembros del grupo. Además este término, *swarm*, tiene una significación que lo trasciende: permite analizar el comportamiento social de grupos de individuos (peces, insectos, pájaros, etc.), identificando el tipo de configuración en sus sistemas de cooperación y auto-adaptación, al efecto de encontrar la manera óptima de alcanzar

un objetivo. La comunicación, según los biólogos, constituye el parámetro clave en este proceso, de modo que a las cualidades mencionadas: descentralización, no-sincronización y simplicidad en los movimientos, debe incorporársele la cooperación entre los individuos del *swarm*.

Desde tales consideraciones, pueden ser establecidos *cinco principios* que caracterizan la Inteligencia de Grupo - IG (*Swarm Intelligence Principles*). Los mismos son reconocidos como aspectos fundamentales en las estrategias mimetizadas de optimización, que se sustentan en el esfuerzo cooperativo, por medio de la comunicación entre los individuos del grupo, en la búsqueda de soluciones.

Estos principios, y su breve enunciación, resultan: **a) Proximidad:** Promueve la habilidad que debe exhibir el grupo, para ejecutar cálculos simples de espacio y tiempo en sus movimientos hacia el objetivo pretendido; **b) Calidad:** Promueve la habilidad del grupo para responder a los factores que induzcan mejoras en la aptitud de sus individuos, en el espacio de soluciones; **c) Diversidad de Respuesta:** Promueve la posibilidad de que los individuos tengan respuestas diferentes ante los mismos estímulos; **d) Estabilidad:** Promueve la habilidad de que el grupo permanezca estable, en ausencia de estímulos que induzcan mejoras en las soluciones alcanzadas; **y e) Adaptación:** Constituye un aspecto complementario de la Estabilidad, puesto que promueve la habilidad de que los individuos reaccionen ante cualquier cambio en la aptitud de las soluciones alcanzadas.

## 5. LA METAHEURÍSTICA PSO

### 5.1. PSO Clásico o Canónico

La Optimización por Enjambre de Partículas (*Particle Swarm Optimization - PSO*), constituye un algoritmo metaheurístico presentado en [Kennedy J., Eberhart R.C. ,1995]. Se inspira en el movimiento colectivo de cardúmenes de peces, bandadas de pájaros o enjambres de abejas, el cual los autores refieren como movimiento de partículas.

En el modelo *PSO Cánico* existe, en cada iteración hacia la solución buscada, un conjunto de alternativas (cuya factibilidad exhibe cierto grado de aptitud), las cuales son denominadas *partículas*. El conjunto es la población o *enjambre*. Desde una iteración a la siguiente, cada partícula se mueve en el espacio de búsqueda, conforme a cierta *regla de movimiento* que depende de *tres factores*, que se explican a continuación. Se indicará mediante  $[p]$  el vector de partículas en movimiento, de modo que  $p_i$  resultará una partícula individual de las  $n$  que pertenecen al enjambre. Adicionalmente, se indicará mediante  $[b]$  el vector de las mejores posiciones (cada posición es, a su vez, un vector) que las partículas han alcanzado individualmente en las iteraciones anteriores (aspecto referido en el modelo como vida pasada de la partícula); entonces  $b_i$  se corresponderá con el óptimo individual de la partícula  $i$  en su vida pasada. Del mismo modo, se indicará mediante  $[b]_G$  el vector cuyos elementos son las mejores posiciones globalmente alcanzadas por el conjunto de partículas

en las iteraciones anteriores; entonces se indicará mediante  $b_G$  al óptimo global alcanzado por el sistema de partículas hasta la iteración presente. Dado el vector que indica la posición de las partículas en cierta iteración  $k$ ,  $X^k$ , el cambio de posición en la iteración siguiente,  $k+1$ , para la partícula  $i$ -ésima, resultará de la siguiente regla de movimiento:

$$X^{[k+1]}_i = X^{[k]}_i + V^{[k+1]}_i x \Delta t \quad (2)$$

Dónde el término  $V^{[k+1]}_i$  es referido como velocidad de la partícula  $i$ -ésima;  $\Delta t$  es el paso de iteración (simil temporal) e igual a la unidad. De modo que es más frecuente encontrar la expresión:

$$X^{[k+1]}_i = X^{[k]}_i + V^{[k+1]}_i \quad (3)$$

El vector velocidad para la partícula  $i$ -ésima, se expresa como sigue:

$$V^{[k+1]}_i = V^{[k]}_i + w_C x (r_1^{[k]}) x [b^{[k]}_i - X^{[k]}_i] + w_S x (r_2^{[k]}) x [b^{[k]}_G - X^{[k]}_i] \quad (4)$$

En (4), representa la *inercia* o hábito de la partícula  $i$ : tiende a mantener su movimiento, para la iteración  $k+1$ , en la dirección en la que se movía en la iteración  $k$ . El segundo término representa la *memoria* o *capacidad cognitiva* de la partícula  $i$ : es atraída por el mejor punto del espacio de búsqueda alcanzado individualmente en su vida pasada; y el tercer término representa la cooperación entre el conjunto, o capacidad social, de la partícula  $i$  respecto del enjambre: las partículas comparten información sobre la mejor posición globalmente alcanzada por el enjambre. La incidencia de estos factores sobre cada partícula, está dada por las constantes o parámetros del modelo,  $w_{C,S}$ . El parámetro  $w_C$  recibe el nombre de *constante cognitiva* y el parámetro  $w_S$  se denomina *constante social* del enjambre. Intervienen los parámetros ( $r_1$ ) y ( $r_2$ ), los cuales son números aleatorios uniformemente distribuidos en  $[0,1]$ ,  $U[0,1]$ , y cuyo objetivo es emular el comportamiento estocástico (un tanto impredecible), que exhibe la población o enjambre, en cada iteración  $k$ .

Se observa que, partiendo de la posición que cada partícula tiene en cierto “instante” o iteración  $k$ ,  $X_{[k]}$ , por composición vectorial de cada factor de influencia en el operador velocidad (inercia, memoria y cooperación) resulta la nueva posición  $X_{[k+1]}$ . Nótese como cada partícula preserva, a través de la componente genérica  $V_{b[k]}$ , su memoria a la mejor posición registrada hasta ese “instante” o iteración  $k$ , a la vez que todas cooperan compartiendo la información sobre la mejor posición global alcanzada por enjambre, según indica la componente genérica  $V_{G[k]}$ .

Existen algunas variaciones, de interés para las propuestas del presente trabajo, sobre la forma *Canónica del PSO*. Se discuten brevemente en el epígrafe siguiente.

## 5.2. Modificaciones sobre el PSO Clásico. Función de decaimiento inercial y factor de constricción.

**A) PSO con Función de Decaimiento Inercial:** En esta forma, el operador velocidad, dado por la expresión (4), es modificado mediante la introducción de una función decreciente con el número de iteraciones,  $k$ , denominada Función de Inercia o de Decaimiento Inercial,  $\delta(k)$ . Su objeto es reducir, progresivamente, la importancia del término de inercia. La expresión (4) es, entonces, modificada sustituyendo el primer término por el producto entre una nueva constante,  $w_I$ , denominada *constante de inercia* y tal función  $\delta(k)$ :

$$\mathbf{V}^{[k+1]}_i = \delta(k) x w_I x \mathbf{V}^{[k]}_i + w_C x (r_1^{[k]}) x [\mathbf{b}^{[k]}_i - \mathbf{X}^{[k]}_i] + w_S x (r_2^{[k]}) x [\mathbf{b}^{[k]}_G - \mathbf{X}^{[k]}_i] \quad (5)$$

Una forma típica para  $\delta(k)$ , está dada por la siguiente expresión lineal:

$$\delta(k) = w_{Max} - \frac{(w_{Max} - w_{Min})}{nTK} \times k \quad (6)$$

Donde  $k$  es la iteración actual;  $nTK$  es el número máximo de iteraciones de la metaheurística; y  $[w_{Min}, w_{Max}]$  son dos constantes inerciales, máxima y mínima, cuyos valores típicos resultan ser  $0,4$  and  $0,9$  respectivamente.

La definición externa de la Función de Decaimiento Inercial requiere de cuidado, puesto que resulta intuitivo el hecho de que si el término de inercia resultase eliminado en iteraciones tempranas del algoritmo, el procedimiento corre el riesgo de quedar atrapado en una solución óptimo-local (o subóptima).

**B) PSO con Factor de Contricción ( $\chi$ -PSO):** En este caso, el operador velocidad canónico se modifica como sigue:

$$\mathbf{V}^{[k+1]}_i = \chi x \{ \mathbf{V}^{[k]}_i + \varphi_M x (r_1^{[k]}) x [\mathbf{b}^{[k]}_i - \mathbf{X}^{[k]}_i] + \varphi_C x (r_2^{[k]}) x [\mathbf{b}^{[k]}_G - \mathbf{X}^{[k]}_i] \} \quad (7)$$

Donde  $\chi$  se denomina Factor de Constricción, y se obtiene desde la siguiente expresión:

$$\chi = \frac{2 \times \kappa}{2 - \varphi - \sqrt{\varphi^2 - 4 \times \varphi}} \quad (8)$$

$$\text{Con } \varphi_M + \varphi_C = \varphi; \varphi > 4 \text{ y } 0 < \kappa \leq 1 \quad (9)$$

Dos configuraciones típicas para este conjunto de parámetros, resultan ser: a)  $\varphi_M = \varphi_C = 2.05, \varphi = 4.1, \kappa = 1, \chi = 0.729$ ; b)  $\varphi_M = \varphi_C = 2.8, \varphi = 4.1, \hat{e} = 1, \chi = 0.729$ .

Esta variante del *PSO*,  $\chi$ -*PSO*, será empleada en la simulación presentada.

## 6. LA METAHEURÍSTICA EPSO

La Optimización Evolucionaria por Enjambre de Partículas (*Evolutionary Particle Swarm Optimization - EPSO*) propuesta en [Miranda V., et al., 2008], constituye un algoritmo de optimización metaheurístico que integra los conceptos de Estrategias Evolutivas (*Evolution Strategic*) y Optimización de Enjambre de Partículas (*Particle Swarm Optimization*). Los autores proponen conferirle al *PSO* una capacidad auto-adaptativa, tal que permita a la metaheurística desarrollar un proceso de cambio de comportamiento, conforme resulte la evolución de las soluciones. La auto-adaptación, permitiría que, en cada iteración  $k$ , los parámetros que requieren de ajuste externo puedan adaptarse sin el riesgo referido de convergencia prematura a un óptimo local. El mecanismo del algoritmo *EPSO* se puede describir de la siguiente manera: para una iteración  $k$  del *PSO*, las partículas evolucionarán a lo largo de un cierto número de generaciones, según los siguientes operadores evolutivos: a) Replicación: cada partícula es replicada un número  $r$  de veces, generando partículas iguales a las existentes; b) Mutación: los parámetros estratégicos (constantes de inercia, cognitiva y social, esencialmente) son mutados (adoptan, en rigor, el carácter de parámetros con la iteración  $k$ ); c) Evaluación: cada sucesor concebido a través de los pasos anteriores, es evaluado mediante la función de aptitud definida; d) Selección: mediante algún proceso (típicamente, el torneo estocástico), las mejores partículas sobreviven para formar la nueva generación, que se somete, en la iteración siguiente, a la nueva regla de movimiento. La ecuación evolutiva para la regla del movimiento en el *EPSO*, se sintetiza en la velocidad de la partícula  $i$ -ésima, entendiendo que la iteración  $k$  se corresponde con una nueva generación:

$$\mathbf{V}^{[k+1]}_i = w_{iI}^{*[k]} x (r_1^{[k]}) x \mathbf{V}^{[k]}_i + w_{iC}^{*[k]} x (r_2^{[k]}) x [\mathbf{b}^{[k]}_i - \mathbf{X}^{[k]}_i] + w_{iS}^{*[k]} x (r_3^{[k]}) x [\mathbf{b}^{[k]*}_G - \mathbf{X}^{[k]}_i] \quad (10)$$

Donde el superíndice (\*), significa que los parámetros son evolutivos, producto de la mutación. La regla de mutación aplicable a las constantes  $w_{iI}, C, S$  tiene, como expresión general:

$$w_{iI, C, S}^{*[k+1]} = w_{iI, C, S}^{[k]} x [1 + \sigma x N(0, 1)] \quad (11)$$

en la cual:  $\sigma$  es un parámetro de aprendizaje, externamente fijado, que controla la amplitud de las mutaciones;  $N(0, 1)$  es una variable aleatoria con distribución gaussiana de media  $0$  y varianza  $1$ . Adicionalmente, el óptimo global también es perturbado en cada iteración, según la regla:

$$\mathbf{b}^{[k+1]*}_G = \mathbf{b}^{[k]*}_G + w_{iN}^{*[k]} x N(0, 1) \quad (12)$$

Donde  $w_{iN}^{*[k]}$ , es un cuarto parámetro estratégico de la regla de movimiento, que controla la amplitud del vecindario de  $b^{[k]*}_G$  donde es más probable localizar la mejor solución global (entendida, al menos, como una solución mejor que la  $b^{[k]*}_G$  actual, para la iteración  $k$ ). El nuevo parámetro, como se indica con el superíndice (\*), es también mutado según la regla (11). Se infiere que en la regla de movimiento modificada para el *EPSO*, el vector cooperación mutado no apuntará en la dirección de  $b^{[k]*}_G$ , sino de  $b^{[k]*}_G$ .

## 7. TOPOLOGÍA EN LA COMUNICACIÓN ENTRE PARTÍCULAS EPSO

Atendiendo al modo en el que se transmite la información entre cada partícula y el resto del enjambre, surgen las topologías global y local. Se asume que el modelo es síncrono es decir que todas las partículas se mueven en paralelo; en cada iteración se evalúa la aptitud de cada partícula, se actualiza su memoria y el conocimiento social y, a continuación, la población se desplaza hacia un nuevo punto tomando como referencia esta información. Respecto del criterio referido a las topologías, en *PSO* los individuos mejoran sus aptitudes imitando los comportamientos y tendencias que encuentran en los mejores congéneres de la población. Entonces, establecer cómo se define la vecindad de un individuo, o lo que es lo mismo, qué otros individuos le influyen, tiene una trascendencia vital en el rendimiento del algoritmo o, lo que es equivalente, en el grado de satisfacción de los cinco principios de la Inteligencia de Grupo, IG. Dependiendo de la topología que adquiera la población, la transmisión de la información entre individuos puede acelerarse o ralentizarse, lo cual está estrechamente relacionado con la velocidad de convergencia y con la capacidad del algoritmo para escapar de soluciones locales.

La topología más extendida es la topología de red global, en la cual todos los individuos están interrelacionados y tienen acceso inmediato a los hallazgos de sus congéneres. Sin embargo, esta estructura social resulta vulnerable a soluciones locales, dado que, dependiendo de la distribución puntual de las partículas sobre el espacio de soluciones, una de ellas, dirigida a una solución local, puede llegar a dominar al resto. La alternativa (más empleada), es la topología local, donde cada partícula orienta su trayectoria influida por sus ( $nv$ ) vecinas adyacentes, quedando, en cierta medida, aislada de las partículas más alejadas del enjambre. De entre todas las ( $nv$ ) vecinas, la partícula extrae las propiedades de aquella con mejor aptitud, utilizándolas para actualizar su vector velocidad y su vector posición. A los efectos de determinar el grado de vecindad de una partícula, lo más sencillo es elegir aquellas partículas topológicamente más próximas.

En las referencias citadas, el problema práctico elegido en el presente trabajo, ha sido resuelto con un modelo síncrono de topología global, con las variantes del *PSO* Clásico presentadas, extendiendo sus capacidades a la optimización Multi-Objetivo, mediante la formulación de una función de aptitud difusa. Análogamente, se ha empleado también la metaheurística *EPSO*.

Sin embargo, conforme la estructura que exhibe el espacio de búsqueda de un problema como el de Balance de Fases (muy pocos puntos aislados que satisfacen los umbrales impuestos en las magnitudes a optimizar), se plantea de qué manera podría incidirse sobre los principios de la Inteligencia de Grupo, propiciando la disminución de tiempo en el hallazgo de buenas soluciones. Como se sugirió, el punto central parece estar en la forma o estructura solidaria a la comunicación de las partículas, y es por ello que se planteó, primero, una topología radial, la cual no brindó resultados diferentes. Entonces se introdujo una idea sustentada en la referencia [Miranda V., et. al., 2008], denominada Topología Estrella Estocástica Global. Su concepto altera los términos de la comunicación de aquella posición o partícula (solución) que ha alcanzado en cierta iteración,  $k$ , el Óptimo Global (*OG*),  $b^{[k]*}_G$ , que es un vector de tantas dimensiones como lo establece el espacio de búsqueda, según se dijo. En lugar de que todas las partículas se dejen influenciar del mismo modo por la que detenta el OG, conforme se aprecia en la Ecuación Evolutiva de Movimiento *EPSO*, (10), que se corresponde con una topología Global, se asigna una probabilidad de que dicho OG afecte o no a las restantes partículas del enjambre y su valor es una cuantía de afectación entre 0 y 1. Puede observarse que, con ello, se propicia al principio de Diversidad, enunciado en el epígrafe 4. dedicado a la IG.

Se introduce, entonces, una nueva topología para definir la comunicación entre partículas, propuesta en el presente artículo. Se sostiene la idea de Estrella Estocástica, en la vecindad del OG definida por probabilidades de comunicación no nulas. Pero se incorpora la probabilidad, que hasta el momento es nula, de que también las partículas incidan sobre otras informándoles de su posición. Por ello el nombre de *Topología Estrella (estocástica) Global/Individual*. Los Óptimos Individuales (OI) de las partículas del enjambre, tienen ahora cierta probabilidad, que puede ser nula, de incidir sobre el resto. Se introduce, para gobernar esta afectación, luego de diversas pruebas, propendiendo al principio Estabilidad de la IG, un Factor de Decaimiento cuya estructura es idéntica al de  $\delta(k)$ , presentado en la ecuación (6). Este factor multiplicativo,  $\delta(k)$ , va haciendo “decaer” la influencia de los óptimos individuales, OI, con probabilidades distintas de 0, desde cada partícula del enjambre hacia el resto, conforme aumenta el número de iteraciones. Con esto se logra una capacidad auto-adaptativa adicional en la metaheurística para espacios de búsqueda como el descrito: las partículas exhiben una mayor diversidad de posiciones en iteraciones tempranas, para luego dejarse influir por el OG evolutivo, a medida que el decaimiento de las incidencias estocásticas de los OI, se va sucediendo conforme aumenta el número de iteraciones. Así es concebida la metaheurística *EPSO GIST*, cuya Ecuación Evolutiva de Movimiento, viene

dada mediante la expresión:

$$\begin{aligned} V^{[k+1]}_i &= w_{iI}^{*[k]} x (r_1^{[k]}) x V^{[k]}_i + w_{iC}^{*[k]} x (r_2^{[k]}) \\ &x [b^{[k]}_i - X^{[k]}_i] + w_{iS}^{*[k]} x (r_3^{[k]}) x [b^{[k]*}_G - X^{[k]}_i] \\ &x \alpha_{OG}^{[k]}_i + \sum_{j=1, j \neq i}^n (\delta(k) x w_{iC}^{*[k]} x [b^{[k]}_j - X^{[k]}_j] \\ &x \alpha_{OI}^{[k]}_{ij} \end{aligned} \quad (13)$$

donde:  $\alpha_{OG}^{[k]}_i$  es la probabilidad de que el Óptimo Global afecte al movimiento de la partícula  $i$ , en la iteración  $k$  y  $\alpha_{OI}^{[k]}_{ij}$  es la probabilidad de que el Óptimo Individual de la partícula  $j$ , afecte al movimiento de la partícula  $i$ ,  $j \neq i$ .

## 8. EXTENSIÓN DE LA FUNCIÓN DE APTITUD AL DOMINIO DIFUSO: FUNCIÓN MULTI-OBJETIVO

### 8.1. Conjuntos difusos objetivos y decisión estática maximizante

En este modelo se propone simular, previamente al desarrollo de las funciones de pertenencia solidarias a cada objetivo, Optimizaciones  $\chi$ -PSO Mono-Objetivo. Esto es: *minimizar pérdidas*, *minimizar componente homopolar referida a la salida*, y *maximizar el Índice de Tensión fuera de Tolerancia*, respectiva e individualmente. Pueden, entonces, establecerse las referencias pertinentes que permitirán definir los correspondientes conjuntos difusos componentes de la función de aptitud para las metaheurísticas Multi-Objetivo.

### 8.2. Función de pertenencia para el conjunto difuso de las pérdidas (perd)

Las pérdidas (refiriéndonos aquí a las pérdidas de potencia activa) resultan, directamente, del Flujo de Potencia Radial Trifásico (FPRT). Sea  $Minperd$ , las pérdidas resultantes de la Optimización  $\chi$ -PSO Mono-Objetivo, y  $Refperd$  las pérdidas resultantes de correr un FPRT en la situación base. El conjunto difuso solidario a las *pérdidas*, tendrá la siguiente expresión condicional para su *función de pertenencia*:

$$\mu(perd) = 1; \text{ si } perd \leq Minperd \quad (14)$$

$$\mu(perd) = [(Refperd - perd) / Refperd]^{p(perd)}; \text{ si } Minperd \leq perd \leq Refperd \quad (15)$$

$$\mu(perd) = 0; \text{ si } perd > Refperd \quad (16)$$

donde  $p(perd)$  es un ponderador exponencial externamente fijado. Su efecto es la *contracción* (*mayor importancia relativa* del conjunto, en el *proceso de decisión estática*), si  $p(perd) > 1$ , o la *dilatación* (*menor*

*importancia relativa*), si  $p(perd) < 1$ , de  $\mu(perd)$  sobre el resto de los objetivos.

### 8.3. Función de pertenencia para el Conjunto difuso de la componente homopolar (CH)

La componente homopolar,  $I^{[0]}$ , se obtiene como la suma de las tres corrientes de fase,  $I^{[R]} + I^{[S]} + I^{[T]} = 3 x I^{[0]}$ , conforme el Teorema de Fortescue (Fortescue, 1918) (también llamado de las Componentes Simétricas) aplicado a sistemas trifásicos desbalanceados. El procedimiento que se ha seguido para su cálculo es el siguiente: **1ro)** se suman las tres inyecciones ( $R, S, T$ ), en cada nodo, obteniendo la componente homopolar que aportará cada uno de los mismos al retorno por tierra; **2do)** este valor será equivalente a la suma, dividido 3, de las tres corrientes de salida para la primer rama. Por esta razón, el balance de intensidades, se dice referido a la salida del CT MT/BT. Su importancia estriba en que **a)** en BT, si se utilizasen, las protecciones principales que pueden interpretar un elevado valor de  $I^{[0]}$  como falla, son instaladas en la salida del transformador y **b)** se busca que, “aguas arriba” (red de MT), el subsistema “vea” cargas con el menor grado de desbalance posible (CT MT/BT). Este criterio satisface lo dicho en el epígrafe 2., inciso **c)**. Sea, entonces,  $MinCH$  la componente homopolar resultante de la Optimización PSO Mono-Objetivo, y  $RefCH$  la resultante de correr un FPRT en la situación base. Análogamente a las pérdidas, se tiene la siguiente expresión condicional de la *función de pertenencia* correspondiente al conjunto difuso  $CH$ :

$$\mu(I^{[0]}) = 1; \text{ si } I^{[0]} \leq MinCH \quad (17)$$

$$\mu(I^{[0]}) = [(RefCH - I^{[0]}) / RefCH]^{p(I^{[0]})}; \text{ si } MinCH \leq I^{[0]} \leq RefCH \quad (18)$$

$$\mu(I^{[0]}) = 0; \text{ si } I^{[0]} > RefCH \quad (19)$$

Lo dicho  $p(perd)$  para vale también  $p(I^{[0]})$ .

### 8.4. Función de pertenencia para el conjunto difuso del índice de tensión fuera de tolerancia (ITS)

El perfil de tensiones también otro de los resultados que arroja el El *perfil de tensiones* también otro de los resultados que arroja el FPRT. En un sistema radial, y para los propósitos de este trabajo, basta con analizar qué módulos de tensión se tiene en los nodos terminales, puesto que “aguas arriba” (hacia el nodo de salida) del sistema, se tendrán valores mayores:

**a)** Se fijan: un *límite inaceptable* de tensión en los nodos terminales,  $u_{nad}$ , y un *límite aceptable* en los mismos,  $u_{ad}$ . Los empleados en la simulación son:  $u_{nad} = 0.92$  [pu] y  $u_{ad} = 0.95$  [pu]; **b)** Se definen los valores recíprocos de las tensiones límites especificadas en **a)**:  $v1 = 1/u_{ad}$ , y  $v2 = 1/u_{nad}$ ; **c)** Dado un valor de tensión,  $u$ , en cierto nodo terminal,  $nt$ , se calcula su recíproco,  $v_{ft} = 1/u$ . Luego, la expresión condicional para la *función de pertenencia* correspondiente al conjunto difuso *tensión fuera de tolerancia*, de variable  $v_{ft}$ , evaluada en el nodo terminal  $nt$ , resulta:



$$\mu(vft) = 1; \text{ si } vft \leq v1 \quad (20)$$

$$\mu(vft) = [(v2 - vft) / (v2 - v1)]^{p(vft)}; \text{ si } v1 \leq vft \leq v2 \quad (21)$$

$$\mu(vft) = 0; \text{ si } vft > v2 \quad (22)$$

Lo dicho  $p(perd)$  para vale también  $parap(vft)$ .

Finalmente, como Índice de Tensión fuera de Tolerancia,  $ITS$ , se propone la media geométrica de todos los valores  $\mu_{nt}(vft)$  en el conjunto de los nodos terminales,  $\{NT\}$ :

$$\mu(Utf) = \sqrt[nNT]{\prod_{nt=1}^{nNT} i_{nt}(vft)} \quad (23)$$

## 8.5. Función de pertenencia para el conjunto difuso del número de cambios (NCf)

La inclusión de este objetivo, respeta el criterio de buscar la mejor solución con el menor número de cambios posibles, por razones de costos y tiempos de interrupción del servicio. La referencia correspondiente al número de cambios de fase, ( $NCf$ ) se adopta desde el máximo de los resultantes en cada una de las optimizaciones PSO Mono-Objetivo. Entonces:

$$RefNCf_{Max} = MAX \{NCf_{PSOMinperd}; NCf_{PSOMinCH}; NCf_{PSOMaxITS}\} \quad (24)$$

Se observa que el PSO Mono-Objetivo para maximizar el  $ITS$ , es requerido al efecto de lograr el valor de  $NCf_{PSOMaxITS}$ , no para componer  $\mu(utf)$ .  $RefNCf_{Max}$ , constituye un *límite máximo admisible*, puesto que los cambios de fase son contabilizados respecto de la situación base, a la cual le corresponde  $NCf = 0$ . Para poder obtener un *límite mínimo admisible*, una posibilidad es obtener el mínimo de los valores de (24), al cual se le sustrae un cierto valor  $NCf0$ , fijado externamente:

$$RefNCf_{Min} = MIN \{NCf_{PSOMinperd}; NCf_{PSOMinCH}; NCf_{PSOMaxITS}\} - NCf0 \quad (25)$$

Luego, la expresión para la *función de pertenencia* correspondiente al conjunto difuso  $NCf$ , es la siguiente:

$$\mu(NCf) = 1; \text{ si } vft \leq v1 \quad (26)$$

$$\mu(NCf) = [(v2 - vft) / (v2 - v1)]^{p(vft)}; \text{ si } v1 \leq vft \leq v2 \quad (27)$$

$$\mu(NCf) = 0; \text{ si } vft > v2 \quad (28)$$

Lo dicho  $p(perd)$  para vale también para  $p(NCf)$ .

## 8.6. Decisión maximizante: La t-Norma producto de Einstein

Debe establecerse el *operador de confluencia* entre los *conjuntos difusos*, a efectos de obtener la *decisión maximizante* [Bellman & Zadeh, 1970] que definirá el valor de la *función difusa de aptitud*

en cada iteración del algoritmo. Para ello se emplea una *t-norma*, la cual es una función  $t$  definida en el intervalo  $[0, 1]$  aplicado también en  $[0, 1]$ . Satisface las siguientes condiciones:

Si  $t: [0, 1] \rightarrow [0, 1]$  es una *t-norma*, entonces: a.-  $t(0,0) = 0$ ;  $t(x,1) = x$  - *Condiciones de Frontera*; b.-  $t(x,y) = t(y,x)$  - *Conmutatividad*; c.- si  $x \leq \alpha$  e  $y \leq \beta \Rightarrow t(x,y) \leq t(\alpha,\beta)$  - *Monotonicidad*; d.-  $t(t(x,y),z) = t(x,t(y,z))$  - *Asociatividad*.

Para este problema específico, la *t-norma MIN*, comúnmente utilizada, no genera buenos resultados. La principal limitación estriba en que existen estados del espacio de búsqueda, en los cuales se mantienen en valores muy similares tres de los cuatro objetivos, mientras que el cuarto se modifica de manera importante, mejorando su aptitud individual. Al establecer la decisión maximizante mediante el *MIN*, la aptitud difusa casi no se modifica, ignorando lo que no sólo fue una mejor solución, sino lo que aportaría mejor información al enjambre para localizar soluciones superadoras. La *t-norma* que mejor resultados produjo en esta aplicación, es la referida como *Producto de Einstein*, y se define del siguiente modo:

$$t_{PEinstein}: (x,y) \rightarrow \frac{x \times y}{2 - (x + y - x \times y)} \quad (29)$$

donde  $x$  e  $y$  son funciones de pertenencia genéricas. Puede verificarse que  $t_{PEinstein}$  satisface todas las condiciones a-d arriba enunciadas. Para el modelo presentado, desde la propiedad de *asociatividad*, d.-, se tiene el cálculo del *Producto de Einstein* mediante los siguientes pasos:

$$t_{PEinstein}^1 = \frac{\mu(perd) \times \mu(|I^{[0]}|)}{2 - (\mu(perd) + \mu(|I^{[0]}|) - \mu(perd) \times \mu(|I^{[0]}|))} \quad (30)$$

$$t_{PEinstein}^2 = \frac{t_{PEinstein}^1 \times \mu(utf)}{2 - (t_{PEinstein}^1 + \mu(utf)) - t_{PEinstein}^1 \times \mu(utf)} \quad (31)$$

y, por último:

$$i_D = \frac{t_{PEinstein}^2 \times \mu(ncf)}{2 - (t_{PEinstein}^2 + \mu(ncf)) - t_{PEinstein}^2 \times \mu(ncf)} \quad (32)$$

siendo:

$$\mu_D = t_{PEinstein} \{ \mu(perd); \mu(|I^{[0]}|); \mu_{nt}(utf); \mu(ncf) \} \quad (33)$$

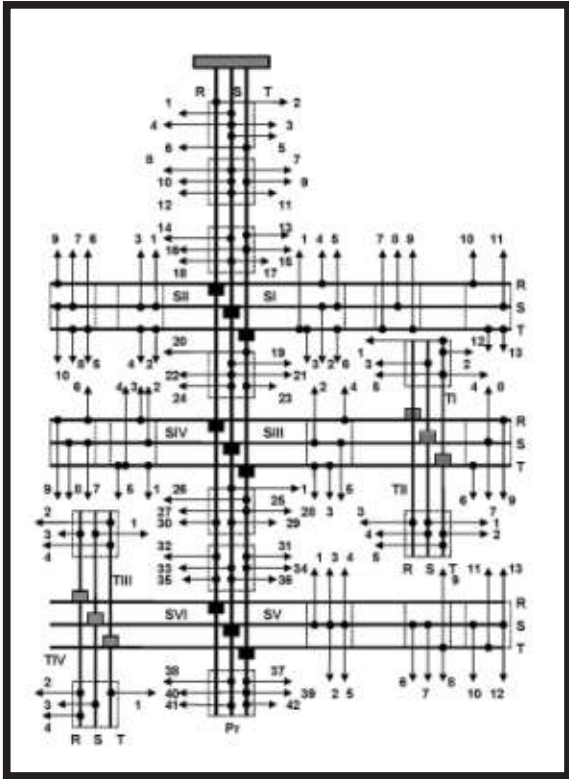
La *decisión maximizante* que proporciona la *aptitud difusa de la solución evaluada*. El proceso iterativo

que implementa la metaheurística se detiene cuando la aptitud dada por (33), se mantiene sin cambios por cierto número de iteraciones  $NItera$ .

## 9. SIMULACIÓN

### 9.1. Sistema considerado

Es una salida real de un CT MT/BT en una de la ciudad de San Carlos de Bariloche. Las cargas son monofásicas. El esquema trifilar se presenta en la Figura 2.



**Figura 2:** Esquema Trifilar de la Red/Salida CT MT/BT considerada en la Simulación. Sobrecargas Importantes en las Fases [S] y [T]

**Fuente.** Elaboración propia

### 9.2. Datos y resultados obtenidos

En el Cuadro1, se muestran los valores de las potencias En el Cuadro1, se muestran los valores de las potencias aparentes, en [kVA], de cada carga, a factor de potencia constante,  $\cos\phi_i = 0.8$ .

Se ha considerado un factor de simultaneidad  $F_s = (1/1.7) \approx 60\%$  en el pico de demanda. De este modo, todas las cargas son multiplicadas por este valor antes de proceder a los cálculos. Los conductores son del tipo preensamblado, siendo sus parámetros:  $Alim Pr: 3 \times 95 [mm^2]$ ,  $(r = 0.372 + i \cdot xl = 0.0891) [\Omega]/[km]$  y  $Alim SI, SII, SIII, SIV, SVI, TII, TIII$  y  $TIV: 3 \times 35 [mm^2]$ ,  $(r = 1.39 + i \cdot xl = 0.0973) [\Omega]/[km]$ .

También se muestran los vectores de conexión resultantes en las Optimizaciones PSO Mono-Objetivo:  $[fMPerd]$ ,  $[fMI^{10}]$ ,  $[fUft]$  y (en letra itálica) el vector de conexión resultante para la Optimización FPSO MultiObjetivo,  $[fPE]$ . Las fases de conexión son [R, S, T]. Se utilizaron aplicaciones software desarrolladas por los autores en MATLAB, C++ y VB. El esquema PSO empleado responde a una Topología Global/Sícrona y la Ecuación de Movimiento incluye un Factor de Constricción,  $\chi$ , ecuación (9). Como se dijo, las variables son las conexiones de las cargas y la dimensión del problema es  $nC=115$  (existen 4 nodos derivadores). Los dominios para tales variables, son tres valores enteros [R=1, S=2, T=3].

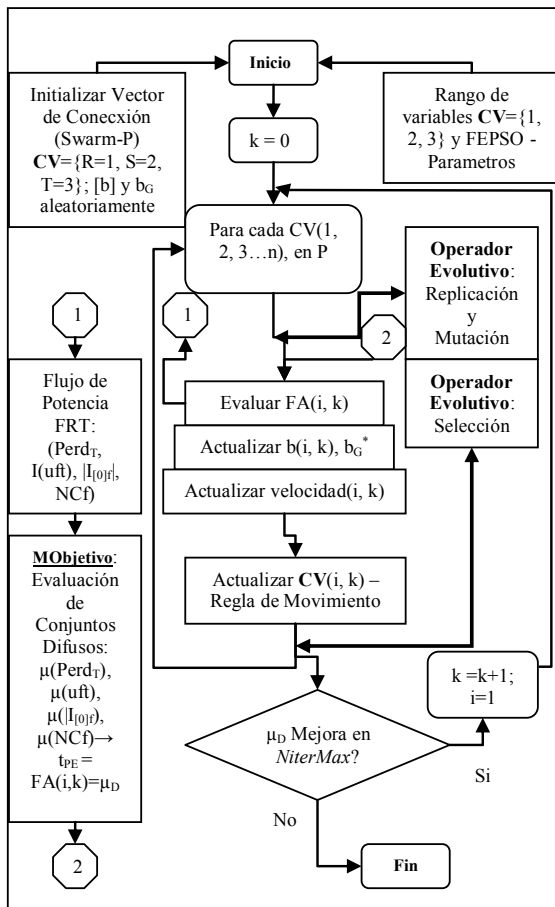
Esta modalidad  $\chi$ -PSO le confiere buena capacidad autoadaptativa al enjambre, para moverse en un espacio de búsqueda de  $3^{115}$  estados, cuyas variables pueden adoptar valores en un intervalo discreto muy reducido. En el Cuadro2, se presentan los resultados numéricos obtenidos, parámetros de las funciones de pertenencia, número de partículas del enjambre y tiempos de ejecución. Un aspecto que debe remarcar en este modelo, es la introducción de un procedimiento *bootstrap* o *de arranque* para las iteraciones tempranas del  $\chi$ -PSO  $\mu(Uft)$  y en la metaheurística FSA, pero no en la FEPSO GIST. El perfil de tensiones admisible, es casi una "rareza" en el espacio de búsqueda. Existirán muy pocos vectores de conexión que podrán satisfacerlo. Por tal motivo, por ejemplo, si se comienza el  $\chi$ -PSO en el caso mencionado, al ser el Índice,  $\mu(Uft)$ , estricto (no se admite ningún nodo con tensión en módulo inferior a  $Unad$ ), las aptitudes resultarán cero.

Como tanto la mejor posición global como la individual de cada partícula del enjambre, reciben esta información, es muy improbable que conciban una dirección hacia donde el enjambre, en promedio, deba moverse, tal que  $\mu(Uft) > 0$ . Como resultado, se tiene una convergencia prematura hacia un valor de aptitud 0, que nada dice sobre las mejoras pretendidas en los objetivos. Por ello, el *bootstrapping* en las iteraciones tempranas, se basa en otro indicador de  $\mu(Uft)$ , que, simplemente, cuenta el número de nodos terminales del sistema que se encuentran fuera de tolerancia,  $Nntft$ . La nueva función de pertenencia, se propone como:  $\mu(Uft)^* = e^{-[\zeta \times Nntft]}$ ; con  $0 < \zeta \leq 1$ . Se itera, entonces, evolucionando con estas soluciones y llevando, simultáneamente, el cálculo de  $\mu(Uft)$ . Cuando el OG alcanzado implique  $\mu(Uft)^* > 0$ , se cambia de  $\mu(Uft)^*$  a  $\mu(Uft)$ , y se continúa el proceso tal como se explicó. Este *bootstrapping* o *arranque*, generó siempre muy buenos resultados. En cambio el FEPSO GIST pudo encontrar, en todas las simulaciones ejecutadas, y a expensas de la mejora en la Diversidad de sus soluciones proporcionada por su topología, un punto de referencia que rápidamente fue comunicado al resto de las partículas, sin que las mismas fuesen impelidas hacia él, en iteraciones tempranas, continuando la mejora en la solución primigenia respecto del OG, y en tiempos menores, como se observa en el Cuadro2.

El algoritmo FEPSO GIST, ss descrito en el diagrama de flujo de la Figura 3.  $NIterMax$  es el máximo número de iteraciones, externamente fijado. También, en la misma Figura 3, es posible observar el flujo de tareas que corresponde al  $\chi$ -PSO aplicado en cada optimización individual, Mono-Objetivo.

Para ello, deben omitirse los procesos denominados **MO** objetivo (metaheurística Multi-Objetivo) y **Operadores Evolutivos** en tal diagrama.  $\delta(k)$  decae un 5% por iteración, partiendo de  $\delta(0)=1$ . Por otro lado, los parámetros empleados en la metaheurística *FSA*, son listados a continuación: a) Temperatura Inicial:  $T_0 = 1.0$ ; b) Número de Iteraciones para la misma Temperatura:  $NT=100$ ; c) Máximo Número de Iteraciones sin mejorar la Función de Aptitud, FA (condición de parada del Algoritmo *FSA*):  $nMaxI = 300$ ; d) Tasa de Enfriamiento:  $\alpha = 0.8$ ; e) Función de Generación de la Vecindad para cierto estado  $i, q(i, j)$ : Se sustenta en la selección, aleatoria, de una carga monofásica que es conectada en cualquier otra fase del sistema; f) Constante  $kB$  (para la determinación de  $c$ , en la expresión (1)):  $kB = 0.00025$ .

La Misma Función de Aptitud Difusa que para el FEPSO GIST,  $i_D = t_{Peinstein} \{ \mu(perd); \mu(|I^{(0)}|); \mu_{nt}(vft); \mu(ncf) \}$ , es evaluada a partir de los resultados de un Flujo de Potencia Trifásico.



**Figura 3:** Esquema *FEPSO GIST* para la Simulación para la Optimización del Grado de Desbalance de Fases del Sistema esquematizado en la Figura2. Cada  $Vc(1,2,3)$  es una *partícula* en la población,  $P$ ,  $vC$  es cada *variable de conexión*  
**Fuente.** Elaboración propia


Por último, a los fines de comparar la diferencia entre las metaheurísticas  $\chi$ -PSO y *FEPSO GIST*, respecto de la dirección hacia el OG en cada partícula, obtenida de su correspondiente Ecuación de Movimiento, Se presenta la Figuras 4.

**10. CONCLUSIONES**

1ra) Se ha presentado una novedosa metaheurística, *FEPSO GIST* Multi-Objetivo, para resolver el problema del desbalance de fases en SDEE trifásicos de Baja Tensión, propendiendo a la Eficiencia Energética del Lado de la Oferta. El Cuadro 2 muestra, respecto de la situación base del sistema real considerado, los muy buenos resultados obtenidos.

2da) En la metaheurística *FEPSO GIST* no es necesaria la inclusión del procedimiento bootstrap o de arranque, al que se recurre en el Algoritmo *FSA*, dadas las mayores capacidades autoadaptativas y las mejoras introducidas en los cinco principios de la Inteligencia de Grupo.

3ra) Cabe destacar la comparación que puede realizarse entre las metaheurísticas *FPSO* y *FEPSO* empleadas para resolver este problema, y observar cómo la topología *GIST*, permite resolverlo más rápido, con un menor número de parámetros a controlar externamente. Esta constituye una línea de investigación que, a juicio del autor, debería ser profundizada.



**Figura 4:** Óptimo Global,OG,  $b_G$  en  $\chi$ -PSO y  $b_G^*$  en *FEPSO GIST*. Efecto de la Mutación EPPO  
**Fuente.** Elaboración Propia

**Alimentador Pr (Primario)**  
 [S] = [1.8 1.15 1.15 1.95 1.15 1.15 1.13 1.14 1.15 1.15 1.14 1.15 2.93 1.12 1.13 1 1.15 1.15 1.15 1.15 1.15 1.17 1.16 1.15 1.13 1.13 1.12 1.13 1.15 1.15 1.15 1.18 1.16 1.15 1.15 1.17 1.15 1.18 1.36 1.36 1.36 1.36]  
 [d] = [0.035 0.035 0.035 0.035 0.035 0.035 0.035 0.045 0.045 0.045 0.045 0.045 0.045 0.045 0.045 0.065 0.065 0.065 0.065 0.065 0.065 0.095 0.095 0.095 0.095 0.095 0.095 0.16 0.16 0.16 0.16 0.16 0.16 0.45 0.45 0.45 0.45 0.45 0.45 0.7 0.7 0.7 0.7 0.7 0.7]  
 [fMPerd] = [T S R S S S T T S R S R S S S S T S T T R T T T S T R T T T S T R T T T S T R T T S R R R S]  
 [fMI<sup>[0]</sup>] = [S S S T S S R T R R R S R S T T S S R S S S R T R S T S R T R S T T T R S R R T R]  
 [fUft] = [R S R T R R T R R S R R R S R R T T T R R S T T R T S T T T S T R R T R S S S S S]  
 [fPE] = [R R S T R R T R R S R R R S R R R T R R R T S R R T S T T R T S R R T S S T T S S]

**Alimentador Si (Secundario)**  
 [S] = [1 1.15 1 1.15 1.155 1 1.15 1.17 1.15 1.15 1.18 1.125 1.125]  
 [d] = [0.1 0.1 0.1 0.1 0.1 0.1 0.25 0.25 0.25 0.3 0.3 0.3 0.3]  
 [fMPerd] = [T R R T S R R T R T S T R] -- [fMI<sup>[0]</sup>] = [T T T T S R S R T S R S R]  
 [fUft] = [T T S S R R T S T S S T S] -- [fPE] = [T S T R S R T S T R S T T]

**Alimentador SII (Secundario)**  
 [S] = [1.15 1.158 1.125 1.125 1.118 1.125 1 1.15 1.15 1.18]  
 [d] = [0.15 0.15 0.15 0.15 0.3 0.3 0.3 0.3 0.3 0.3]  
 [fMPerd] = [T T R T T R R T R R] -- [fMI<sup>[0]</sup>] = [T T T R S T R R S T]  
 [fUft] = [S T T T S S S R T R] -- [fPE] = [R T T T S S S R T R]

**Alimentador SIII (Secundario)**  
 [S] = [1 1.15 1 1.155 1.155 1.18 1.15 1.155 1.15] -- [d] = [0.25 0.25 0.25 0.25 0.25 0.35 0.35 0.35 0.35]  
 [fMPerd] = [T S R S S T R T R] -- [fMI<sup>[0]</sup>] = [T T S T T S R T R]  
 [fUft] = [R R R S T T T S S] -- [fPE] = [R S R R T T S S T]

**Alimentador SIV (Secundario)**  
 [S] = [1.15 1.148 1.125 1.125 1.15 1.18 1.125 1 1.15] - [d] = [0.1 0.1 0.1 0.1 0.1 0.2 0.2 0.2 0.2]  
 [fMPerd] = [S R R T R T R T T] -- [fMI<sup>[0]</sup>] = [S R T R R T S T R]  
 [fUft] = [T T S S T S T S T] -- [fPE] = [T S R R T R S S T]

**Alimentador SV (Secundario)**  
 [S] = [1 1.15 1 1.12 1.125 1 1.18 1.12 1.155 1.15 1.128 1.125 1.125]  
 [d] = [0.1 0.1 0.1 0.1 0.1 0.15 0.15 0.15 0.15 0.2 0.2 0.2 0.2]  
 [fMPerd] = [S R T T T R S R R S S S R] -- [fMI<sup>[0]</sup>] = [R T R R S T T S R S S R R]  
 [fUft] = [R S T T R S T R R S S S S] -- [fPE] = [R S T T R S T R T S S S S]

**Alimentador TI (Terciario)**  
 [S] = [1 1.15 1 1.128 1.125] - [d] = [0.15 0.15 0.15 0.15 0.15]  
 [fMPerd] = [R T T S R] -- [fMI<sup>[0]</sup>] = [T S R S T] -- [fUft] = [S T T S S] -- [fPE] = [T T S S T]

**Alimentador TII (Terciario)**  
 [S] = [1 1.122 1 1.124 1.15] - [d] = [0.095 0.095 0.095 0.095 0.095]  
 [fMPerd] = [R T R T R] -- [fMI<sup>[0]</sup>] = [S T S R T] -- [fUft] = [T T S S T] -- [fPE] = [T S S S T]

**Alimentador TIII (Terciario)**  
 [S] = [1 1.152 1.123 1.725] - [d] = [0.135 0.135 0.135 0.135]  
 [fMPerd] = [R S S R] -- [fMI<sup>[0]</sup>] = [R T R R] -- [fUft] = [T R S S] -- [fPE] = [S R S T]

**Alimentador TIV (Terciario)**  
 [S] = [1.12 1.15 1 1.8] - [d] = [0.125 0.125 0.125 0.125]  
 [fMPerd] = [S R R R] -- [fMI<sup>[0]</sup>] = [T S R S] -- [fUft] = [T S R S] -- [fPE] = [T S S S]

**Cuadro 1:** Potencias [kVA] y Distancias al Nodo de Salida [km]. Vector de Fases Solución PSO MonoObjetivo: [fMPerd], [fMI<sup>[0]</sup>], [fUft] y Solución FPSO GIST MultiObjetivo [fPE]  
 Fuente: Elaboración Propia

Valores del Esquema Base: Perd[kW] = 13.02   I <sup>[0]</sup> [A] = 47.6 μ(Uft) = 0 ncf = 0							
<b>χ-PSO MonoObjetivo</b>	Nro Partículas	Tiempo de Ejecución	Perd[kW]	I <sup>[0]</sup> [A]	μ(Uft)	ncf	
Min Perd	150	45 [min]	6.94	18.93	0.32	81	
Min  I <sup>[0]</sup>	150	37 [min]	10.16	0.1	0	79	
Max μ(Uft)	150	43 [min]	7.02	13.80	0.34	85	
<b>FSA MultiObjetivo</b>	Nro Partículas	Tiempo de Ejecución	Perd[kW]	I <sup>[0]</sup> [A]	μ(Uft)	ncf	
Max t <sub>Peinstein</sub>	250	1 [h] 37 [min]	8.64	3.9	0.57	80	
<b>FEPSO GIST MultiObjetivo</b>	Nro Partículas	Tiempo de Ejecución	Perd[kW]	I <sup>[0]</sup> [A]	μ(Uft)	ncf	
Max t <sub>Peinstein</sub>	200	47 [min]	7.210.40.27	59			
<b>Exponentes y Referencias para las Funciones de Pertenencia:</b> p(perd)=p( I <sup>[0]</sup>  )=p(ncf)=3; p(uft)=4;							
I <sub>Minperd</sub> =6.94. Refperd=13.02; I <sub>MinCH</sub> =0.1. RefCH=47.6; I <sub>RefNCf<sub>Min</sub></sub> =45. RefNCf <sub>Max</sub> =81							

**Cuadro 2:** Valores Base y Resultados de los χ-PSO, FEPSO GIST y FSA  
 Fuente: Elaboración Propia

## REFERENCIAS

- Arrillaga J., Arnold C., Harker B. (1991): "Computer Modelling of Electrical Power". John Wiley & Sons, pgs 90-123. ISBN 0-47-110406-X.
- Bellman, R.; Zadeh, L. (1970): "Decision-Making in a Fuzzy Environment". *Management Science*, 17, pgs. 141-164.
- Beni, G.; Wang, J. (1989). "Swarm Intelligence in Cellular Robotic Systems", in: *Proceedings NATO Advanced Workshop on Robots and Biological Systems*, June (26-30), Italy: Tuscany.
- Fortescue, C.L. (1918), "Method of Symmetrical Coordinates Applied to the Solution of Polyphase Networks", *Trans. AIEE*: pgs. 1027-1140.
- Grainger J., Stevenson W. (1996): "Power Systems Analysis". Mc. Graw Hill, U.S.A. ISBN 0-07-061293-5.
- Kennedy, J.; Eberhart, R.C. (1995): "Particle Swarm Optimization", *IEEE International Conference on Neural Networks*. Perth, Australia. IEEE Service Center, Piscataway, NJ.
- Kirkpatrick S., Gelatt C., and Vecchi M. (1995), "Optimization by Simulated Annealing", *Science*, Vol. 220, No. 4598, pp. 671-680.
- Metropolis N., Rosenbluth A., Teller A., and Teller E. (1953), "Equation of state calculation by fast Computing Machines", *Journal of Chemical Physics*, 21, pp. 1087-1092.
- Miranda V., Keko H., and Duque Jaramillo A. (2008), "EPSO: Evolutionary Particle Swarms. In *Advances in Evolutionary Computing for System Design*". Jain L., Palade V., Srinivasan D. Eds., Springer series in Computational Intelligence, vol. 66, pp. 139-168.
- Schweickardt G., Miranda V. (2010): "Metaheurística FEPSO aplicada a problemas de Optimización Combinatoria: Balance de Fases en Sistemas de Distribución Eléctrica". *Revista Ciencia, Docencia y Tecnología*, Universidad Nacional de Entre Ríos, Año XXI, nro. 40, p. 133-163.
- Zhu J., Griff B., Chow M. (1998): "Phase Balancing Using Mixed-Integer Programming". *IEEE Trans. Power Systems*, vol. 13, nro. 4.