

METAHEURÍSTICAS MULTIOBJETIVO CARDUMEN DE PECES ARTIFICIALES (FAFS) Y OPTIMIZACIÓN EVOLUCIONARIA POR ENJAMBRE DE PARTÍCULAS CON TOPOLOGÍA ESTOCÁSTICA GLOBAL INDIVIDUAL (FEPSO GIST). PARTE I: ANTECEDENTES Y DESARROLLOS TEÓRICOS

MULTIOBJECTIVE METAHEURISTICS ARTIFICIAL FISH SCHOOL (FAFS) AND EVOLUTIONARY PARTICLES SWARM OPTIMIZATION WITH GLOBAL INDIVIDUAL STOCHASTIC TOPOLOGY (FEPSO GIST). PART I: FRAMEWORK AND THEORETICAL DEVELOPMENTS

Gustavo Alejandro Schweickardt, PhD.

*Grupo de Investigación sobre Economía Computacional de Regulación de Redes y Energías Renovables
Universidad Tecnológica Nacional
Concepción del Uruguay, Argentina
gustavoschweickardt@conicet.gov.ar*

(Recibido el 20-05-2014. Aprobado el 20-06-2014)

Resumen. El presente trabajo describe un modelo para la optimización del grado de desbalance de cargas en una red trifásica de distribución de energía eléctrica (SDEE) en baja tensión (BT). Se presenta la integración de dos novedosas metaheurísticas: FEPSO GIST (*Fuzzy-MultiObjective Particles Swarm Optimization with Global/Individual Stochastic Topology*) desarrollada por el autor, y FAFS (*Fuzzy-MultiObjective Artificial Fish Shool*), cuya extensión multiobjetivo es propuesta por el autor, se valoriza la función de aptitud mediante conjuntos difusos. El problema propuesto ya ha sido resuelto en un trabajo presentado por el autor, mediante la metaheurística FPSO, y su solución constituye una referencia para comparar resultados. Entre los inconvenientes producidos por un elevado grado de desbalance en las fases del sistema, se consideran la minimización de las pérdidas técnicas y la mejora del perfil de tensiones. Ambos aspectos, relacionados con el uso racional de la energía propiciado desde el lado de la oferta, son observados por la autoridad regulatoria. Se presenta, adicionalmente, un modelo matheurístico que combina el enfoque clásico del problema, con el uso de programación lineal entera-mixta con las dos metaheurísticas introducidas, FEPSO GIST y FAFS. Se comparan los resultados de aplicar los modelos sobre el mismo SDEE BT considerado en el enfoque resuelto vía FPSO. En esta Parte I se abordan los antecedentes y desarrollos teóricos requeridos en la aplicación.

Palabras clave: Cardumen de peces artificiales; Desbalance de cargas; Enjambre de partículas; Metaheurísticas; Sistemas de distribución de energía eléctrica.

Abstract. This work presents a model to Low Voltage (LV) Unbalance Degree Optimization in a Three-phase Electric Distribution Network (EDN). The combination of two new Fuzzy-MultiObjective MetaHeuristics FEPSO GIST (*Fuzzy Particles Swarm Optimization with Global/Individual Stochastic Topology*) proposed by the author and, FAFS (*Fuzzy Artificial Fish Shool*) extended to MultiObjective domain by the author, using Fuzzy Sets, are presented. Of multiple problems resulting from such unbalance degree, are considered the technical losses and the voltage drops. Both aspects are fundamentals in the rational use of energy, when this objective is focused from the offer side, and are observed for Regulatory Authority. In addition, a MatHeuristic approach composed for the classical approach based in Mixed-Integer Linear Programming and FEPSO GIST-FAFS MetaHeuristics, is introduced. In this Part I of the work, the framework and theoretical developments, required for the Models application, are presented.

Keywords: Artificial Fish School, Electric Distribution Systems, MetaHeuristics, Particles Swarm, Load Unbalance.

1. INTRODUCCIÓN

El balance de fases en un sistema trifásico de distribución eléctrica en baja tensión, es un problema que exhibe una apariencia menor, razón por la cual, tal vez, no ha sido muy tratado de manera formal conforme se observa en el estado del arte. Más allá de esta apariencia, su importancia es fundamental, puesto que el mayor porcentaje de pérdidas de las redes de distribución se encuentran en los sistemas de baja tensión. Pueden referirse, al menos, dos razones por las que este problema no ha sido abordado formalmente y de manera adecuada: **a)** es de compleja solución (combinatorio) y **b)** en los últimos años, a partir de la reforma, las regulaciones eléctricas se han preocupado más por los aspectos de calidad y por el uso racional de la energía desde la perspectiva de la oferta. Históricamente han sido razones técnicas las que han impuesto límites a las pérdidas y perfiles de tensión, y no económicas (se hace referencia a un costo social de oportunidad), enfoque que se intenta establecer en la actualidad [1].

El presente trabajo intenta hallar una solución formal y superadora, respecto de las existentes, aun la obtenida desde la metaheurística propuesta en [1], para que se minimicen los efectos de un grado significativo de desbalance de fases, re-balanceándolas y con un criterio que contemple el menor número posible de cambios. Esta primera parte del trabajo presenta los antecedentes del problema y los desarrollos teóricos previos, requeridos para la implementación de las metaheurísticas FEPSO GIST, FAS, combinación de ambas y una matheurística que integra los algoritmos metaheurísticos con programación lineal entera-mixta (MIP). Los desarrollos se han ordenado como sigue: en la sección 2 se describe el problema referido en la literatura como balance de cargas o balance de fases, indistintamente. Se presentan los enfoques tradicionales para su solución, así como sus limitaciones cuando es tratado mediante instrumentos cuya complejidad no escapa de la programación matemática clásica. En la sección 3 se desarrollan las definiciones necesarias para comprender los conceptos de metaheurística y matheurística, insertas en el marco de la inteligencia computacional. En la sección 4 se desarrollan los principios de la denominada inteligencia de grupo (*Swarm Intelligence*), que sustentan los algoritmos bio-inspirados. Luego, se presentan, en tal contexto, la metaheurística PSO, y sus variantes hasta llegar a la EPSO, así

como la AFS. Por último, en la sección 5, se presentan algunas conclusiones que permitirán abonar los desarrollos específicos de las meta/matheurísticas usadas en la solución del problema planteado con una formulación multiobjetivo.

2. EL PROBLEMA DEL BALANCE DE CARGAS EN SISTEMAS DE DISTRIBUCIÓN EN BAJA TENSIÓN

2.1. Caracterización del problema

El sistema de distribución de energía eléctrica en baja tensión (SDEE BT) que se adoptará como referencia, sin pérdida de generalidad alguna, será empleado en las simulaciones presentadas en la segunda parte del artículo, y se corresponde con los parámetros eléctricos y de diseño vigentes en Argentina. El SDEE BT, parte de centros de transformación de media tensión a baja tensión (CT MT/BT), 13,2/0,38 (kV), 50 (hz), 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 sucesivamente), y se conforma una *red independiente cuya topología de operación es radial*. El sistema es *trifásico*, pero las cargas conectadas en los diferentes nodos de los alimentadores primarios o sus derivaciones, resultan, en su mayoría, *monofásicas*. Esto le confiere un carácter, si bien *simétrico* (dos *fasores* contiguos difieren en 120° eléctricos), *desbalanceado* (*módulos* distintos). Significa que el sistema de BT, *opera necesariamente con cierto grado de desbalance en sus tres fases*. En la Figura 1 se muestra un *sistema trifásico de corrientes (intensidades o cargas) simétrico balanceado* (referido como *perfecto*) y en la Figura 2 se observa un sistema *simétrico desbalanceado*.

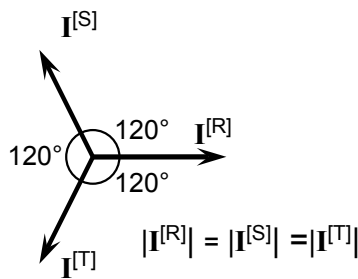


Figura 1. Sistema trifásico de intensidades simétrico y balanceado

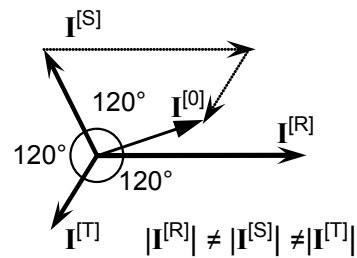


Figura 2. Sistema trifásico de intensidades simétrico y desbalanceado

Sin embargo, en la medida que tal desbalance exhiba un grado más pronunciado, se advierten, por lo 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, principalmente, en zonas carenciadas por el tipo constructivo de red que se usa (frecuentemente, conductores desnudos conocidos como convencionales); **b)** Disminuye la calidad del producto técnico tensión de suministro, controlada por la regulación. La tolerancia, regulatoriamente establecida, sobre la tensión de suministro para redes como las descritas en el ítem anterior, está entre un 5% (zonas urbanas, con alta densidad de carga) y un 7% (zonas rurales, con baja densidad de carga) 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, componente homopolar, $I^{[0]}$ (suma de las intensidades de las tres fases y que circulará por tierra), de un valor tal que puede accionar las protecciones contra cortocircuitos en el sistema MT, “aguas arriba”. Particularmente, por la falla monofásica/fase a tierra (la más frecuente: un 80% de las fallas son de este tipo). En la Figura 1 se observa que la suma fasorial de las intensidades es nula, mientras que en la Figura 2 no lo es. El sistema pierde confiabilidad por cuanto las protecciones interpretan los fuertes desbalances como una señal de cortocircuito y se interrumpe el servicio. Esto, como se dijo, adquiere mayor relevancia en el subsistema de MT, pues 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. Por ello se requiere especial cuidado con su ajuste. El problema de optimización en el grado de desbalance de fases, se define como la búsqueda de aquella configuración de conexiones de las cargas a las fases [R, S, T] en el sistema, tal que propenda por 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 tres fases tomadas de n cargas. El espacio de búsqueda tendrá, entonces, $NE = 3^{n_C}$ estados. Para el sistema cuyo esquema trifilar se presenta en las simulaciones de la segunda parte del presente trabajo, con $n_C = 115$ cargas, se tiene un espacio de búsqueda (o de soluciones) de $NE = 3^{115}$ estados.

2.2. Primeros intentos de solución mediante búsqueda iterativa (BI). Modelo “prueba y error”

Los primeros intentos de solución para el *balance de fases*, responden, en su versión más sofisticada, al esquema presentado en la Figura 3. Este método es aplicado actualmente en una versión más simple que sustituye las *heurísticas*, y su compleja implementación desde el punto de vista informático, por *configuraciones de fases aleatoriamente generadas* [1].

Se itera, en este caso, un cierto número de veces para retener el mejor indicador de balance (IB). Dada la enorme cantidad de estados del espacio de búsqueda, como se explicó en el epígrafe anterior, en un sistema relevante, con un gran número de cargas. Este método constituye un pobre sondeo.

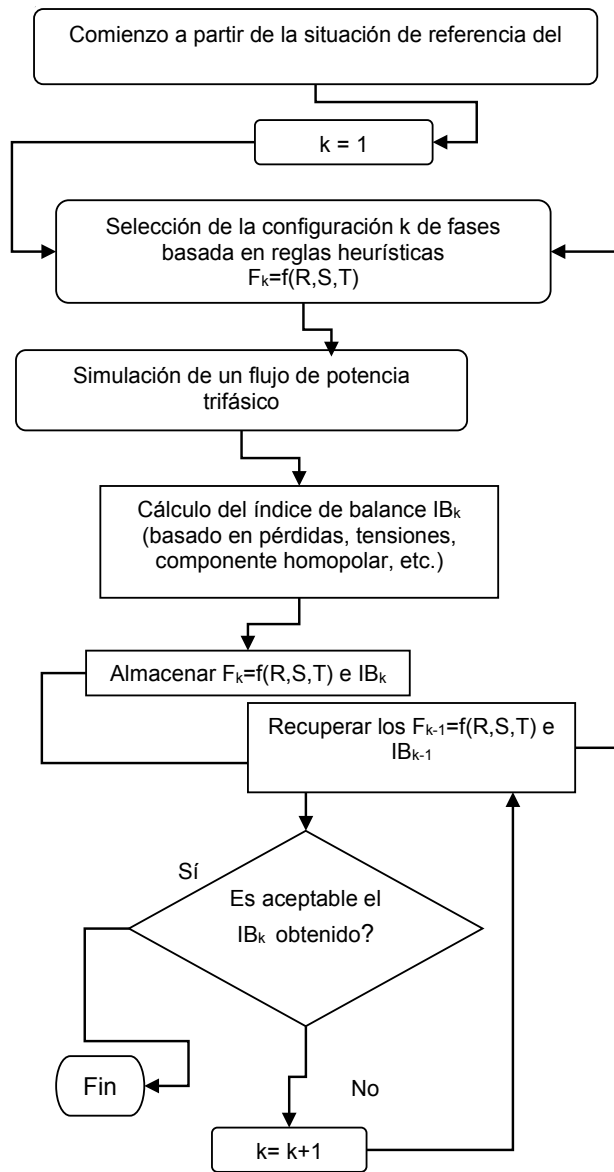


Figura 3. Esquema de solución del balance de fases por búsqueda iterativa.

Los pasos y simbología utilizados en el diagrama de la Figura 3, se explican en el mismo esquema secuencial.

2.3. El problema de desbalance de fases abordado mediante programación lineal entera-mixta (MIP).

Con un enfoque propiciado por técnicas de optimización clásicas, el modelo MIP fue presentado en [2]. Considérese un alimentador único, Pr, que tiene cierta conexión de cargas en nodos cuya distancia

a la salida de Pr, se encuentra definida. Se trata de encontrar la asignación óptima de las cargas para cada fase del sistema [R, S, T], tal que las intensidades, tomadas de a pares, esto es: [R, T], [S, T] y [R, S] exhiban una diferencia de módulos en cada rama (distancia entre dos nodos contiguos) que resulte mínima. Formalmente:

$$\text{Min} \{ \sum_j p_j \times U_j \}$$

Sujeto a:

$$U_j = \text{Max} \{ |I_j^{[R]} - I_j^{[T]}|; |I_j^{[S]} - I_j^{[T]}|; |I_j^{[R]} - I_j^{[S]}| \} \quad (1)$$

$$I_j^{[\Phi]} = \sum_k I_k^{[\Phi]} + \sum_w \delta_i^{[\Phi]} \times I_i^{[\Phi]_w} \quad (2)$$

$$\sum_w \delta_i^{[\Phi]_w} = 1; \forall [\Phi] \in \{R, S, T\} \quad (3)$$

$$\sum_w \delta_i^{[\Phi]_w} = 1; \forall [w] \in [1..nC] \quad (4)$$

$$|I_j^{[\Phi]}| \leq C_j \quad (5)$$

$$\delta_i^{[\Phi]_w} \in \{0, 1\} \forall [i, \Phi] \quad (6)$$

$$\sum_j p_j = 1; \forall [j] \in [1..nR] \quad (7)$$

donde: j es la rama genérica; U_j es el desbalance de intensidades en la rama j; I_j^[Φ] es la intensidad sobre la rama j en la fase Φ; δ_i^{[Φ]_w} es la variable de decisión para la conexión de la carga w-ésima en el nodo i-ésimo, a la fase Φ, I_i^[Φ]; i es el nodo "aguas abajo" o terminal de la rama j; C_j es la capacidad de la línea en la rama j, por fase; nC es el número de cargas y nR es el número de ramas.

En esta formulación MIP, la igualdad (2) no es otra cosa que la Ley de Kirchhoff de las intensidades aplicada al nodo i (la suma fasorial de las intensidades en dicho nodo debe ser nula); las restricciones (3), (4) y (6) aseguran que una carga se asigne sólo a una fase; la restricción (5) asegura que no se vulnere los límites operacionales del alimentador (intensidad máxima); la condición (7) es necesaria puesto que las ramas deben tratarse de un modo independiente y fijar pesos al balance logrado en cada una de ellas. Se trata de una típica modelación lineal entera-mixta, que puede ser resuelta mediante un algoritmo de ramificación y acotamiento, incluido en cualquier paquete de software educacional o comercial. Sin embargo, hay que destacar algunas severas limitaciones en este enfoque: 1ro) La más importante: supone una característica de las cargas denominada de corriente constante. Esto significa que, independientemente de los cambios que se puedan producir en la tensión de nodo, la carga ajustará su impedancia para demandar siempre la misma intensidad. Esta es una simplificación que exime de em-

plear, por cada cambio de configuración (conexión a fases), un flujo de potencia trifásico para determinar el estado resultante del sistema analizado. De este modo se hace posible la linealización del problema ya que las intensidades (fasores), permanecen constantes. En sistemas reales, en los que predomina un consumo tipo residencial, esta característica de carga es improbable de sostener (mucho menos aún para todas las cargas/usuarios del sistema); **2do)** Se propone un índice de balance que intenta resolver, estrictamente, el ítem c) referido en el epígrafe **2.1**. Los autores infieren en su propuesta que tal solución propendería por la mejora de los dos primeros ítems, a) minimización de pérdidas y b) menores caídas de tensión. Esta aseveración, si bien en algún intervalo de solución es correcta, no siempre resulta válida, más cuando se habla de “óptimo” y en sistemas con un grado de desbalance muy elevado. En los resultados de la simulación que se presenta en la segunda parte del presente trabajo, puede ser observado este hecho; **3ro)** En un sistema (80-100 cargas), la modelación específica resulta de bastante a muy engorrosa de realizar. Más aún, si se aplicara a múltiples CT MT/BT, por cada salida se tendría una formulación distinta, motivo por el cual la optimización para un sistema de BT, puede tornarse impracticable; **4to)** Los ponderadores de la expresión (7) son subjetivos, de modo que el modelo resulta, en realidad, una de las formas más simples de la PL multiobjetivo y se presenta, muy discutible, “una” solución óptima; y **5to)** Se destaca, como en tantos otros casos de aplicación en el campo de los sistemas de potencia, que forzar la linealización de ecuaciones que resumen leyes de comportamiento claramente no lineales, por más que los métodos clásicos de optimización presenten elegantes soluciones, las mismas resultan de escasa o nula aplicabilidad práctica. Diferente es, en problemas del tipo combinatorio, fundamentalmente, generar modelos híbridos que combinan metaheurísticas con métodos clásicos (tal como la programación lineal o la dinámica), situación para la cual pueden obtenerse excelentes resultados.

Este modelo MIP fue implementado por el autor del presente trabajo sólo para el alimentador principal, Pr, considerado en la red BT presentada para las simulaciones realizadas en la segunda parte del presente trabajo. Se usó una versión educacional del software Lindo 6. Para el mismo caso, se implementó, además, y con fines comparativos, un algoritmo de búsqueda iterativa (BI). El BI, con 1000 iteraciones (25 min. de cálculo, aproximadamente, en un procesador de última generación, estándar en

el mercado), *generó mejores resultados que el MIP, no se logró obtener, para este último, un conjunto convexo de ponderadores (7) que mejorara la solución iterativa.* En el BI, se modelaron las cargas a *potencia constante* y se requirió del *flujo de potencia trifásico*, descrito en la segunda parte del presente trabajo. Se generaron *aleatoriamente* los *vectores de conexión* de las cargas a las fases [R, S, T] en cada iteración. El *desbalance total* se obtuvo como la *sumatoria de los desbalances en cada rama.*

3. DEFINICIONES RELACIONADAS CON LAS ESTRATEGIAS BIO-INSPIRADAS DE OPTIMIZACIÓN

3.1. Métodos heurísticos

La etimología del término *heurística*, proviene de la palabra griega *heuriskein* que se traduce como *encontrar*. En el contexto del presente trabajo, es necesaria una definición, en tanto *Método heurístico*. Más allá de las múltiples interpretaciones y de la vastísima bibliografía al respecto, se propone aquí la idea de *Método heurístico* sugerida en [3]:

Un Método heurístico constituye un procedimiento para resolver un problema de optimización bien definido, mediante una aproximación intuitiva, en la que la estructura del problema se utiliza de forma inteligente para obtener una buena solución. Desde la definición propuesta, el método está dirigido a un problema específico, del cual se conocen sus características (bien definido), con el propósito de sacar provecho de ellas en la estrategia de búsqueda concebida. La pregunta que cabe hacerse es: ¿cómo aprovechar las similitudes que ciertos problemas, fundamentalmente de carácter combinatorio, exhiben, cuando un método heurístico ha generado muy buenos resultados? Esta es la idea que subyace en el concepto de *metaheurística*.

3.2. Métodos metaheurísticos

El término *metaheurística* deriva del complemento entre la palabra *heuriskein* y el prefijo *meta*, el cual se traduce como *más allá de* o *en un nivel superior de/a*. Fue introducido por primera vez por Fred Glover, al presentar el método (metaheurístico) denominado Tabu Search (Búsqueda Tabú) [4]. Sin embargo, existe una controversia respecto de si una metaheurística es diferente de una *heurística*, y va-

rias fuentes pueden ser citadas en tal sentido. Según [5]: **a)** Una metaheurística define un marco de referencia algorítmico cuyo enfoque puede ser especializado para resolver problemas de optimización; **b)** Una metaheurística constituye una estrategia de alto nivel que guía/conduce heurísticas en la búsqueda de soluciones factibles. Si se toma en consideración **a)**, se tiene un método heurístico, entendido como un marco de referencia algorítmico. En cambio, según **b)**, se observa una respuesta a la pregunta referida. Siguiendo esta línea, se adoptará la definición [6]:

Una metaheurística se define como un proceso iterativo que guía una heurística subordinada, combinando diferentes conceptos para explorar y explotar las características que pueda exhibir el espacio de búsqueda.

Frecuentemente, al considerar la referencia al término *proceso iterativo*, se suele hablar de *Algoritmo metaheurístico*. En el presente trabajo se utilizan de manera indistinta los términos *metaheurística* y *algoritmo metaheurístico*.

3.3. Principios de la inteligencia de grupo (Swarm Intelligence)

La inteligencia de grupo, IG, (o *Swarm Intelligence*) refiere un *tipo de inteligencia artificial*, basado en el comportamiento de *sistemas colectivos, auto-organizados*. La expresión fue introducida en 1989 por Gerardo Beni [7].

El término *Swarm* describió, a su entender, el comportamiento de los autómatas celulares, que exhiben características similares a las que se observan en ciertos sistemas biológicos, tales como los *insectos*. De esas características mencionó: la *descentralización, no-sincronización* y *simplicidad en los movimientos* de los miembros del grupo. Además, este término tiene una significación que lo trasciende: permite analizar el comportamiento social de grupos de individuos (peces, insectos, pájaros, etc.), e identificar el tipo de configuración en sus sistemas de cooperación y auto-adaptación, con el fin de hallar la manera óptima de alcanzar un objetivo. La *comunicación*, según los biólogos, constituye el parámetro *clave* en este proceso [8], de modo que a las cualidades mencionadas debe incorporársele la *cooperación* entre los individuos del *swarm*. Desde tales consideraciones pueden establecerse *cinco principios* que caracterizan la IG (*Swarm Intelligence Principles*).

Estos *principios*, y su breve enunciación, resultan: **IG1) Proximidad**: Promueve la habilidad que debe exhibir el grupo para ejecutar cálculos simples de espacio y tiempo en sus movimientos hacia el objetivo pretendido; **IG2) 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; **IG3) Diversidad de respuesta**: Promueve la posibilidad de que los individuos tengan respuestas diferentes ante los mismos estímulos; **IG4) Estabilidad**: Promueve la habilidad de que el grupo permanezca estable, en ausencia de estímulos que induzcan mejoras en las soluciones alcanzadas; y **IG5) 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.

Los principios de inteligencia de grupo tienen una incidencia fundamental en la definición de los algoritmos bio-inspirados, como lo son las metaheurísticas empleadas en este trabajo: las que están basadas en enjambre de partículas o formas X-PSO, clasificación propuesta por el autor en trabajos previos [1], o bien en la metaheurística AFS [9].

En la segunda parte del presente trabajo, conjuntamente con la medida en que tales principios IG son satisfechos por extender tales algoritmos metaheurísticos al dominio de aplicación multiobjetivo, serán introducidos otros dos requisitos adicionales para el éxito en el procedimiento de búsqueda más de la “solución más satisfactoria”, en lugar del “óptimo”, por las razones que se explicarán: La *pareto-dominancia* en el conjunto de *buenas soluciones*, y la *compatibilidad métrica* de las reglas de búsqueda conforme resulte el espacio de soluciones del problema que se ha de resolver.

4. METAHEURÍSTICAS DE LA FORMA X-PSO Y FSA

4.1. Forma X1: Formulación canónica de la metaheurística PSO

La optimización por enjambre de partículas (*Particle Swarm Optimization - PSO*), constituye un algoritmo metaheurístico presentado en [8]. Se inspira en el

movimiento colectivo de cardúmenes de peces, bandadas de pájaros o enjambres de abejas, que los autores refieren como *movimiento de partículas*.

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*: 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*:

$$X^{[k+1]}_i = X^{[k]}_i + V^{[k+1]}_i \times \Delta t \quad (8)$$

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

$$X^{[k+1]}_i = X^{[k]}_i + V^{[k+1]}_i \quad (9)$$

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

$$V^{[k+1]}_i = V^{[k]}_i + w_C \times (r_1^{[k]}) \times [b^{[k]}_i - X^{[k]}_i] + w_S \times (r_2^{[k]}) \times [b^{[k]}_G - X^{[k]}_i] \quad (10)$$

El primer término de la suma (10), representa la *inerencia* 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) , que 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 .

4.2. Forma X2: Formulación de la metaheurística PSO con función de decaimiento inercial

En esta forma, el *operador velocidad canónico*, dado por la expresión (10), 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 (10) es modificada y sustituye el primer término por el producto entre una nueva constante, w_I , denominada *constante de inercia* y tal función $\delta(k)$:

$$V^{[k+1]}_i = \delta(k) \times w_I \times V^{[k]}_i + w_C \times (r_1^{[k]}) \times [b^{[k]}_i - X^{[k]}_i] + w_S \times (r_2^{[k]}) \times [b^{[k]}_G - X^{[k]}_i] \quad (11)$$

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

$$\delta(k) = w_{Max} - k \times (w_{Max} - w_{Min}) / nTK \quad (12)$$

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 y 0,9, respectivamente. La función de decaimiento inercial requiere de cuidado, puesto que resulta intuitivo el hecho de que si el término de inercia resultara eliminado en iteraciones tempranas del algoritmo, el procedimiento corre el riesgo de quedar atrapado en una solución óptimo local (o subóptima).

4.3. Forma X3: Formulación de la metaheurística PSO con factor de constricción

En este caso, el *operador velocidad canónico* se modifica como sigue:

$$\mathbf{V}^{[k+1]}_i = \chi \times \{ \mathbf{V}^{[k]}_i + \varphi_M \times (r_1^{[k]}) \times [\mathbf{b}^{[k]}_i - \mathbf{X}^{[k]}_i] + \varphi_C \times (r_2^{[k]}) \times [\mathbf{b}^{[k]}_G - \mathbf{X}^{[k]}_i] \} \quad (13)$$

Donde χ se denomina factor de constricción y se obtiene desde la siguiente expresión condicionada:

$$\chi = 2 \times \kappa / \left| 2 - \varphi - \sqrt{\varphi^2 - 4 \times \kappa} \right| \quad (14)$$

con:

$$\varphi_M + \varphi_C = \varphi; \varphi > 4 \text{ y } 0 < \kappa \leq 1 \quad (15)$$

4.4. Forma X4: Formulación de la metaheurística PSO evolucionaria (EPSO)

La X-PSO EPSO (*Evolutionary Particle Swarm Optimization*), combina la *programación evolucionaria* mediante *operadores evolutivos* similares a los establecidos para los algoritmos genéticos (particularmente: *mutación, selección, combinación*) con el movimiento PSO, que se aplican sobre sus parámetros y óptimo global en la instancia de iteración k-ésima. La *ecuación evolutiva para la regla del movimiento* en el EPSO, se sintetiza en la *velocidad de la partícula i-ésima* (alteración del *operador canónico velocidad*):

$$\mathbf{V}^{[k+1]}_i = w_{i1}^{*[k]} \times (r_1^{[k]}) \times \mathbf{V}^{[k]}_i + w_{iC}^{*[k]} \times (r_2^{[k]}) \times [\mathbf{b}^{[k]}_i - \mathbf{X}^{[k]}_i] + w_{iS}^{*[k]} \times (r_3^{[k]}) \times [\mathbf{b}^{[k]*}_G - \mathbf{X}^{[k]}_i] \quad (16)$$

Donde: el superíndice (*), significa que los parámetros son *evolutivos*, producto de la *mutación*. La *regla de mutación* aplicable a las constantes $w_{i1, C, S}$ tiene, como expresión general:

$$w_{i1, C, S}^{*[k+1]} = w_{i1, C, S}^{[k]} \times [1 + \sigma \times N(0,1)] \quad (17)$$

Donde: σ 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:

$$\mathbf{b}^{[k+1]*}_G = \mathbf{b}^{[k]*}_G + w_{iN}^{*[k]} \times N(0,1) \quad (18)$$

Donde $w_{iN}^{*[k]}$, es un parámetro estratégico de la regla de movimiento, que controla la amplitud del vecindario de $\mathbf{b}^{[k]*}_G$ donde es más probable localizar la mejor solución global (entendida, al menos, como una *solu-*

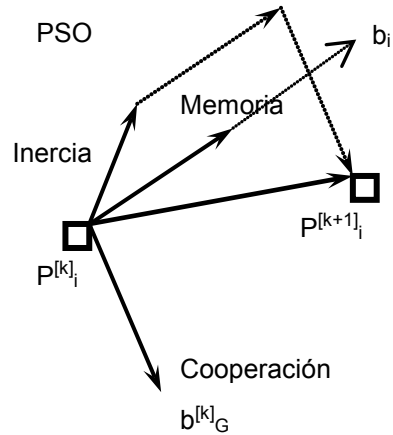


Figura 4. Ecuación de movimiento de una partícula PSO canónico.

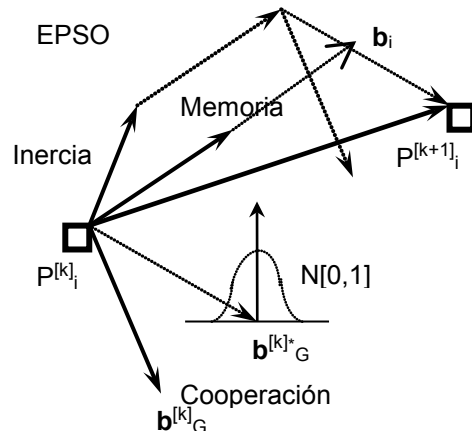


Figura 5. Ecuación evolutiva de movimiento de una partícula EPSO.

ción mejor que la $\mathbf{b}^{[k]*}_G$ actual, para la iteración k). El nuevo parámetro, como se indica con el superíndice (*), es también mutado según la regla (18).

En la Figura 4, se representa la composición vectorial correspondiente a la ecuación del movimiento correspondiente al algoritmo PSO canónico (o PSO) en dos dimensiones. En la Figura 5, se representa, idénticamente, la ecuación evolutiva del movimiento correspondiente al algoritmo EPSO. Nótese, más allá de la composición de los tres términos de velocidad referidos para establecer la dirección en la que debe moverse una partícula i-ésima, desde la iteración k a la k+1, $P^{[k]}_i$, cómo cambia la dirección del *óptimo global mutado*, $\mathbf{b}^{[k]*}_G$, y, por tanto, la dirección de movimiento de la partícula EPSO en la iteración k+1.

4.5. Metaheurística AFS (Artificial Fish School)

Este algoritmo metaheurístico, referido en el estado del arte como *Artificial Fish Shool Algoritm* (AFSA) (Algoritmo de cardumen de peces artificiales), ha recibido, recientemente, gran atención por parte de la comunidad científica en el campo de la inteligencia computacional. Fue propuesto por Xiaolei Li en [9]. Se sustenta en dos tareas básicas: *primero*, construye un modelo simple de peces artificiales (AF) y *segundo*, implementa una estrategia de búsqueda del óptimo global, basada en el comportamiento que caracteriza la búsqueda de alimento de los individuos (AF) del grupo o cardumen.

El algoritmo intenta imitar el siguiente proceso bio-inspirado: en el agua, considerada como hábitat natural, cualquier pez puede localizar alimento siguiendo a otro pez, pues donde hay más concentración de alimento hay mayor cantidad de peces. Para emular este proceso se establecieron *comportamientos* que identifican al cardumen de peces artificiales, y se definieron algunas *variables* y *parámetros*. Se tipifican cinco *comportamientos* en el cardumen:

1) De ataque (Prey): El pez percibe la concentración de alimento en el agua, y escoge, por medio de su visión, como sentido general de percepción, el movimiento a seguir o tendencia; 2) Grupal (Swarm): De forma natural, en el movimiento del cardumen, cada pez integra este grupo, como un hábitat en el que supervive y es garantizada una mayor seguridad de no ser presa de otro pez, en general; 3) De seguimiento (Follow): En el movimiento del grupo de peces, cuando un pez individualmente, o un grupo de ellos, detecta alimento, la vecindad (sub-grupo próximo de peces) de los mismos, se alineará y seguirá su movimiento con el objeto de alcanzar rápidamente el alimento; 4) Registro (Bulletin Update): Este constituye un comportamiento bio-inspirado, asociado con el algoritmo. Se asemeja a la memoria autobiográfica que exhiben las partículas del PSO. La posición o estado de un pez artificial que ha alcanzado la máxima concentración de alimento, individualmente, es registrado en un boletín. Luego de cada acción o movimiento (iteración), el nuevo estado de cada pez artificial se compara con su registro en el boletín, el cual, si dicho estado tiene mayor mérito que el registrado, se actualiza por reemplazo; y 5) Evaluación del movimiento (Moving Evaluation): Los comportamientos Grupal y de Seguimiento tendrán lugar en el cardumen (es decir: sus respectivos procedimientos serán ejecutados en el algoritmo) *cuando exhiban*

Los resultados se presentan en la Tabla 1.

Tabla 1. metaheurísticas y su habilidad para satisfacer los principios de la inteligencia de grupo en espacios de búsqueda discretos y con buenas soluciones aisladas

MetaH	IG1	IG2	IG3	IG4	IG5
PSO	M	M	M	R	R
PSO D	B	R	M	R	R
PSO ÷	B	R	R	B	R
EPSO	B	B	R	B	B
AFS	B	M	M	B	M

pertinencia, efecto que será observable en el algoritmo, al describir sus respectivos procedimientos. En tal caso, el comportamiento del cardumen seleccionado entre ambos, será aquel que conduzca a la mayor *consistencia alimenticia (food consistence)*, representada por la posición de mayor aptitud. En caso contrario, no existe tal *pertinencia*, el comportamiento que tiene lugar (*pertinente*) es el De ataque.

El desarrollo del algoritmo, al igual que la X-PSO forma EPSO GIST y sus extensiones al dominio multiobjetivo, se presentarán en la segunda parte del presente trabajo, por integrar una estrategia de solución para el problema abordado de balance de cargas.

Cabe destacar que el espacio de búsqueda para esta clase de problemas de optimización en los sistemas de potencia, en los que cada objetivo que caracteriza al problema abordado es tratado en forma individual, y resuelto mediante las metaheurísticas presentadas (X-PSO formas y AFS), exhibe una característica singular. La misma estriba en presentar, en un campo discreto, pocas y buenas soluciones aisladas. Desde varias simulaciones realizadas por el autor, puede establecerse la relación entre la aplicación de cada metaheurística formulada, y su habilidad para satisfacer cada principio de la inteligencia de grupo (B = Buena, R = Regular y M = Mala).

5. TRABAJOS FUTUROS

Se definirán en la segunda parte del presente trabajo.

6. CONCLUSIONES

En esta primera parte del trabajo, se han realizado los despliegues teóricos y conceptos solidarios a las metaheurísticas monobjetivo tipo X-PSO y AFS y se incluye su habilidad para satisfacer los cinco principios IG, conforme la caracterización del espacio de soluciones que exhibe el problema de balance de cargas en un SDEE BT. Sobre el mismo, se han presentado dos enfoques de solución: BI y MIP, con sus limitaciones. Se justifica un enfoque alternativo, matheurístico, cuya aplicación, con la integración de tales metaheurísticas, planteadas multiobjetivo, con el enfoque MIP, se aborda en la segunda parte.

REFERENCIAS

- [1] G. Schweickardt & V. Miranda. "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*. Nro. 40, pp. 133-163. 2010.
- [2] J. Zhu, B. Griff & M. Chow. "Phase Balancing Using Mixed-Integer Programming". *IEEE Trans. Power Systems*. Vol. 13, nro. 4. 1998.
- [3] A. Díaz, F. Glover, H. Ghaziri & J. González. "Optimización Heurística y Redes Neuronales". Paraninfo. Madrid, España. 1996.
- [4] F. Glover. "Tabu Search: Part I". *In: ORSA Journal on Computing*. Vol. 1, pp. 190-206. 1989.
- [5] P. Black. "Dictionay Of Algorithms and Data Structures". National Institute of Standars and Technology. Available in: <http://www.nist.gov/index.html>. 2009.
- [6] I. Osman & J. Kelly. "Meta-Heuristics: Theory and Applications". Ed. Kluwer Academic. Boston, USA. 1996
- [7] G. Beni & J. Wang. "Swarm Intelligence in Cellular Robotic Systems". *Proccedings NATO Advanced Workshop on Robots and Biological Systems*. June, Tuscany, Italy. 1989.
- [8] J. Kennedy & R. Eberhart. "Particle Swarm Optimization". *IEEE International Conference on Neural Networks*. IEEE Service Center, Piscataway, NJ. Pert , Australia. 1995.
- [9] X. LI, Z. Shao & J. Qian. "An Optimizing Method Based on Autonomous Animats: Fish-Swarm Algorithm (in Chinese)". *Systems Engineering Theory and Practice*. Vol. 22(11), pp. 32-38. 2002.