

Análisis cuantitativo de las habilidades de Metaheurísticas X-PSO Multiobjetivo mediante Indicadores de Inteligencia de Grupo

Aplicación en el Balance de Cargas en Redes Eléctricas de Baja Tensión

Carlos Casanova
casanovac@frcu.utn.edu.ar

Gustavo Schweickardt
schweickardt@frcu.utn.edu.ar

CONICET – Universidad Tecnológica Nacional
Facultad Regional Concepción del Uruguay
Ing. Pereira 676 – 3260
Concepción del Uruguay – Argentina

Abstract

This paper presents a quantitative behaviour analysis of metaheuristics, referred as Multiobjective X-PSO Forms (X-FPSO), making use of the Swarm Intelligence concept (SI). Through many papers in this investigation line, the authors establish a qualitative correspondence between the ability of X-FPSO Forms to suit the five SI Principles (SIP), and the aptitude of Hyperheuristic's Selection Function when such X-FPSO Forms compose its domain. Quantitative Swarm Intelligence Indicators are proposed for allowing behavior characterization and differentiation of different movement strategies, derived from the original FPSO: the FPSO with constriction factor and Global Deterministic Star Topology, the FPSO with constriction factor and VonNeumann Topology, the FEPSO with Global Deterministic Star Topology, and the FEPSO GISiT (Global Individual Stochastic Star Topology). These indicators reflect key aspects related to the Swarm Intelligence, allowing iteration to iteration tracking of the Hyperheuristic Algorithm, serving as a guide for its Selection Function. A simulation is presented in the context of solving a combinatorial optimization problem, considered in previous works as a case study: the load balancing in a Three-phase Electric Distribution System.

Key Words: Swarm Intelligence – Metaheuristics – Optimization – Particle Swarm.

Resumen

Este trabajo presenta un análisis cuantitativo del comportamiento de MetaHeurísticas referidas como X-PSO Formas MultiObjetivo (X-FPSO), recurriendo al concepto de Inteligencia de Grupo (IG). A través de varios trabajos en esta línea de investigación, los autores

han establecido cualitativamente que existe una correspondencia entre la habilidad de las Formas X-FPSO para satisfacer los cinco Principios de la IG (PIG), y la aptitud de la Función de Selección de una HiperHeurística cuando las Formas X-FPSO componen su dominio. Se proponen Indicadores de IG cuantitativos que permiten caracterizar y diferenciar el comportamiento de estrategias de movimiento derivadas de la MetaHeurística FPSO original: la FPSO con Factor de Constricción y Topología de Comunicación entre partículas Estrella Global Determinística (FPSO FC DS), la FPSO con Factor de Constricción y Topología de Comunicación Von Neumann (FPSO FC VN), la FEPSO con Topología de Comunicación Estrella Global Determinística (FPSO DS) y la FEPSO GISiT (Topología de Comunicación Global/Individual Estocástica). Estos indicadores reflejan aspectos clave relacionados con la IG, permitiendo realizar un seguimiento iteración a iteración del Algoritmo HiperHeurístico, sirviendo de guía para su Función de Selección. Se presenta una simulación en el contexto de la resolución de un problema de Optimización Combinatoria, considerado en trabajos previos como estudio de caso: el Balance de Cargas en un Sistema Trifásico de Distribución de Energía Eléctrica.

Palabras Clave: Inteligencia de Grupo – Metaheurísticas – Optimización – Enjambre de Partículas.

1. Introducción

1.1 Habilidades de las Formas X-FPSO para satisfacer los Principios de la Inteligencia de Grupo. Función de Selección HiperHeurística con Dominio X-FPSO

El objetivo central del presente trabajo, consiste en validar cuantitativamente, mediante la propuesta de cinco Indicadores solidarios a cada Principio de la Inteligencia de Grupo (PIG), una hipótesis que ha sido observada y utilizada cualitativamente por los autores, en trabajos previos [12-13]. En ellos, se desarrolló un Modelo HiperHeurístico Basado en Razonamiento o CBR (Case Based Reasoning), cuya Función de Selección (FS) se implementó mediante una Red Neuronal tipo Retropropagación Simple (RNR), con dominio en Formas X-FPSO. Se explica que la Clase de Problemas que puede resolver la HiperHeurística desarrollada, queda definida mediante las características del Espacio de Búsqueda o Espacio de Soluciones donde operan, conforme determine la Función de Selección, cada una de las Formas X-FPSO, en cierta instancia de decisión o conjunto de iteraciones del Algoritmo HiperHeurístico. Se observan dos características:

a) Supone problemas de Optimización Combinatoria, dado el número de estados posibles que deben ser considerados.

b) La búsqueda de soluciones más satisfactorias no puede seguir reglas de mejoras sustentadas en una Función Gradiente. Esto significa que las mejores soluciones para la Clase de Problemas a tratar, se encuentran aisladas, de modo que no existen cambios pequeños en alguna dirección que puedan guiar a cierta MetaHeurística hacia una mejora segura en la solución.

Estas son precisamente las características que exhiben los Problemas de Economía Computacional de Redes de Distribución Eléctrica, tal como el Balance de Fases en un Sistema Trifásico de Baja Tensión, en el cual se procura resolver, en última instancia, un conexionado de las cargas que propenda a satisfacer los requerimientos impuestos regulatoriamente sobre la calidad de servicio y de producto técnico.

En las dos referencias citadas, así como también en [14] se demuestra que una estrategia HiperHeurística, seleccionando la MetaHeurística más apta en cierta instancia de decisión (a través de la FS) del dominio compuesto por Formas X-FPSO, genera una mejor solución para este problema (por mejor debe entenderse mejor calidad/aptitud o, ante una misma aptitud, menor tiempo de cómputo) que la obtenida empleando la mejor Forma X-FPSO. Para ello, se parte de la hipótesis arriba referida y validada cualitativamente a través de los resultados obtenidos: cada X-FPSO forma exhibe, en general, habilidades diferentes para satisfacer los cinco Principios de Inteligencia de Grupo.

Se pretende, entonces, en los desarrollos siguientes, tomar de las Formas X-FPSO, y sin por ello perder generalidad para el resto, las dos consideradas más representativas por sus habilidades complementarias para satisfacer los Principios IG: la MetaHeurística FPSO con Factor de Constricción y Topología de Comunicación

entre partículas Estrella Global Determinística y la FEPSO GIStT (Global Individual Stochastic Topology) con Topología de Comunicación Global/Individual Estocástica, ambas desarrolladas por los autores. Luego, proponer cinco Indicadores IG que permitan validar cuantitativamente las habilidades identificadas sobre cada una para satisfacer los Principios IG. En la medida que la Estrategia de Solución empleada pueda ser capaz de satisfacer, del mejor modo posible, tales Principios, mejor será la calidad de la solución obtenida. Y en la medida que se disponga de Indicadores Cuantitativos, aplicables a cualquier Forma X-FPSO dominio de una HiperHeurística, mayor información se tendrá para definir una Función de Selección que conduzca a soluciones de calidad. En estas consideraciones estriba la importancia de los aportes aquí presentados.

El trabajo está organizado como sigue: En la Sección I, introductoria, además del contexto proporcionado en este epígrafe, 1.1, se define en el epígrafe siguiente, 1.2, el Problema del Balance de Fases. En la Sección II, se presenta una síntesis de las estrategias correspondiente a la MetaHeurística PSO MonoObjetivo (o PSO Canónica), epígrafe 2.1, el concepto de Topología de Comunicación entre partículas, epígrafe 2.2, y las Formas X-PSO (también MonoObjetivo) concebidas como estrategias alternativas: PSO con Factor de Constricción y Topología de Comunicación entre partículas Estrella Global Determinística, epígrafe 2.3, PSO con Factor de Constricción y Topología de Comunicación entre partículas de VonNeumann, epígrafe 2.4, EPSO con Topología de Comunicación entre partículas Estrella Global Determinística, epígrafe 2.5, y EPSO GIStT con Topología de Comunicación Global/Individual Estocástica, epígrafe 2.6. La EPSO es introducida en esta descripción, porque la EPSO GIStT es una variante de la misma, con una Topología de Comunicación diferente. En el epígrafe 2.7, se describe sintéticamente contando con el apoyo de trabajos previos de los autores, como son extendidas las Formas X-PSO MonoObjetivo al dominio MultiObjetivo. Al emplear Conjuntos Difusos con este fin, surgen las Formas X-FPSO (MultiObjetivo), donde la letra "F" hace referencia al empleo de tales conjuntos (Fuzzy Sets).

En la SECCIÓN 3, se describen los Principios de Inteligencia de Grupo, epígrafe 3.1, y luego son introducidos los Indicadores IG propuestos, solidarios a cada principio, en el epígrafe 3.2. En la SECCIÓN 4, se realiza el análisis para las Formas X-FPSO referidas: la FPSO FC con Topología Estrella Global Determinística, epígrafe 4.1, la FPSO FC con Topología VonNeumann, epígrafe 4.2, la FEPSO DS, epígrafe 4.3 y la FEPSO GIStT, epígrafe 4.4, presentando los resultados correspondientes para cada una de ellas. La Sección 5 presenta las conclusiones más relevantes. Finalmente, en

las SECCIÓN 6, se presentan las referencias bibliográficas consultadas.

1.2 El Problema de Balance de Fases

El Problema del Balance de Fases o de Cargas en un Sistema de Distribución de Energía Eléctrica en Baja Tensión (SDEE BT) desde un planteo MultiObjetivo, no tiene solución realista aplicando técnicas derivadas de la Optimización Clásica [11]. 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.

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); **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). 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 nC cargas. El espacio de búsqueda tendrá, entonces, $NE = 3^{nC}$ estados. Para un sistema como el considerado en la simulación del presente trabajo, con $nC = 115$ cargas, se tiene un espacio de búsqueda de $NE = 3^{115}$ estados.

Este problema ha sido resuelto por los autores, mediante la utilización de MetaHeurísticas de las denominadas formas X-FPSO (MultiObjetivo) propuestas en [11].

El aporte de este trabajo es, no sólo evaluar la capacidad para resolver el problema descrito mediante la utilización de tales Métodos MetaHeurísticos, sino también *caracterizar* la forma en que realizan la resolución, a la luz del concepto de Inteligencia de Grupo.

2. La Metaheurística PSO y las Formas X-FPSO consideradas

2.1. La MetaHeurística PSO

El primer enfoque PSO (*Particle Swarm Optimization*) u Optimización por Enjambre de Partículas, fue propuesto en [6]. Este tipo de solución puede tratar con problemas de optimización MonoObjetivo. Se lo conoce como *PSO Clásico*, y muchas variantes o formas X-PSO, pueden ser consultadas en la referencia [11].

En el modelo *PSO Clásico* 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 nP 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 \mathbf{b}_i se corresponderá con el óptimo individual de la partícula i en su vida pasada. Del mismo modo, se indicará mediante $[\mathbf{b}]_G$ el vector cuyos elementos son las mejores posiciones globalmente alcanzadas por el conjunto de partículas en las iteraciones anteriores; entonces se indicará mediante \mathbf{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 , $\mathbf{X}^{[k]}$, el cambio de posición en la iteración siguiente, $k+1$, para la partícula i -ésima, resultará de la siguiente regla de movimiento:

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

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

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

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

$$\mathbf{V}^{[k+1]}_i = \mathbf{V}^{[k]}_i + w_c \times (r_1^{[k]}) \times [\mathbf{b}^{[k]}_i - \mathbf{X}^{[k]}_i] + w_s \times (r_2^{[k]}) \times [\mathbf{b}^{[k]}_G - \mathbf{X}^{[k]}_i] \quad (3)$$

En (3), el primer término 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 números aleatorios (r_1) y (r_2), 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 .

2.2. La Topología de Comunicación

Las primeras versiones de PSO abrieron el estudio de los *grafos de influencia* o *topologías de comunicación* entre las partículas. Una topología de comunicación o vecindario para las partículas se define como una función $s: S \rightarrow P(S)$, siendo S el conjunto de todas las partículas, y $P(S)$ el potencial o conjunto de partes de dicho conjunto. La función $s(p)$ asigna a cada partícula un

subconjunto de la población total de partículas. Tal subconjunto es llamado *vecindario de la partícula*. La utilidad de la topología estriba en regular la información disponible para cada partícula. Esta información es la que se utiliza en el tercer término de la ecuación de movimiento: *cooperación*. Además, debe existir un criterio según el cual cada partícula, según el subconjunto de vecinos que la topología reinante determine, construye el término cooperación de la ecuación de movimiento. Este criterio generalmente se basa en los valores de la función de aptitud de las posiciones \mathbf{b}_j , para todas las partículas j en el vecindario de la partícula en cuestión.

De ellas, la topología llamada Estrella Global es la utilizada por el PSO Clásico o Canónico: la partícula que posee la mejor posición del enjambre hasta la iteración k , $\mathbf{b}^{[k]}_G$, la informa al resto.

2.3. PSO con Factor de Constricción con Topología Estrella Global Determinística (PSO FC DS)

Esta variante X-PSO fue propuesta en [5]. Con esta modificación se buscó propiciar una mejor convergencia de las partículas en el tiempo, mediante la constricción, o reducción, de la amplitud de las oscilaciones de las partículas a medida que se enfocan en un punto prometedor determinado. En este caso, el operador velocidad clásico se modifica como sigue:

$$\mathbf{V}^{[k+1]}_i = \chi \times \{ \mathbf{V}^{[k]}_i + \varphi_M \times (r_1^{[k]}) \times [\mathbf{b}^{[k]}_i - \mathbf{X}^{[k]}_i] + \varphi_C \times (r_2^{[k]}) \times [\mathbf{b}^{[k]}_G - \mathbf{X}^{[k]}_i] \} \quad (4)$$

donde χ se denomina Factor de Constricción, y se obtiene mediante la siguiente expresión:

$$\chi = \frac{2 \times \kappa}{2 - \varphi - \sqrt{\varphi^2 - 4 \times \varphi}} \quad (5)$$

con: $\varphi_M + \varphi_C = \varphi$; $\varphi > 4$ y $0 < \kappa \leq 1$

Una configuración de parámetros comúnmente utilizada es $\varphi = 4.1$, $\varphi_M = \varphi_C = 2.05$. Esto resulta en un valor de $\chi \approx 0.73$. Cuando $\kappa = 1$, la convergencia es lo suficientemente lenta como para permitir una exploración detallada antes de que la búsqueda se estabilice en el punto de máxima aptitud encontrado.

La topología de comunicación utilizada en este caso es la Estrella Global.

2.4. PSO con Factor de Constricción con Topología VonNeumann (PSO FC VN)

Esta variante X-PSO difiere de la PSO FC DS fundamentalmente en dos aspectos: la topología de comunicación y la forma en que se utiliza la información topológica.

La topología utilizada en este caso es la llamada de VonNeumann, que se describe a continuación.

Esta topología es utilizada en los Automatas Celulares y las Redes Neuronales Artificiales, particularmente los mapas auto organizados (SOM). En PSO, se ha utilizado en trabajos como [17], en gran parte para que la velocidad con que la información referente al óptimo global del enjambre se propaga no sea instantánea, sino que se amortigüe, tratando de evitar de esta manera la convergencia prematura en óptimos locales.

En esta topología, el enjambre se configura según un arreglo bidimensional de partículas, de tamaño $m \times n$, donde cada partícula, ubicada genéricamente en la posición $[x, y]$ del arreglo, tiene exactamente cuatro vecinos: el superior $[(x+1) \bmod m, y]$, el inferior $[(x-1) \bmod m, y]$, el derecho $[x, (y+1) \bmod n]$ y el izquierdo $[x, (y-1) \bmod n]$, donde $a \bmod b$ denota el resto de la división entera de a/b . Esto tiene como consecuencia un conocimiento acotado de cada partícula respecto del enjambre.

Por lo tanto, la ecuación de movimiento para esta estrategia es igual que la estrategia anterior, a excepción de que ya no contiene la mejor posición global del enjambre, $b_G^{[k]}$, sino que se reemplaza por la mejor posición en el vecindario de VonNeumann de la partícula correspondiente, $b_{VN}^{[k]}$ (esto es, la mejor de los cuatro vecinos).

$$V_i^{[k+1]} = \chi \times \{ V_i^{[k]} + \phi_M \times (r_1^{[k]}) \times [b_i^{[k]} - X_i^{[k]}] + \phi_C \times (r_2^{[k]}) \times [b_{VN}^{[k]} - X_i^{[k]}] \} \quad (6)$$

2.5. EPSO

Desde los diferentes aportes realizados atentos a la *performance* de las formas X-PSO MonoObjetivo, se encuentra la MetaHeurística EPSO (*Evolutionary Particle Swarm Optimization*) u Optimización Evolucionaria por Enjambre de Partículas propuesta en [10]. Constituye un algoritmo de optimización metaheurístico que integra los conceptos de Estrategias Evolutivas (*Evolutionary Strategies*) 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 riesgo de una convergencia prematura a un óptimo local. El mecanismo del algoritmo EPSO se puede describir de la siguiente manera: para una iteración (también llamada en este contexto “generación”) k del PSO, las partículas evolucionarán 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) Cruzamiento: las partículas replicadas y mutadas se mueven según la regla de movimiento (ecuación evolutiva) correspondiente, combinando información de generaciones anteriores; d) 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:

$$V^{[k+1]}_i = w_{iL}^{*[k]} \times V^{[k]}_i + w_{iC}^{*[k]} \times [b^{[k]}_i - X^{[k]}_i] + w_{iS}^{*[k]} \times [b^{[k]*}_G - X^{[k]}_i] \quad (7)$$

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

$$w_{iL, C, S}^{[k+1]} = w_{iL, C, S}^{[k]} \times [1 + \sigma \times N(0,1)] \quad (8)$$

en la cual: 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:

$$b^{[k+1]*}_G = b^{[k]*}_G + w_{iN}^{*[k]} \times N(0,1) \quad (9)$$

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 (8). 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 $b^{[k]*}_G$.

La topología de comunicación utilizada en este caso es la Estrella, por lo que esta estrategia será referida como EPSO DS.

2.6. EPSO GIST (Global Individual Stochastic/Topology)

Esta X-PSO Forma evolucionaria se introduce en el presente trabajo, desde una propuesta presentada en [18], basada en una variante, denominada EPSO GIST, en la cual el acrónimo GIST, significa Topología Estrella Global/Individual (*Global Individual Star Topology*). En las X-PSO Formas presentadas, el óptimo global

alcanzado en cierta instancia de decisión o iteración algorítmica, k , es comunicado a la Población completa. Desde allí que se hable de Topología Estrella, pues podría asimilarse a una forma de comunicación en la que $\mathbf{b}^{[k]}_G$ ($\mathbf{b}^{[k]*}_G$, en la X-Forma EPSO), “irradia” información hacia todas las direcciones, hasta las posiciones del Espacio de Búsqueda donde se encuentran las partículas, con excepción de aquella/s cuyo óptimo individual, $\mathbf{b}^{[k]}_i$, coincide con el global. La MetaHeurística EPSO GIST, introduce, respecto de la EPSO, dos modificaciones a los efectos de favorecer el 3er Principio IG, la Diversidad de Respuesta, propiciando evitar convergencias prematuras en óptimos locales, sobre Espacios de Búsqueda que exhiben soluciones muy aisladas, tales como los observados en la Clase de Problemas referida y que aquí sigue considerándose. Para ello, la primera modificación consiste en asignar una probabilidad de comunicación del óptimo global al resto de las partículas, y la segunda, consiste en permitir, además, que cada partícula comunique, con cierta probabilidad, la información relativa a su óptimo individual al resto de la Población. De tal modo, la X-Forma EPSO GIST, tiene por ecuación evolutiva de movimiento, la expresión:

$$\mathbf{V}^{[k+1]}_i = w_{i1}^{*[k]} \times (r_1^{[k]}) \times \mathbf{V}^{[k]}_i + w_{iC}^{*[k]} \times (r_2^{[k]}) \times [\mathbf{b}^{[k]}_i - \mathbf{X}^{[k]}_i] + w_{iS}^{*[k]} \times (r_3^{[k]}) \times [\mathbf{b}^{[k]*}_G - \mathbf{X}^{[k]}_i] \times \alpha_{OG}^{[k]} + \sum_{j=1, j \neq i}^n (\delta(k) \times w_{iC}^{*[k]} \times [\mathbf{b}^{[k]}_j - \mathbf{X}^{[k]}_i] \times \alpha_{OI}^{[k]}_{ij}) \quad (10)$$

donde: $\alpha_{OG}^{[k]}_i$; es la probabilidad de que el óptimo global (OG) afecte al movimiento de la partícula i , en la iteración k y $\alpha_{OI}^{[k]}_{ij}$ es la probabilidad de que el óptimo individual (OI) de la partícula j , afecte al movimiento de la partícula i , $j \neq i$; $\delta(k)$ es un factor multiplicativo que va haciendo “decaer” la influencia de los OI, con probabilidades distintas de 0, conforme aumenta el número de iteraciones.

2.7. Extensión de las Formas X-PSO MonoObjetivo a las Formas X-FPSO MultiObjetivo

Si bien el enfoque adoptado originalmente por la metaheurística PSO fue MonoObjetivo, en [11] se propone una extensión al dominio MultiObjetivo de la MetaHeurística EPSO, referida como FEPSO (*Fuzzy EPSO*), mediante la utilización de Conjuntos Difusos. Como se detalla en tal referencia, los mismos son capaces de captar *incertidumbres no estocásticas de valor*. Esta extensión, aplicable a cualquier estrategia variante de la MetaHeurística PSO Canónica, es la que se utilizó en este trabajo.

Los Objetivos y la configuración de los Conjuntos Difusos solidarios correspondientes al Problema del Balance de Fases, así la obtención de los valores de referencia para cada objetivo, es idéntica a la descripta en el trabajo citado. Se trata de: a) Minimizar las **Pérdidas totales de potencia activa** (Perd), b) Minimizar la **Corriente Homopolar** ($I^{[0]}$), c) Maximizar un **Índice de**

Caídas de Tensión ($I(\Delta V)$) propuesto, y d) Minimizar el **Número de Cambios de Fase de conexión** (NC). La Función de Aptitud empleada, es la t-norma Producto de Einstein, cuyos argumentos son las Funciones de Pertenencia de los Conjuntos Difusos solidarios a cada objetivo, valuadas en cada iteración del Algoritmo MetaHeurístico correspondiente. No son de relevancia mayores detalles en el presente trabajo, pues el objetivo es evaluar el comportamiento de los Indicadores IG en las dos Formas X-FPSO mencionadas. Análogamente ocurre con los resultados, que por otro lado son los mismos que los obtenidos en tal referencia. Sí es importante destacar que si cierta forma X-PSO MonoObjetivo exhibe determinadas habilidades para satisfacer los Principios IG, su extensión X-FPSO al dominio MultiObjetivo las preserva, pues no se modifica la estrategia de movimiento de las partículas.

De modo que lo dicho en la sección siguiente para una Forma X-PSO, vale para su extensión X-FPSO.

3. INTELIGENCIA DE GRUPO. INDICADORES PROPUESTOS

3.1. Inteligencia de Grupo

El término Inteligencia de Grupo (*Swarm Intelligence*) fue introducido en [3]. Allí el concepto es utilizado para describir el comportamiento de los autómatas celulares, que exhiben características similares a las observables 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, *swarm* (traducido usualmente como *enjambre* o *grupo*), 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*.

Millonas [9], al tratar el mismo concepto, enuncia cinco principios que, en un comienzo, no pretendieron ser definitivos, aunque con el tiempo muchos artículos se hicieron eco de ellos, al no haber ninguna otra descripción coloquial, menos aún funcional, que sirviera para caracterizar el comportamiento colectivo de los enjambres o grupos. Los principios, tal como fueron descriptos en el trabajo citado, son:

Proximidad: el grupo debería ser capaz de realizar cálculos de espacio y tiempo elementales. Ya que espacio

y tiempo se traducen en utilización de energía, el grupo debería tener alguna habilidad para evaluar la utilidad de una respuesta al ambiente dada mediante estos términos. La palabra “cálculo” significa en este contexto una respuesta directa en el comportamiento del grupo a estímulos del ambiente, los cuales tienden a maximizar la utilidad del grupo como un todo para cierto tipo de actividad, por caso, la construcción de nidos, la búsqueda de comida, la defensa del grupo, el movimiento colectivo, entre otras;

Calidad: el grupo debería ser capaz de responder, no sólo a consideraciones de espacio y tiempo, sino también a factores de calidad, por ejemplo, la calidad de la comida o la seguridad del lugar;

Diversidad de Respuesta: el grupo no debería asignar todos sus recursos a través de espacios excesivamente reducidos. Debería buscar distribuir sus recursos en varias formas como garantía contra cambios repentinos en alguna de esas formas debido a fluctuaciones en el ambiente. Está claro que una respuesta completamente ordenada al medio, aún si fuera posible, no es deseable.

Estabilidad: el grupo no debería cambiar su comportamiento de un modo a otro ante cada fluctuación en el ambiente, ya que tales cambios insumen energía, y podría suceder que no se produzca un adecuado retorno de tal inversión.

Adaptación: junto con la Estabilidad constituyen dos lados de una misma moneda. Cuando la recompensa por cambiar el modo de comportamiento parece valer la inversión en energía, el grupo debería ser capaz de cambiar.

La mejor respuesta parece ser un balance entre el completo orden y un completo caos, y por tanto, el nivel de aleatoriedad del grupo es un factor importante. Suficiente ruido permitirá respuestas diversas, mientras que demasiado ruido destruirá cualquier comportamiento cooperativo.

Estas definiciones, como el mismo Millonas afirma, pueden ser vistas como análogas a muchos principios para la buena toma de decisiones, o dichos populares, como “el tiempo es dinero”, “sólo compra lo mejor”, “no pongas todos tus huevos en una sola canasta”, “mejor prevenir que lamentar”, “más vale pájaro en mano que cien volando”, “invierte para el futuro”, etc.

Los principios de Inteligencia de Grupo están inspirados en el comportamiento de organismos reales, como las hormigas, las cuales, afirma, realizan *cómputos ambientales (environmental computation)*, refiriéndose al hecho de que colectivamente llevan a cabo una recolección y procesamiento de información en su ambiente o entorno local. Ambos, recolección y procesamiento, ocurren simultáneamente y sin ningún control centralizado. Las acciones llevadas a cabo localmente por cada hormiga llevan a la consecución de

un objetivo global, en este caso, la búsqueda y recolección de comida.

Los algoritmos bioinspirados buscan emular este tipo de mecanismos de comportamiento emergente. Estos algoritmos, de naturaleza metaheurística, se utilizan típicamente para la resolución de problemas de optimización. “Si los pájaros artificiales pueden ser programados para volar hacia un árbol, ¿qué tal si los hacemos buscar algo, como comida?” [7]. En este contexto, se puede pensar en la búsqueda de una buena solución como la búsqueda del lugar con la mayor concentración de comida: el espacio de soluciones al problema de optimización y la función objetivo a optimizar pueden pensarse como el medio en el que los integrantes del grupo se mueven y la concentración de comida en cierto lugar, respectivamente.

Ejemplos de este tipo de algoritmos son *Ant Colony System (ACS – Sistema de Colonia de Hormigas)* [4], *Particle Swarm Optimization (PSO – Optimización por Enjambre de Partículas)* [6], *Artificial Fish School (AFS – Cardumen de Peces Artificiales)* [8], por citar los más conocidos. Particularmente, en [6], donde se desarrolla por primera vez el algoritmo PSO, se incluyen los principios de Inteligencia de Grupo mencionados más arriba, junto a un análisis acerca del cumplimiento de estos principios por parte de la MetaHeurística. En ese artículo se establece que PSO *adhiera* a los Principios de IG.

No se encontraron referencias en la extensa búsqueda bibliográfica realizada sobre expresiones cuantitativas acerca de cómo medir la inteligencia de un grupo. Muchos trabajos, como [1], centran la idea de Inteligencia de un Grupo en su *habilidad para la consecución de un objetivo o el cumplimiento de una tarea a través de acciones simples, colaborativas y descentralizadas llevadas a cabo por sus miembros*. Esta definición es la que adoptamos en este trabajo.

Puede notarse que esta definición hace énfasis en el éxito o la eficacia de un cierto grupo en la realización de la tarea. Sin embargo, el objetivo de este trabajo es establecer medidas descriptivas acerca de *la forma* en la que un grupo realiza la tarea que se le ha encomendado.

3.2. Indicadores Propuestos de Inteligencia de Grupo

Un aporte importante de este trabajo es el diseño de indicadores concernientes a la forma en que cierto grupo se encuentra alcanzando un objetivo. Estos indicadores se encuentran inspirados en los Principios de Inteligencia de Grupo de Millonas, por este motivo se propone un indicador por cada principio. El objetivo primigenio buscado con la formulación de estos indicadores es el análisis de las habilidades de distintas estrategias MetaHeurísticas, buscando describir las diferencias de comportamiento de las mismas. En principio, estos

indicadores están formulados para estrategias del tipo X-PSO, aunque nada impide que se apliquen a otro tipo de metaheurísticas poblacionales que tengan una interfaz similar a la X-PSO. En los próximos apartados se describen los indicadores junto al análisis mencionado.

Todos los indicadores están normalizados en el intervalo [0,1], siendo 0 el valor de mínima habilidad y 1 el de máxima habilidad en cada indicador, y son evaluados en cada iteración k.

3.2.1. Indicador de Proximidad

El Indicador de Proximidad (IP), mide la cantidad de partículas que recientemente han cambiado su posición. Por tanto, este indicador aporta información sobre el comportamiento del el grupo al realizar un desplazamiento, como respuesta al estímulo que reciben desde la estrategia de movimiento dentro del Espacio de Búsqueda.

Se calcula como la cantidad de partículas que cambiaron su posición en la última iteración sobre la cantidad total de partículas.

$$IP^{[k]} = \frac{\sum_{i=1}^{nP} X_i^{[k]} \neq X_i^{[k-1]}}{nP} \quad (10)$$

Aquí se emplea \neq como un operador relacional que devuelve 1 si los operandos son distintos, o bien 0 si son iguales.

3.2.2. Indicador de Calidad

El Indicador de Calidad (IC), mide la cantidad de partículas que recientemente han mejorado su aptitud, es decir, aquellas que se han desplazado a una posición mejor. Se supone que un grupo es más hábil en este principio en la medida en que sus miembros utilizan información de calidad del ambiente para realizar su movimiento, buscando nuevos lugares, mejores que los anteriores, para que puedan ser utilizados en el próximo movimiento, completando un círculo virtuoso.

Se calcula como la cantidad de partículas que mejoraron su aptitud individual en alguna de las últimas dos iteraciones (o ambas) sobre la cantidad total de partículas.

$$IC^{[k]} = \frac{\sum_{i=1}^{nP} f(x_i^{[k]}) > f(x_i^{[k-1]}) \vee f(x_i^{[k-1]}) > f(x_i^{[k-2]})}{nP} \quad (11)$$

Aquí se emplea $>$ como un operador relacional que devuelve 1 si el operando izquierdo es estrictamente mayor que el derecho, o bien 0 en caso contrario.

3.2.3. Indicador de Diversidad de Respuesta

La respuesta de una partícula al requerimiento de información de otra es su mejor posición individual, b_i . Un grupo es más diverso en la medida en que la cantidad de información disponible aumenta. Quiere decir que a mayor cantidad de mejores posiciones individuales distintas, el grupo posee más información.

El Indicador de Diversidad de Respuesta (IDR) se calcula como la entropía, o cantidad de información, determinada por las ocurrencias de las aptitudes de los mejores individuales de las partículas. Según la clásica expresión acuñada por Shannon [16]:

$$\text{Entropía} = - \sum_{i=1}^n P_i \log(P_i) \quad (12)$$

siendo P_i la frecuencia de la variable i . La base del logaritmo generalmente es 2, ya que ésta determina la “unidad de medida” de la entropía, y en la teoría de la información esta unidad suele ser el *bit*. De modo que esta expresión estaría determinando en ese caso la cantidad de bits de información en una colección de datos.

Para este indicador, se propone medir la entropía o cantidad de información en el conjunto de las aptitudes de las partículas, por lo que, si se define $F^{[k]}$ como el conjunto de todas las $f(b^{[k]})$, puede considerarse $f \in F^{[k]}$, y $P_f = \text{frec}(f)/nP$, siendo $\text{frec}(f)$ la cantidad de partículas que tienen la misma función de aptitud en la iteración k , y nP el número total de partículas. Así, la expresión resultante puede escribirse como sigue:

$$IDR^{[k]} = - \sum_{f \in F^{[k]}} P_f \log_{nP}(P_f) \quad (13)$$

con $\log_{nP}(P_f)$ el logaritmo en base nP de P_f . Este indicador toma valor 1 cuando todos los b_i son distintos, y 0 cuando todos los b_i son iguales. Tómese, por caso y sin pérdida de generalidad, un grupo de 10 partículas. Si todos los b_i son distintos, cada $P_f = 1/10$, y, como $nP = 10$, $\log_{nP}(P_f) = \log_{10}(1/10) = -1$, por lo tanto, los diez términos de la sumatoria serán $-1/10$, lo que resulta en un valor del indicador de $IDR^{[k]} = 1$. Por el contrario, si todas las partículas tienen el mismo b_i , existe un único $P_f = 10/10 = 1$. Como $\log_{10}(1) = 0$, $IDR^{[k]} = 0$.

3.2.4. Indicador de Estabilidad

El Indicador de Estabilidad (IE), mide el movimiento promedio del grupo. Se supone que el grupo se encuentra inestable cuando sus movimientos son muy pronunciados, y más estable cuando sus movimientos son conservadores. Para su cálculo se propone la siguiente expresión:

$$IE^{[k]} = e^{- \left(\frac{2 \times \sum_{i=1}^{nP} \|V_i^{[k]}\|^1}{DIM \times nP} \right)} \quad (14)$$

Siendo DIM la dimensión del problema (número de objetivos), nP la cantidad de partículas y $\|V_i^{[k]}\|^1$ la norma de orden 1 o de Hamming correspondiente a la velocidad de la partícula i . Esta función siempre estará

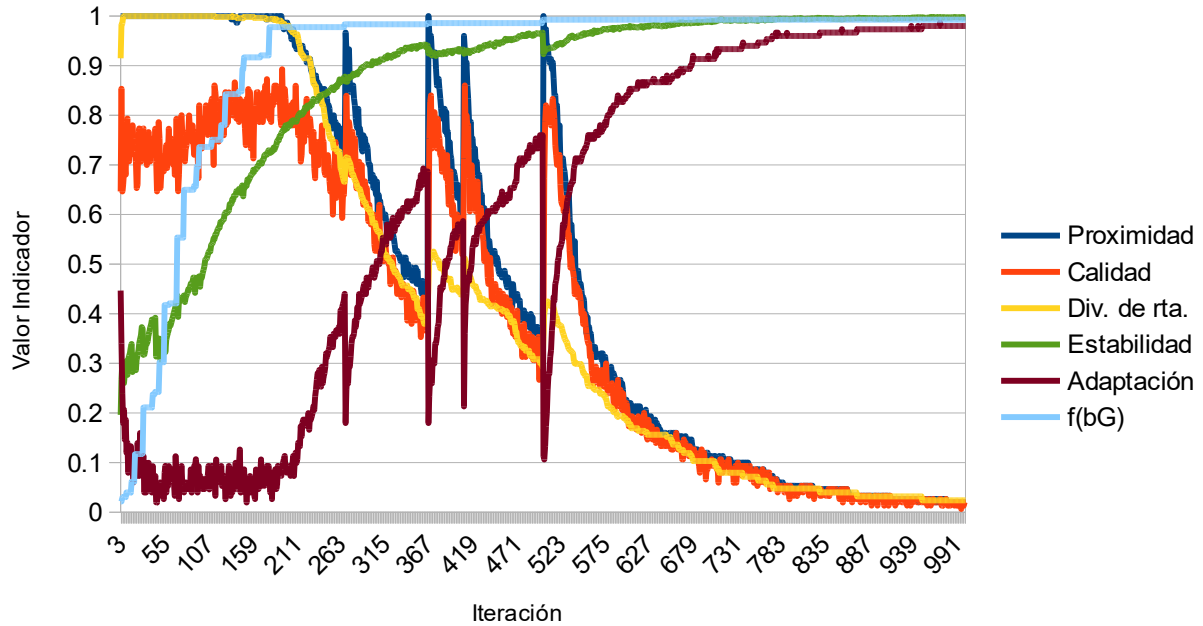


Figura 1: Evolución de los IIG en la FPSO CF DS

acotada en el intervalo $[0,1]$, con valores cercanos a 1 cuando la cantidad de movimiento promedio esté cerca de 0, e irá decreciendo a medida que la cantidad de movimiento promedio aumente.

3.2.5. Indicador de Adaptación

Según el principio de adaptación, un grupo debe ser capaz de cambiar su comportamiento si la energía insumida para ello vale la pena el esfuerzo. En este indicador, se busca medir cuántas partículas del grupo están “adaptadas”. El significado atribuido a este concepto es el siguiente: sea una partícula i que cuenta con vecinas $j \in s(i)$. Si la partícula i conoce el mejor lugar \mathbf{b}_i de todo su vecindario, esto es, $\forall j \in s(i): f(\mathbf{b}_i^{[k]}) \geq f(\mathbf{b}_j^{[k]})$, entonces la partícula está *adaptada*, ya que se encuentra (o se ha encontrado) en el mejor lugar que puede, con la información que tiene disponible. Además, si lo anterior no se cumple, esto es, $\exists j \in s(i): f(\mathbf{b}_i^{[k]}) < f(\mathbf{b}_j^{[k]})$, la partícula i aún puede estar adaptada, o más bien, *adaptándose*, si es que mejora su mejor posición individual de la iteración actual a la siguiente, esto es, $f(\mathbf{b}_i^{[k+1]}) > f(\mathbf{b}_i^{[k]})$. Nótese que esta condición es más exigente que la enunciada por Millonas, ya que adicionalmente a demostrar una respuesta mediante el desplazamiento, aquí se exige que la partícula siga una trayectoria que haga mejorar su registro de lugares prometedoros mientras logra una solución que se equipare, o supere, a la mejor de su vecindario. En cualquier otro caso, la partícula se considera *desadaptada*.

Por lo tanto, para el cálculo de Indicador de Adaptación (IA), se propone según la expresión condicional:

$$adaptado(i,k) = \begin{cases} 1 & \text{si } \left(\begin{array}{l} \exists j \in s(i) : f(\mathbf{b}_j^{[k-1]}) \\ > f(\mathbf{b}_i^{[k-1]}) \\ \rightarrow f(\mathbf{b}_i^{[k]}) > f(\mathbf{b}_i^{[k-1]}) \end{array} \right) \\ 0 & \text{si no} \end{cases} \quad (15)$$

$$IA^{[k]} = \frac{\sum_{i=1}^{nP} (adaptado(i,k))}{nP} \quad (16)$$

4. Análisis de las Habilidades de las Formas X-FPSO seleccionadas según los indicadores IG Propuestos.

A continuación se presenta la evolución de los indicadores de Inteligencia de Grupo en ejecuciones típicas de las Formas X-FPSO referidas en la resolución del Problema del Balance de Fases de un SDEE BT.

4.1. FPSO FC DS

Los resultados para esta variante X-PSO, en una ejecución de 150 partículas durante 1000 iteraciones se presentan en la Figura 1.

Proximidad: los niveles de este indicador empiezan muy altos, lo cual quiere decir que la gran mayoría de las partículas se encuentran en movimiento. Mientras la estrategia se mantiene actualizando b_G , las partículas se mantienen en movimiento. A medida que las iteraciones pasan y no hay actualizaciones de b_G , las partículas tienden a mantener su posición, lo que lleva a la disminución del valor del indicador. Ante el descubrimiento de un nuevo b_G , en la instancia que sea del algoritmo, muchas partículas reactivan su movimiento, de modo que este indicador aumenta su valor bruscamente, como puede apreciarse en la figura entre las iteraciones 400 y 600.

Calidad: este indicador presenta niveles altos, entre 0.7 y 0.9 durante las primeras iteraciones. La mayor parte de las partículas tienden a mejorar sus aptitudes. En gran medida, este indicador tiende a “copiar” los movimientos de IP en este caso, lo cual significa que los movimientos están “teniendo éxito”, en el sentido de que las partículas se están moviendo a posiciones mejores que las anteriores.

Diversidad de respuesta: este indicador comienza con niveles muy buenos, y es esperable, ya que es la parte de la ejecución en la que más se actualizan los mejores individuales b_i . Puede observarse que eventualmente este indicador empieza a descender, y esto se debe a que una cantidad creciente de partículas visita el mejor lugar global, b_G , actualizando su b_i , de modo que $b_i = b_G$. También se aprecian pequeñas recuperaciones de este indicador, coincidentes con el descubrimiento de nuevos

b_G .

Estabilidad: tiende a estabilizarse adecuadamente, sin impedir la exploración. Se desestabiliza, aunque en medidas poco perceptibles, cuando se descubre un nuevo b_G . Observando esto en conjunción con IP, puede concluirse en que los nuevos b_G no se encuentran muy lejos de los anteriores, ya que, si bien muchas partículas reactivan su movimiento (IP alto), la cantidad de movimiento de los desplazamientos que realizan no es muy alta (IE apenas más bajo).

Adaptación: en iteraciones tempranas presenta bajos niveles de este indicador, con tendencia creciente con el paso de las iteraciones. Esto es esperable debido a la naturaleza cambiante de los b_i y por tanto del “ranking” de las partículas. Las caídas en el nivel de este indicador se deben al descubrimiento de nuevas soluciones prometedoras en el vecindario de las partículas, sin embargo, es capaz de “recuperar terreno” en cualquier etapa de la ejecución.

4.2. FPSO FC VN

Los resultados para esta variante X-PSO, en una ejecución de 150 partículas durante 1000 iteraciones, en un arreglo de 10x15 se presentan en la Figura 2.

Proximidad: presenta niveles elevados de este indicador, y los mantiene con el correr de las iteraciones. Pueden apreciarse algunos picos, que se corresponden con el descubrimiento de nuevas soluciones prometedoras muy buenas, que afectan al movimiento de,




Figura 2: Evolución de los IIG en la FPSO CF VN

al menos, cuatro partículas, como se explicó más arriba. El hecho de conservar un nivel tan alto de movimiento después de tantas iteraciones (aún afectada por el factor de constricción) se debe a la forma a la forma en que la información de las mejores posiciones se pasa en el enjambre: es un topología de tipo local, de manera que el traspaso de información es lento.

Calidad: los niveles de este indicador también son muy altos, y al igual que en el caso de la FPSO FC DS, tiende a “copiar” los movimientos del IP. Una desventaja de esta variante es la lentitud con que el mejor global se actualiza: un candidato aceptable en esta ejecución fue encontrado alrededor de la iteración 400.

Diversidad de respuesta: este indicador se mantiene en niveles muy altos, en gran parte debido a la configuración topológica, como se explicó en el apartado del IP. Tiende a decaer, pero la velocidad con lo que lo hace es lenta.

Estabilidad: esta es la variante menos estable de las estudiadas. No alcanza valores superiores a 0.8 en corridas de 1000 iteraciones, necesitando, en general, de cantidades muy elevadas de iteraciones para que su cantidad de movimiento decaiga.

Adaptación: los niveles de adaptación han sido aceptables, también debido a la configuración topológica., aunque, como en los indicadores anteriores, la velocidad de mejora es baja.

4.3. FEPSO DS

Los resultados para esta variante X-PSO, en una ejecución de 150 partículas durante 600 iteraciones se presentan en la Figura 3.

Proximidad: se mantiene en movimiento por muy pocas iteraciones comparada con las estrategias anteriores. Aún así, la búsqueda es intensa y rinde sus frutos rápidamente. Tiende a converger rápido. No suele superar la iteración 200-250 con sus partículas en movimiento. Algunos picos se deben a descubrimientos de nuevas soluciones debido a la mutación de pocas partículas que se encuentran buscando alrededor del óptimo global.

Calidad: presenta valores altos en iteraciones tempranas. Decae y se recupera bruscamente. En varias ocasiones supera al IP, lo cual se debe a sucesiones de buenas posiciones, seguidas de ausencia de movimiento. Esto se debe al criterio de evolución de la EPSO, que prioriza la aptitud frente al movimiento. Cuando una partícula se encuentra con una solución muy buena, posiblemente la mejor de las soluciones cercanas, la partícula tiende a mantener esa posición, ya que cualquier movimiento hace que su aptitud disminuya, de modo que es muy difícil llegar a soluciones mejores que se encuentran muy lejos. Esta habilidad es la más remarcable para esta estrategia.

Diversidad de respuesta: logra muy buenos valores, especialmente teniendo en cuenta de que se trata de una topología Estrella Global Determinística. Puede apreciarse que la “fortuna” al encontrar soluciones muy buenas, difíciles de superar, en iteraciones tempranas,

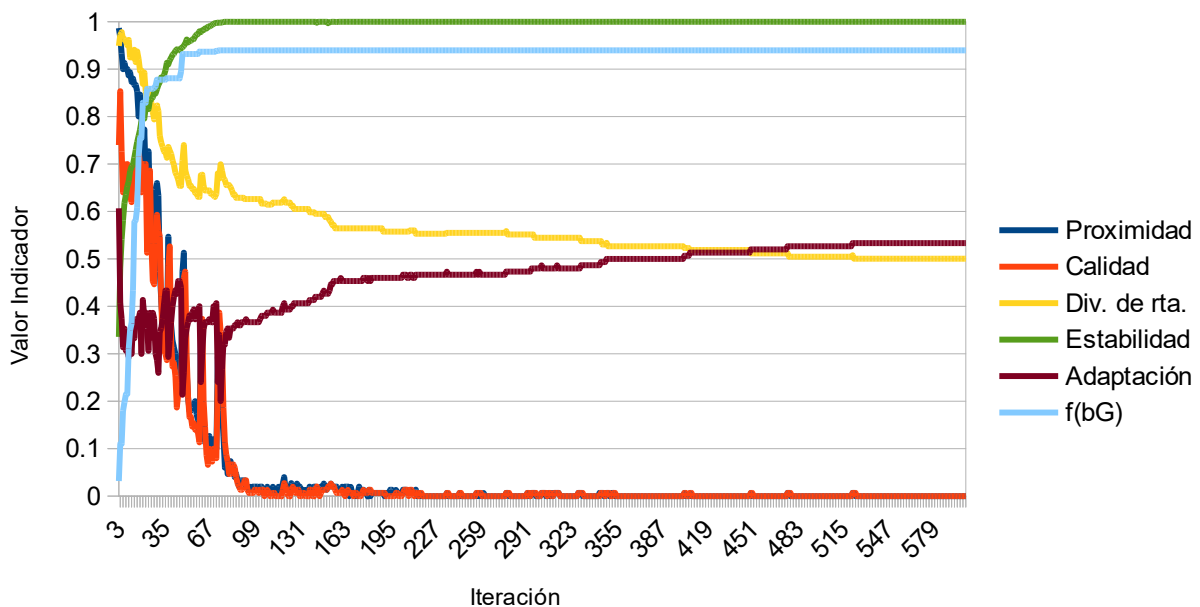


Figura 3: Evolución de los IIG en la FEPSO DS

hace que, en general, el valor del indicador decaiga.

Estabilidad: las partículas que se mueven mediante esta estrategia se estabilizan mediante el autoajuste de sus parámetros, en particular, cuando las constantes asociadas a la ecuación de movimiento tienden al valor 0. Una vez que esto ha sucedido es muy difícil que una partícula pueda reaccionar ante un cambio de aptitud en su vecindario. Esto produce conservación o mejora de la

Proximidad: el valor de este indicador se mantiene en niveles similares a los de la FEPSO DS, aunque siempre por encima. La configuración de valores de probabilidad topológicos hace que la información se propague algo más lentamente que en dicha estrategia, aunque no tanto como la FEPSO CF VN.

Calidad: los valores de calidad no son tan elevados, aunque, en comparación con los niveles de IP, son

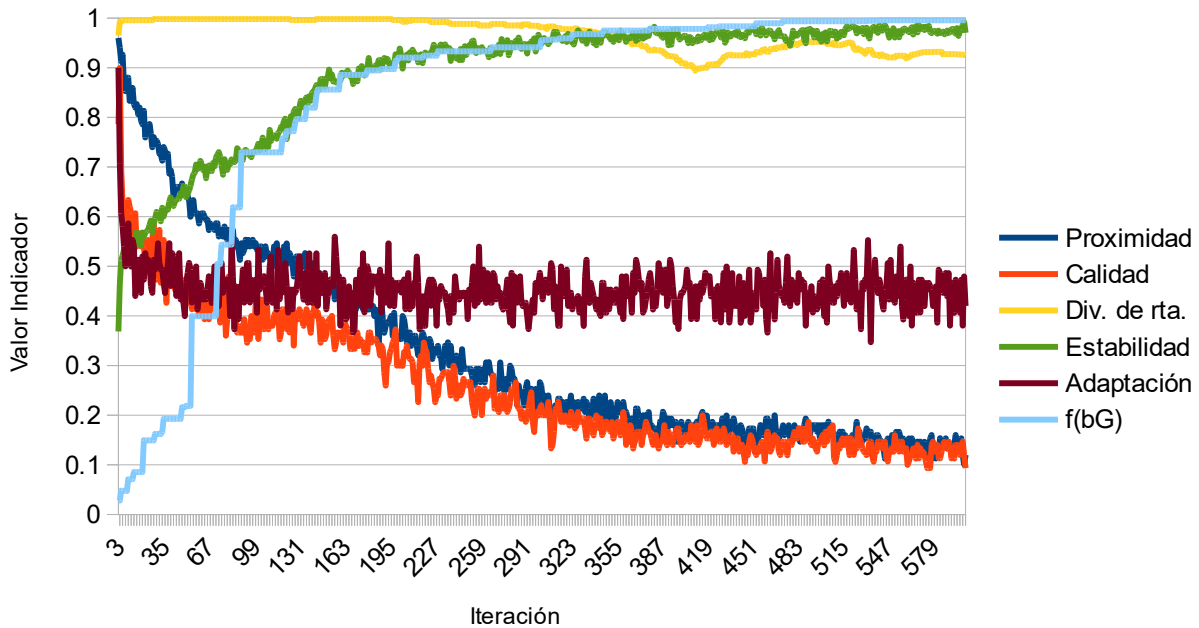


Figura 4: Evolución de los IIG en la FEPSO GISSt

diversidad de respuesta, en detrimento de la adaptación (una partícula tiende a quedarse en su lugar debido a que no puede cambiar de posición por poseer constantes de movimiento cercanas a 0, por lo que su aptitud no cambia, o empeora).

Adaptación: es buena adaptándose durante iteraciones tempranas del algoritmo, cuando las partículas conservan su potencial de movimiento. Una parte del enjambre tiende a adaptarse buscando la mejor solución global, mientras que otra se conforma con su mejor individual, logrando un buen balance Diversidad-Adaptación, aunque tienda a priorizar este principio por sobre aquel.

4.4. FEPSO GISSt

Los resultados para esta variante X-PSO, en una ejecución de 150 partículas durante 600 iteraciones se presentan en la Figura 4. En particular, para esta variante de la FEPSO GISSt se utilizó un valor de $\alpha_{OG} = 0$ y $\alpha_{OI} = 2/150$, para realzar aún más las habilidades de esta estrategia. También se consideró un $\delta(k)$ constante e igual a 1 para que la influencia de los OI no decaiga.

similares, es decir que hay pocos movimientos infructuosos. La velocidad de actualización de bG es algo más lenta que en su variante con Estrella Global Determinística, lo cual se condice con la elección de valores de probabilidad topológicos escogidos para esta ejecución.

Diversidad de respuesta: este principio es en el cual esta estrategia posee mayor habilidad en general, aunque con esta elección de parámetros esto se evidencia aún más. Se mantiene durante prácticamente toda la ejecución por encima del valor 0.9, algo que ninguna estrategia hasta el momento había logrado.

Estabilidad: se estabiliza correctamente, sin detrimento de la exploración.

Adaptación: los niveles de “ruido” en este indicador se deben a los cambios topológicos de esta estrategia (vecindario variable). Aún así, logra niveles cercanos al 0.45 durante toda su ejecución.

5. Conclusiones

1) Se han presentado novedosos indicadores como medidas de la habilidad en sendos principios de Inteligencia de Grupo aplicables (no excluyentemente) a MetaHeurísticas MultiObjetivo referidas como Formas X-FPSO, de amplio uso en la Optimización Combinatoria. Sin pérdida de generalidad, se los aplicó al estudio de cuatro variantes consideradas por los autores como representativas debido a sus habilidades para satisfacer los cinco Principios de Inteligencia de Grupo, tres de ellos (FPSO FC DS, FEPSO DS y FEPSO GIStT) validados cualitativamente a través de los resultados obtenidos mediante una HiperHeurística CBR con dominio en Formas X-FPSO, desarrollada en trabajos previos para resolver el Problema de Balance de Fases en un SDEE BT. Las cuatro Formas X-FPSO, son la FPSO con Factor de Constricción y Topología de Comunicación Estrella Global Determinística (FPSO FC DS), la FPSO con Factor de Constricción y Topología de Comunicación VonNeumann (FPSO FC VN), la FEPSO con Topología de Comunicación Estrella Global Determinística y la FEPSO GIStT con Topología de Comunicación Global/Individual Estocástica. En la validación *cualitativa* referida, se observó que FPSO FC exhibía habilidad específica para satisfacer los Principios IG de Proximidad y Estabilidad, mientras que la FPSO DS lo hacía en Calidad y Adaptación y la FEPSO GIStT en Diversidad de Respuesta. Estas observaciones pudieron ser validadas cuantitativamente, mediante los indicadores propuestos. Finalmente, la FPSO FC VN no había sido estudiada anteriormente por los autores, presentando habilidades específicas en los principios de Proximidad (por sobre FPSO FC FS) y Diversidad de Respuesta (por debajo de FEPSO GIStT), siendo muy pobre su desempeño en Estabilidad.

2) Estos indicadores permiten caracterizar el comportamiento de tales MetaHeurísticas durante la ejecución de las mismas. Adicionalmente, permiten identificar instancias clave de dicha ejecución, como la ausencia de reacción ante el descubrimiento de una nueva solución prometedora, la pérdida de la diversidad en el enjambre, y el éxito en el desplazamiento, entre otras. Son independientes del dominio del problema específico al que se aplique la MetaHeurística dentro de la Clase de Problemas caracterizados como se presentó en el epígrafe 1.1.

3) Finalmente, los indicadores desarrollados son una invaluable fuente de información para la generación de patrones de entrenamiento de redes neuronales, que pueden actuar como función de selección de una Hiperheurística Basada en Razonamiento (CBR) con dominio en Forma X-FPSO. Una de las ventajas más salientes de este esquema respecto de otros enfoques ya utilizados en los trabajos previos, es que la información

caracteriza a todo el enjambre, y no a un subconjunto de este.

6. REFERENCIAS

- [1] Aydin, M. E. (2010): "Coordinating metaheuristic agents with swarm intelligence". *Journal of Intelligent Manufacturing*, 23(4), pp. 991–999.
- [2] Beni, G. (2004). From swarm intelligence to swarm robotics. In *Swarm robotics* (pp. 1-9). Springer Berlin Heidelberg.
- [3] Beni, G. Y Wang, J. (1989): "Swarm Intelligence in Cellular Robotic Systems". In *Proceedings NATO Advanced Workshop on Robots and Biological Systems*. Tuscany.
- [4] Bonabeau, E., Dorigo, M., Theraulaz, G. (1999): *Swarm intelligence: from natural to artificial systems*. Handbook of Nature-Inspired and Innovative Computing.
- [5] Clerc, M., Y Kennedy, J. (2002). "The particle swarm - explosion, stability, and convergence in a multidimensional complex space". *IEEE Transactions on Evolutionary Computation*, 6(1), pp. 58–73.
- [6] Kennedy, J.; Eberhart, R.C. "Particle Swarm Optimization". *IEEE International Conference on Neural Networks*. Perth, Australia. IEEE Service Center, Piscataway, NJ. 1995.
- [7] Kennedy, J., Eberhart, R. C., Shi, Y., Jacob, C., Koza, J. R., III, F. H. B., Keane, M. A. (2001). *Swarm Intelligence*. Evolutionary Computation – Morgan Kaufmann Series.
- [8] Li, X., Shao, Z., Qian, J. (2002). "An optimizing method based on autonomous animats: fish-swarm algorithm". *Systems Engineering: Theory and Practice*, 22(11), pp. 32–38.
- [9] Millonas, M. M. (1994). "Swarms, phase transitions, and collective intelligence". C. G. Langton (Ed.), *Artificial Life III*, pp. 417–445.
- [10] Miranda, V., Keko, H., Jaramillo, A. (2007). "EPSO: Evolutionary particle swarms". *Studies in Computational Intelligence*, 66, pp. 139–167.
- [11] Schweickardt, G., Y Miranda, V. (2010). "Metaheurística FEPSO aplicada a problemas de Optimización Combinatoria: Balance de Fases en Sistemas de Distribución Eléctrica". *Ciencia, Docencia Y Tecnología*, (40), pp. 133–163.
- [12] Schweickardt, G.; Casanova, C.; Gimenez, J. (2013): "Hiperheurística Basada en Razonamiento con Dominio en Metaheurísticas X-FPSO Multiobjetivo. Aplicación sobre una Optimización Dinámica Posibilística. Parte 1". *Revista de la Escuela de Perfeccionamiento en Investigación Operativa – Nro. 34* – pp. 8-29.
- [13] Schweickardt, G.; Casanova, C.; Gimenez, J. (2014): "Hiperheurística Basada en Razonamiento con Dominio en Metaheurísticas X-FPSO Multiobjetivo.

Aplicación sobre una Optimización Dinámica Posibilística. Parte 2”. Revista de la Escuela de Perfeccionamiento en Investigación Operativa – Nro. 35 – pp. 128-148.

[14] Schweickardt, G.; Casanova, C. (2015): “Modelos HiperHeurísticos basados en Razonamiento con Procesamiento Paralelo y Dominio en MetaHeurísticas X-PSO Y AFS MultiObjetivo”. Revista de la Escuela de Perfeccionamiento en Investigación Operativa – Nro. 37 – pp. 7-26.

[15] Schweickardt, G., Miranda, V., Giménez, J. M.

[16] Shannon, C. E. (1948). “A Mathematical Theory of Communication”. The Bell System Technical Journal, 27, pp. 379–423.

[17] Kennedy, J., Mendes, R. (2006). “Neighborhood Topologies in Fully Informed and Best-of-Neighborhood Particle Swarms”. IEEE Transactions on Systems, Man, And Cybernetics—Part C: Applications and Reviews, Vol. 36, N° 4, July 2006.

[18] Schweickardt, G., Miranda, V., Giménez, J. (2010). “Dos Enfoques Metaheurísticos para Resolver Problemas de Optimización Combinatoria Multicriterio: Fuzzy Evolutionary Particle Swarm Optimization con Topología Estrella Global/Individual (FEPSO GIST) y Fuzzy Simulated Annealing (FSA)”. XXIII ENDIO - XXI EPIO - II ERABIO, Tandil, Argentina.