



UNIVERSIDAD DE CUENCA

Facultad de Ingeniería

Carrera de Ingeniería Eléctrica

Planeamiento Dinámico de la Expansión de los Sistemas de
Transmisión usando Algoritmos Meméticos

Trabajo de titulación previo a la
obtención del título de
Ingeniero Eléctrico

Autores:

Carlos Andrés Luna Beltrán

CI: 0302714183

Correo electrónico: carlos.lunab96@gmail.com

Martin Sebastián Carangui González

CI: 0302365515

Correo electrónico: shebacarangui@gmail.com

Director:

Ing. Santiago Patricio Torres Contreras, PhD.

CI: 0102448958

Cuenca, Ecuador

23-marzo-2021



Resumen:

El objetivo del Planeamiento Dinámico de la Expansión de los Sistemas de Transmisión (PDEST) es determinar qué infraestructura eléctrica, en qué lugar y en qué momento debe ser agregada a un sistema eléctrico de potencia dentro de un horizonte de tiempo determinado. La adición de nuevos componentes al sistema procura satisfacer el crecimiento de la demanda, y cumplir con parámetros de eficiencia, calidad de servicio, confiabilidad y economía, dentro del horizonte de planeamiento. En este trabajo de investigación se propone e implementa un método de solución usando una técnica basada en Algoritmos Meméticos, los cuales resuelven el problema del PDEST combinando técnicas de solución basadas en población y búsqueda local. El algoritmo propuesto combina la técnica de Enjambre de Partículas (PSO) y la técnica de búsqueda local Hill Climbing. Los sistemas de prueba para obtener los resultados fueron los sistemas Garver y el IEEE de 24 nodos. Los escenarios de prueba para estos sistemas fueron con y sin redespacho.

Palabras claves: Algoritmo memético. Hill climbing. Modelo AC. PDEST. PSO. SEP.



Abstract:

The objective of Dynamic Transmission Expansion Planning (DTEP) is to determine what electrical infrastructure, where and when it should be added to a power system within a given time horizon. The addition of new components to the system seeks to meet the growth in demand, and to comply with parameters of efficiency, quality of service, reliability and economy, within the planning horizon. In this research work, a solution method is proposed and implemented using a technique based on Memetic Algorithms, which solves the DTEP problem by combining solution techniques based on population and local search. The proposed algorithm combines the Particle Swarm Optimization (PSO) technique and Hill Climbing local search technique. The test systems to obtain the results were the Garver and the 24-node IEEE systems. The test scenarios for these systems were with and without redispatch.

Keywords: Memetic algorithm. Hill climbing. AC Model. DTEP. PSO. SEP.



Cláusula de Propiedad Intelectual

Carlos Andres Luna Beltran, autor del trabajo de titulación “Planeamiento Dinámico de la Expansión de los Sistemas de Transmisión usando Algoritmos Meméticos”, certifico que todas las ideas, opiniones y contenidos expuestos en la presente investigación son de exclusiva responsabilidad de su autor.

Cuenca, 23 de marzo de 2021.

Carlos Andres Luna Beltran

C.I: 0302714183



Cláusula de Propiedad Intelectual

Martin Sebastián Carangui González, autor del trabajo de titulación “Planeamiento Dinámico de la Expansión de los Sistemas de Transmisión usando Algoritmos Meméticos”, certifico que todas las ideas, opiniones y contenidos expuestos en la presente investigación son de exclusiva responsabilidad de su autor.

Cuenca, 23 de marzo de 2021.

Martin Sebastián Carangui González

C.I: 0302365515



Cláusula de licencia y autorización para publicación en el Repositorio Institucional

Carlos Andres Luna Beltran, en calidad de autor y titular de los derechos morales y patrimoniales del trabajo de titulación "Planeamiento Dinámico de la Expansión de los Sistemas de Transmisión usando Algoritmos Meméticos", de conformidad con el Art. 114 del CÓDIGO ORGÁNICO DE LA ECONOMÍA SOCIAL DE LOS CONOCIMIENTOS, CREATIVIDAD E INNOVACIÓN reconozco a favor de la Universidad de Cuenca una licencia gratuita, intransferible y no exclusiva para el uso no comercial de la obra, con fines estrictamente académicos.

Asimismo, autorizo a la Universidad de Cuenca para que realice la publicación de este trabajo de titulación en el repositorio institucional, de conformidad a lo dispuesto en el Art. 144 de la Ley Orgánica de Educación Superior.

Cuenca, 23 de marzo de 2021.

Carlos Andres Luna Beltran

C.I: 0302714183



Cláusula de licencia y autorización para publicación en el Repositorio Institucional

Martin Sebastián Carangui González, en calidad de autor y titular de los derechos morales y patrimoniales del trabajo de titulación “Planeamiento Dinámico de la Expansión de los Sistemas de Transmisión usando Algoritmos Meméticos”, de conformidad con el Art. 114 del CÓDIGO ORGÁNICO DE LA ECONOMÍA SOCIAL DE LOS CONOCIMIENTOS, CREATIVIDAD E INNOVACIÓN reconozco a favor de la Universidad de Cuenca una licencia gratuita, intransferible y no exclusiva para el uso no comercial de la obra, con fines estrictamente académicos.

Asimismo, autorizo a la Universidad de Cuenca para que realice la publicación de este trabajo de titulación en el repositorio institucional, de conformidad a lo dispuesto en el Art. 144 de la Ley Orgánica de Educación Superior.

Cuenca, 23 de marzo de 2021

Martin Sebastián Carangui González

C.I: 0302365515

I. INTRODUCCIÓN

Un Sistema Eléctrico de Potencia (SEP) tiene como propósito entregar energía eléctrica a los consumidores en las mejores condiciones técnicas, económicas y ambientales, y en el lugar y momento que necesiten. Los Sistemas Eléctricos de Potencia se encuentran en continua evolución debido a que la demanda crece en el transcurso del tiempo, e ingresan en operación nuevos proyectos de generación que pueden estar basados o no en energía renovable. [8] Debido a estas circunstancias, es necesario proyectar la manera en que deberían expandirse y operar los diferentes subsistemas en el largo plazo (Generación, Transmisión, Distribución). En el caso de la expansión de los sistemas de transmisión, existen dos enfoques principales respecto al horizonte de planificación: el planeamiento estático y el dinámico. El planeamiento estático responde a las preguntas: ¿Qué? y ¿Dónde? debe agregarse la nueva infraestructura eléctrica; mientras que el planeamiento dinámico, además, indica el momento en que debe agregarse dicha infraestructura [3].

El Planeamiento Dinámico de la Expansión de los Sistemas de Transmisión (PDEST) tiene como objetivo determinar las adiciones de infraestructura eléctrica en los diferentes horizontes de tiempo, de forma que se minimicen costos de inversión, pérdidas, etc., satisfaciendo la demanda de energía en los centros de consumo. Este estudio se aborda en dos partes: primero se determina el modelo matemático del problema, y posteriormente, se implementa la técnica de solución para resolverlo.

En cuanto al modelo matemático del problema, existen dos modelos desarrollados: el modelo de corriente continua (DC) y el modelo de corriente alterna (AC). El PDEST usando el modelo AC resulta un problema no polinomial complejo, y por este motivo se necesitan herramientas de optimización que permiten resolver el problema en sistemas eléctricos como los presentados en [2]-[8]. El modelo AC desarrollado en [1] representa un modelo más completo del caso de estudio, debido a que presenta un enfoque multiobjetivo.

Debido a la complejidad para resolver el problema PDEST, es necesario buscar mejores métodos de solución. El propósito de este trabajo es desarrollar un Algoritmo Memético para resolver el problema PDEST. Los Algoritmos Meméticos son técnicas de optimización que emplean el conocimiento de un problema específico que se quiere resolver a través de metaheurísticas basadas en población y búsqueda local [9]. Estos algoritmos han presentado buenos resultados cuando se aplican a problemas de optimización combinatoria [10]; sin embargo, en el problema PDEST han sido muy poco explorados [11].

La estructura del presente artículo continua en la sección II con la Descripción del Modelo Matemático empleado,

mientras que en la sección III se detalla la técnica de solución implementada. En la sección IV se analizan los resultados obtenidos. Por último, en la sección V se establecen las conclusiones y recomendaciones de este trabajo de investigación.

II. DESCRIPCIÓN DEL MODELO

El modelo matemático emplea un enfoque multiobjetivo, es decir, aborda el problema en dos partes: el problema de expansión y el problema de operación. En el problema de expansión se plantea una función objetivo que busca minimizar el costo total de inversión de infraestructura eléctrica agregada al sistema. Su formulación matemática [3] se presenta a continuación.

$$\min v = \sum_{t=1}^{T_F} \left(\sum_{(k,l) \in \Omega} \left(\frac{c_{kl}^t \times n_{kl}^t}{(1+d)^{t-1}} + \omega^t \right) \right) \quad (1)$$

donde v representa el costo de inversión total para la expansión del sistema de transmisión para todo el horizonte de planificación ($t = 1: T_F$). c_{kl}^t indica el costo de la adición de un nuevo circuito y n_{kl}^t indica el número de circuitos agregados entre los nodos k - l en la etapa t . ω^t corresponde a los costos de potencia activa y reactiva no servida a la carga en cada etapa t . Ω indica el conjunto de todos los derechos de transmisión disponibles en cada topología. Debido a que el horizonte de planificación se divide en etapas (T_F), el costo de adición de líneas en cada etapa debe actualizarse a su valor presente a través de la tasa de descuento d .

La restricción (2) detalla el número de circuitos que se puede agregar por cada derecho de transmisión; donde, $n^{0,t}$ representa el número de circuitos existentes en la etapa t , mientras que, \bar{n} indica el número máximo de circuitos permitidos.

$$n^{0,t} \leq n^t \leq \bar{n} \quad (n \text{ entero}) \quad (2)$$

El problema de operación proporciona el costo de potencias activa y reactiva no suministradas a la carga durante el horizonte de planificación. La función objetivo (3) incluye los costos de la potencia activa y reactiva no servidas, modelados mediante el uso de generadores ficticios en los nodos de carga.

$$\min \omega^t = \sum_{(k \in A)} \left(\alpha_1^t \times r_{Pk}^t + \frac{\alpha_2^t \times r_{Qk}^t}{(1+d)^{t-1}} \right) \quad (3)$$

donde α_1^t es el costo de la potencia activa no suministrada y r_{Pk}^t es la potencia activa no suministrada en el nodo k y en la etapa t . α_2^t corresponde al costo de la compensación reactiva y r_{Qk}^t es la potencia reactiva necesaria para la compensación en el nodo k y en la etapa t .

El problema de operación tiene como propósito penalizar la función objetivo cuando el sistema no puede abastecer la totalidad de la demanda existente. Este procedimiento permite que el algoritmo de solución converja de manera sencilla, incluso si alguna restricción (4-12) no se satisface; dicha restricción inicialmente será compensada mediante el redespacho de la generación, si no es posible esto, se utilizan los generadores ficticios.

$$P(V, \theta)^t - P_G^t + P_D^t - r_P^t = 0 \quad (4)$$

$$Q(V, \theta)^t - Q_G^t + Q_D^t - r_Q^t - r_Q^{t-1} = 0 \quad (5)$$

$$\underline{P}_G^t \leq P_G^t \leq \bar{P}_G^t \quad (6)$$

$$\underline{Q}_G^t \leq Q_G^t \leq \bar{Q}_G^t \quad (7)$$

$$\underline{r}_P \leq r_P^t \leq \bar{r}_P \quad (8)$$

$$\underline{r}_Q \leq r_Q^t \leq \bar{r}_Q \quad (9)$$

$$\underline{V} \leq V^t \leq \bar{V} \quad (10)$$

$$S^{desde,t} \leq \bar{S} \quad (11)$$

$$S^{hacia,t} \leq \bar{S} \quad (12)$$

Las ecuaciones (4) y (5) representan el balance de potencias activa y reactiva en cada barra del sistema. Cabe destacar que el término r_Q^{t-1} en la ecuación (5), representa la compensación reactiva necesaria en la etapa $t - 1$ y que es agregada en la etapa t . Las restricciones (6) y (7) indican los límites de generación de potencias activa y reactiva en el sistema; en cambio, (8) y (9) son los límites de potencia activa y reactiva que proporcionan los generadores ficticios. Los límites de tensión en (10) se encuentran entre el 95% y 105% de la tensión nominal. \bar{S} en (11) y (12) es un vector con la potencia aparente máxima que puede transferirse a través de las líneas de transmisión.



Fig. 1. Función de costo para la compensación reactiva. [2]

El costo de la compensación shunt emplea un modelo de función lineal por partes como se muestra en la Figura 1, donde los costos siempre serán positivos para cada etapa, ya que cuando existe una compensación capacitiva, el valor del coeficiente α_2^t se modela como positivo, mientras que cuando

la compensación es inductiva su valor se modela como negativo.

III. MÉTODO DE SOLUCIÓN

3.1. Algoritmos Meméticos

Los algoritmos meméticos (MAs) son instrumentos de optimización basados en la combinación de metaheurísticas de población y técnicas de búsqueda local. El término inglés "meme", establecido por Richard Dawkins [14] hace referencia análoga a un gen, pero dentro de procesos de evolución cultural; es decir, un meme contiene información que puede replicarse y transmitirse de individuo a individuo mediante procesos de asimilación e imitación. A menudo los algoritmos meméticos son también definidos como "Algoritmos Híbridos Evolutivos", ya que combinan diversas técnicas metaheurísticas de resolución. En estos algoritmos resaltan la inserción de conocimiento del problema, lo cual permite obtener soluciones más eficientes, ya que se restringe los escenarios de solución. [12]

Debido a que los algoritmos meméticos son técnicas basadas en población, las soluciones candidatas son conocidas como individuos. Los individuos son sometidos a procesos evolutivos de competición y cooperación en búsqueda de soluciones óptimas. Para el caso específico de los algoritmos meméticos, el término individuo es reemplazado por agente, ya que indica una participación activa durante el proceso de búsqueda. Esta característica se debe a la introducción de las técnicas de búsqueda local que mejoran las soluciones encontradas por las técnicas evolutivas. Los MAs utilizan la exploración y explotación del conocimiento que se tiene de un problema para encontrar soluciones de calidad. La exploración se entiende como la localización de zonas del espacio de búsqueda con potenciales soluciones candidatas, mientras que, la explotación se entiende como el refinamiento de esas soluciones candidatas para encontrar soluciones óptimas [13]. El algoritmo memético propuesto en este trabajo combina la metaheurística de Enjambre de Partículas (exploración) y la técnica de búsqueda local Hill Climbing (explotación).

3.1.1. Enjambre de Partículas

El método de búsqueda por Enjambre de Partículas o PSO (Particle Swarm Optimization) [20] es una técnica de optimización basada en el comportamiento colectivo de diversos organismos vivos como bandadas de aves, manadas de animales o bancos de peces. El algoritmo consiste en un grupo de partículas (n partículas) que se desplazan en el espacio de búsqueda con el objetivo de encontrar soluciones óptimas. Cada partícula j ($1 \leq j \leq n$) de m dimensiones, está asociada a un vector de posición X_j^m y a otro de velocidad V_j^m . El modelo de búsqueda empleado se denomina Local

Best Model [21] y divide el enjambre en vecindarios independientes para diversificar el espacio de búsqueda ya que, al utilizar el modelo global, las partículas se ven fuertemente atraídas a la mejor posición encontrada por todo el enjambre, y si esta se localiza en la región de un óptimo local se produce una pérdida en la exploración del espacio de búsqueda, y una rápida convergencia hacia ese óptimo local. Cada partícula posee una topología solución, la cual varía en base a su mejor posición individual y a la mejor posición encontrada por su vecindario, mediante la siguiente formulación:

$$V_j^m(i+1) = x[V_j^m(i) + c_1 R_1(\text{best}p_j^m - X_j^m(i)) + c_2 R_2(\text{best}ve_g^m - X_j^m(i))] \quad (13)$$

$$X_j^m(i+1) = \text{round}[X_j(i) + V_j(i+1)] \quad (14)$$

donde, V_j^m es el vector de velocidad de la partícula j ; X_j^m es la posición de la partícula j ; $\text{best}p_j^m$ es la mejor posición alcanzada por la partícula j y $\text{best}ve_g^m$ es la mejor posición alcanzada por el vecindario g . R_1 y R_2 son números aleatorios en el intervalo cerrado entre 0 y 1. c_1 es un parámetro cognitivo y c_2 es un parámetro social del enjambre; x (chi) es un coeficiente de constricción. [2]. Durante el desarrollo de la metaheurística, las partículas interactúan entre ellas a través de las experiencias propias y de su vecindario, mejorando la experiencia de búsqueda.

3.1.2. Búsqueda Local: Hill Climbing

El éxito de un algoritmo memético está en la armonía entre la búsqueda global y local. La búsqueda local en los algoritmos meméticos tiene un rol fundamental ya que se encarga de explotar todo el conocimiento que se tiene del problema al mejorar las soluciones encontradas por los métodos de búsqueda global. La forma más simple de realizar una búsqueda local es modificando una solución candidata, y luego evaluando esta nueva solución. La nueva solución reemplazará a la solución original si posee mejores aptitudes cuando se evalúa en la función objetivo; este procedimiento es conocido como Hill Climbing o Escalada de Colinas.

En base a la regla de búsqueda que se aplique, podemos definir dos tipos de ejecución para este algoritmo, en la primera se realiza una búsqueda progresiva dentro del vecindario hasta encontrar un óptimo local o hasta cumplir un límite computacional; en la segunda, la búsqueda es estocástica, en la cual el proceso de búsqueda es aleatorio y su límite de ejecución es el límite computacional que se establezca.

En el MA planteado se emplea el algoritmo Hill Climbing de naturaleza estocástica, donde todas las partículas son sometidas al proceso de búsqueda local. Dentro de la búsqueda local se elige un único vecino aleatorio, para luego

ser evaluado y reemplazar a la solución original si mejora su desempeño.

3.2. Implementación del Algoritmo Memético

En la Figura 2, se presenta el diagrama del flujo del algoritmo memético implementado para la resolución del problema PDEST.

Datos de Red: Son datos proporcionados por la topología del sistema eléctrico en cada etapa, donde se tiene el número de derechos de transmisión permitidos o caminos candidatos (m), y la topología base que varía en cada etapa t ($x_{min,t}$).

Configuración de Parámetros: Corresponde al número de etapas (T_F), número máximo de líneas que se pueden agregar por cada derecho de transmisión (x_{max}), número máximo de iteraciones, número máximo de repeticiones, tamaño de la población y número de vecindarios, los cuales son establecidos de acuerdo a la complejidad del sistema eléctrico analizado.

Espacio de Búsqueda: Dada la dimensión del problema (m caminos candidatos) y el número máximo de líneas permitidas (x_{max}), el número máximo de topologías posibles esta dado por: $(x_{max} + 1)^m$.

Soluciones Iniciales: La generación de soluciones iniciales es de manera aleatoria, mediante la siguiente formulación matemática:

$$x_{inicial} = \text{round}[x_{min} + \text{rand}_{0,1}(x_{max} - x_{min})] \quad (15)$$

Herramienta de Evaluación Paralela: Permite evaluar de manera paralela a todo el enjambre utilizando la tecnología multinúcleo de los procesadores modernos. Mediante Parallel Computing Toolbox de Matlab se pueden realizar procesos de cálculo intensivo ya que cada núcleo del procesador trabaja de manera independiente y es capaz de realizar los flujos óptimos de potencia, acelerando el proceso de cálculo.

Evaluación de Costo: Cada uno de los individuos es evaluado por la función objetivo (1) en cada etapa, para obtener el costo de adición de infraestructura eléctrica. Se selecciona una partícula con menor costo por cada vecindario y luego, la menor entre ellas será elegida como la mejor.

Actualización de Posiciones y Velocidades: Primero se actualiza la velocidad de cada miembro del enjambre a través de la ecuación (13); la velocidad máxima que puede tener una partícula es $v_{max,t} = 0.5(x_{max} - x_{min,t})$. Luego, se actualiza las posiciones de cada partícula del enjambre mediante la ecuación (14). Los límites para la posición están entre $x_{min,t}$ y x_{max} .



Fig. 2. Diagrama de flujo del Algoritmo Memético para resolver el PDEST.

Búsqueda Local: En la implementación se optó utilizar la búsqueda local en las primeras iteraciones del algoritmo, debido a que en las pruebas realizadas este criterio mejora la convergencia del programa y evita estancamientos en óptimos locales. [13]

Criterio de Parada: Los criterios para finalizar el programa son el número de iteraciones máximo, número de repeticiones máximo, número de evaluaciones máximo de la función objetivo y el valor de referencia al cual debe converger el programa.

IV. RESULTADOS Y DISCUSIÓN

Los sistemas empleados para la obtención y comparación de resultados son el sistema Garver y el IEEE de 24 nodos, evaluando los escenarios con y sin redespatch.

- Escenario con Redespatch: Permite que los generadores entreguen un mayor nivel de potencia al preestablecido,

dentro de sus límites de generación para satisfacer la demanda y facilitar la convergencia del programa. Si no es posible el redespatch, se utilizan los generadores ficticios para permitir la convergencia del sistema. En este escenario se permite el uso ilimitado de reactivos con un costo de \$0/MVAR. [5]

- Escenario sin Redespatch: La generación de potencia es constante durante todo el proceso de optimización. Este escenario resulta conveniente, debido a que representa la inserción de energías renovables (solar o eólico), donde no es posible el redespatch de energía, ya que estos sistemas poseen un valor fijo de generación de acuerdo a la disponibilidad del recurso natural que empleen. Para este caso se estudia el escenario sin compensación reactiva, asemejándose a un sistema real y aumentando la complejidad en la resolución. [8]

Los parámetros de la metaheurística utilizados para todos los escenarios de prueba son: $x = 0,729$, $c_1 = 2,05$, $c_2 = 2,05$, [19] *número de vecindarios* = 3. Para todo el horizonte de planificación el crecimiento de la demanda será del 60%; en el estudio dinámico dicho crecimiento se divide de acuerdo con el número de etapas que se plantee. La tasa de descuento anual empleada será del 10%, donde el valor presente para la etapa 2 y 3 será de 0.729 y 0.478, respectivamente [24].

Para verificar la confiabilidad y robustez del algoritmo implementado, se recolectaron datos como: tasa de éxito, la cual indica el porcentaje de pruebas que convergieron del número total de experimentos; número de iteraciones promedio, que hace referencia al promedio de iteraciones en las cuales se obtuvo convergencia; número de evaluaciones promedio de la función objetivo, la que indica el promedio de evaluaciones que se realizó a la función objetivo durante un experimento; y tiempo de ejecución, que indica el tiempo total de duración del experimento.

El dispositivo empleado para realizar las simulaciones posee un procesador Intel Core i7-8750H de 2.2 GHz, 16 GB de RAM y el software MATLAB R2020a.

1. Sistema Garver

El sistema Garver está compuesto por 6 nodos, con una demanda máxima de 760 MW y 15 caminos candidatos para la adición de líneas. El número máximo de líneas agregadas entre nodos es de 5; por lo cual, el número de topologías disponibles es de 6^{15} . [4]

Escenario A: Con Redespatch y Reactivos Ilimitados

En el estado estático se utilizó una población de 60 partículas, y un máximo de 100 iteraciones; para el estado dinámico se empleó una población de 120 partículas con un máximo de 200 iteraciones.

Tabla I. Solución del PDEST para el escenario A del sistema Garver.

Barras: Inicial-Final	Líneas Agregadas			
	Estático	Dinámico		
	Etapa 1	Etapa 1	Etapa 2	Etapa 3
4-6	3	2	-	1
3-5	1	-	1	-
Costo (k u.m.)	110	88,92		

Como solución para este escenario, se adiciona 3 líneas entre las barras 4-6, y 1 línea entre las barras 3-5. El costo para una etapa es de 110 mil unidades monetarias (k u.m.). Para el planeamiento dinámico se adicionaron 2 líneas entre las barras 4-6 en la etapa 1, 1 línea entre las barras 3-5 en la etapa 2 y 1 línea entre las barras 4-6 en la etapa 3, con un costo final de 88,92k u.m.

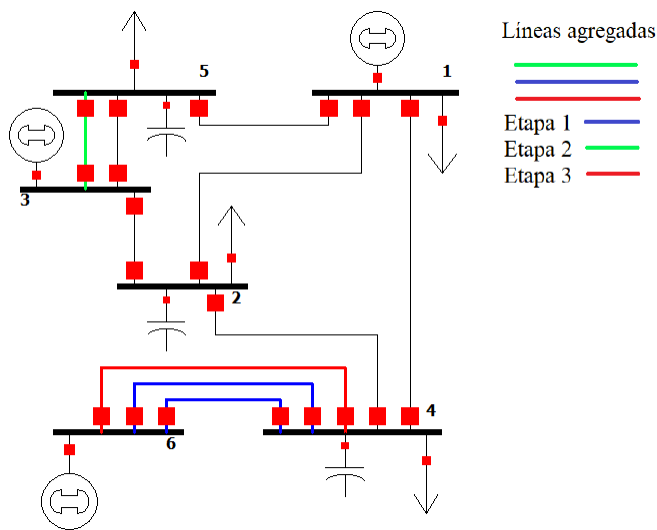


Fig. 3. Líneas agregadas para el escenario A del sistema Garver.

En la Figura 3, se presenta la topología solución del sistema Garver para el escenario A, con las líneas agregadas en cada etapa. La Tabla II detalla la compensación reactiva agregada para el estudio estático y dinámico.

Tabla II. Compensación Reactiva para el escenario A del sistema Garver.

Barras	Estático	Dinámico		
	Etapa 1 (MVAR)	Etapa 1 (MVAR)	Etapa 2 (MVAR)	Etapa 3 (MVAR)
1	0	0	0	0
2	96,69	43,69	20,64	32,72
3	0	0	0	0
4	82,22	54,97	25,89	3,7
5	72,55	45,92	4,75	23
6	0	0	0	0
Total	251,46	144,58	51,28	59,42
		255,28		

En la Tabla III, se expone la robustez y el desempeño del algoritmo en este escenario con una tasa de éxito de 100% y con un número de iteraciones promedio bajo. Debido a la efectividad del algoritmo, los tiempos de convergencia

promedio son de 6,68 segundos para el caso estático y 115,8 segundos para el caso dinámico.

Tabla III. Desempeño del algoritmo memético para el PDEST del sistema Garver en el escenario A.

	Estático	Dinámico
Número de Pruebas	50	50
Éxitos	50	50
Tasa de Éxitos	100%	100%
Número de Iteraciones Promedio	7,14	21,7
Número de Evaluaciones Promedio de la F.O.	428,4	7812
Tiempo Promedio de Convergencia (segundos)	6,679	115,809

Escenario B: Sin Redespacho – Sin Reactivos

En el estado estático se utilizó una población de 60 partículas y un máximo de 100 iteraciones; para el estado dinámico se empleó una población de 120 partículas con un máximo de 150 iteraciones.

Tabla IV. Solución del PDEST para el escenario B del sistema Garver.

Barras: Inicial-Final	Líneas Agregadas			
	Estático	Dinámico		
	Etapa 1	Etapa 1	Etapa 2	Etapa 3
2-5	1	-	-	1
2-6	4	4	-	-
3-5	1	-	1	-
4-6	3	2	-	1
Costo (k u.m.)	261	223,74		

La solución de este escenario establece la adición de 1 línea entre las barras 2-5, 4 líneas entre las barras 2-6, 1 línea entre las barras 3-5, y 3 líneas entre las barras 4-6. El costo para una etapa es de 261k u.m. Para el estado dinámico se adicionaron 4 líneas entre las barras 2-6 y 2 líneas entre las barras 4-6 en la etapa 1, 1 línea entre las barras 3-5 en la etapa 2 y 1 línea entre las barras 2-5 y 4-6 en la etapa 3, con un costo final de 223,74k u.m.

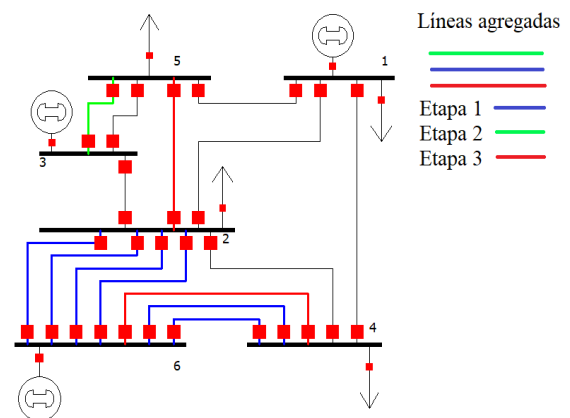


Fig. 4. Líneas agregadas para el escenario B del sistema Garver.

En la Figura 4, se presenta la topología solución del sistema Garver para el escenario B con las líneas agregadas en cada etapa.

Tabla V. Desempeño del algoritmo memético para el PDEST del sistema Garver en el escenario B.

	Estático	Dinámico
Número de Pruebas	50	50
Éxitos	46	46
Tasa de Éxitos	92%	92%
Número de Iteraciones Promedio	17,596	33,774
Número de Evaluaciones Promedio de la F.O.	1055,7	6079,4
Tiempo Promedio de Convergencia (segundos)	21,818	134,397

En la Tabla V, se expone una tasa de éxito de 92% para este escenario, con un número de iteraciones promedio bajo y tiempos de ejecución cortos. En comparación con el escenario con redespacho, el sistema es más complejo, por lo que, se dificulta la resolución y tarda más tiempo en encontrar la solución óptima.

2. Sistema IEEE de 24 nodos

Este sistema está compuesto por 24 nodos, con una demanda máxima de 8550 MW y con 41 caminos candidatos para la adición de líneas. El número máximo de líneas agregadas entre nodos es de 5; por lo cual, el número de topologías disponibles es de 6^{41} . [4]

Escenario A: Con Redespacho – Reactivos Ilimitados

En el caso estático se empleó una población de 60 partículas y un máximo de 100 iteraciones; por otro lado, para el caso dinámico el tamaño de población fue de 180 partículas y un máximo de 250 iteraciones.

Tabla VI. Solución del PDEST para el escenario A del sistema IEEE de 24 nodos.

Barras: Inicial-Final	Líneas Agregadas			
	Estático	Dinámico		
		Etapa 1	Etapa 1	Etapa 2
6-10	1	-	1	-
7-8	2	-	-	2
Costo (k u.m.)	48	26,96		

En este escenario para el caso estático, se debe adicionar 1 línea entre los nodos 6-10 y 2 líneas entre los nodos 7-8, con un costo de 48k u.m. En el estudio dinámico, se debe adicionar 1 línea entre los nodos 6-10 en la etapa 2, mientras que en la etapa 3 se debe agregar 2 líneas entre los nodos 7-8, con un costo total de 26,96k u.m. La Tabla VII detalla la compensación reactiva agregada para el estudio estático y dinámico.

Tabla VII. Compensación Reactiva para el escenario A del sistema IEEE de 24 nodos.

Barras	Estático	Dinámico		
	Etapa 1 (MVAR)	Etapa 1 (MVAR)	Etapa 2 (MVAR)	Etapa 3 (MVAR)
1	0	0	0	0
2	0	0	0	0
3	300,42	108,8	54,59	268,05
4	82,81	58,87	28,18	-20,28
5	75,99	51,24	6,7	79,96
6	0	0	0	0
7	0	0	0	0
8	143,08	89,81	60,03	-10,38
9	22,97	123,75	55,49	-84,19
10	168,6	37,48	19,96	92,36
11	103,76	128,01	69,4	-79,65
12	773,71	125,73	204,2	430,58
13	0	0	0	0
14	0	0	0	0
15	0	0	0	0
16	0	0	0	0
17	0,31	121,594	107,3	-60,5
18	0	0	0	0
19	39,53	121,59	107,31	60,5
20	-10,3	107,55	87,08	-85,47
21	0	0	0	0
22	0	0	0	0
23	0	0	0	0
24	293,02	128,17	27,38	76,79

En la Figura 5, se presenta la topología solución del sistema IEEE de 24 nodos para el escenario A con las líneas agregadas en cada etapa.

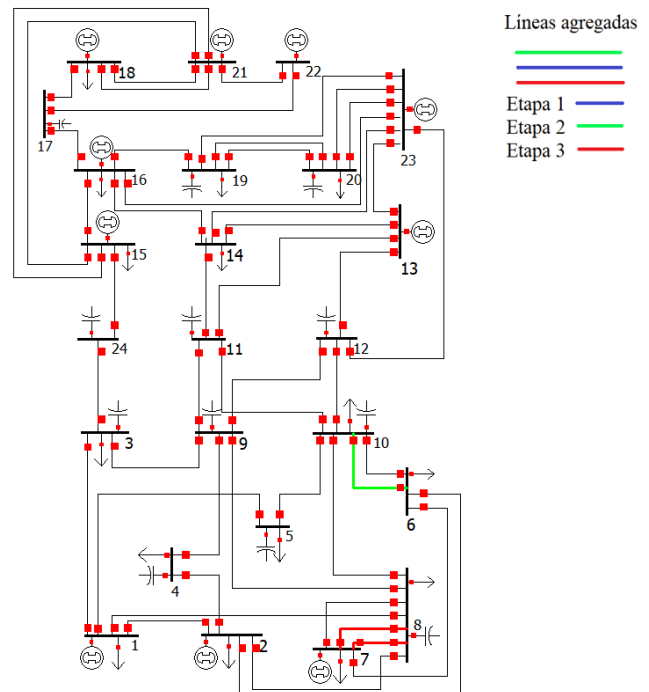


Fig. 5. Líneas agregadas para el escenario A del sistema IEEE 24 nodos.

El desempeño del algoritmo para el escenario A del sistema IEEE de 24 nodos se presenta en la Tabla VIII.

Tabla VIII. Desempeño del algoritmo memético para el PDEST del sistema IEEE de 24 nodos en el escenario A.

	Estático	Dinámico
Número de Pruebas	50	50
Éxitos	43	39
Tasa de Éxitos	86%	78%
Número de Iteraciones Promedio	23,92	50,1
Número de Evaluaciones Promedio de la F.O.	1435,1	27059,78
Tiempo Promedio de Convergencia (segundos)	45,427	800,434

Nuevamente, el algoritmo puede resolver efectivamente el problema con una tasa de éxitos alta e iteraciones promedio bajas; pero con relación al sistema anterior, la tasa de éxitos es menor y los tiempos promedios para convergencia son más altos, lo cual se debe a la complejidad del sistema de 24 nodos con respecto al de 6 nodos.

Escenario B: Sin Redespacho – Sin Reactivos

Este es el escenario más complejo analizado ya que las unidades generadoras no re despachan energía para satisfacer la carga, ni será posible el uso de reactivos para lograr la convergencia del sistema; por lo cual, los cálculos y el número de evaluaciones es más alto, produciendo un gasto computacional mayor. En el caso estático el tamaño de la población fue de 300 partículas y el número de iteraciones máximo de 100. En el caso dinámico, se utilizaron 360 partículas y un número máximo de iteraciones de 200.

Tabla IX. Solución del PDEST para el escenario B del sistema IEEE de 24 nodos.

Barras: Inicial-Final	Líneas Agregadas			
	Estático	Dinámico		
	Etapas	Etapas	Etapas	Etapas
	1	1	2	3
1-3	2	-	2	-
2-4	1	-	1	-
3-24	1	-	-	1
6-10	2	-	1	1
7-8	2	1	-	1
9-11	1	-	1	-
11-13	1	-	1	-
15-24	1	1	-	-
Costo (k u.m.)	445	327,67		

La solución para el caso estático incorpora 2 líneas entre los nodos 1-3, 6-10 y 7-8; 1 línea entre los nodos 2-4, 3-24, 9-11, 11-13 y 15-24, con un costo total de inversión de 445k u.m. Para el caso dinámico, en la etapa 1 se agrega 1 línea entre los nodos 7-8 y 15-24, en la etapa 2 se añaden 2 líneas entre los nodos 1-3 y 1 línea en los nodos 2-4, 6-10, 9-11 y 11-13, en la etapa 3 se agrega 1 línea en los nodos 3-24, 6-10, 7-8, con un costo total de 327,67k u.m.

Tabla X. Desempeño del algoritmo memético para el PDEST del sistema IEEE de 24 nodos en el escenario B.

	Estático	Dinámico
Número de Pruebas	50	10
Éxitos	34	6
Tasa de Éxitos	68%	60%
Número de Iteraciones Promedio	40,49	78,13
Número de Evaluaciones Promedio de la F.O.	12148,57	96615
Tiempo Promedio de Convergencia (segundos)	392,117	2093,45

Debido a la complejidad que presenta el escenario B, al no poseer capacidad de redespacho y uso de reactivos, tanto el número de iteraciones promedio como el tiempo de ejecución son mayores respecto a los obtenidos para el escenario A; sin embargo, la tasa de éxitos es del 68% para el estudio estático y del 60% para el dinámico.

La Figura 6, presenta la topología solución del sistema IEEE de 24 nodos para el escenario B con las líneas agregadas en cada etapa.




Fig. 6. Líneas agregadas para el escenario B del sistema IEEE 24 nodos.

En las Tablas XI y XII, se presenta un análisis comparativo del algoritmo memético con las siguientes metaheurísticas: Firefly y PSO [8], Evolución Diferencial (DE) [7], Optimización Basada en la Biogeografía (BBO) [6], Evolución Diferencial y Aprendizaje Incremental Basado en Población (DE-PBIL) [3] y Procedimiento de Búsqueda Adaptativa Aleatoria Codiciosa (GRASP) [5], las cuales no poseen búsqueda local dentro de su estructura.

Tabla XI. *Desempeño de los algoritmos en el escenario A del sistema Garver para el estudio estático.*

	Tasa de Éxitos	Número de Iteraciones Promedio	Número de Evaluaciones Promedio de la F.O.
Memético	100%	7	428
Firefly	45%	94	5686
PSO	100%	28	1662
DE	100%	24	960
BBO	100%	11	908
DE-PBILc	100%	30	1980

De acuerdo con la Tabla XI, el algoritmo memético brinda un menor número de iteraciones promedio y un menor gasto computacional con la misma eficacia que los otros algoritmos.

 Tabla XII. *Desempeño de los algoritmos en el escenario A del sistema IEEE 24 nodos para el estudio estático.*

	Tasa de Éxitos	Número de Iteraciones Promedio	Número de Evaluaciones Promedio de la F.O.
Memético	86%	24	1435
Firefly	30%	76	7600
PSO	70%	85	6811
DE-PBILc	100%	90	5160
GRASP	93%	44	14051
BBO	80%	57	4520

Nuevamente el algoritmo memético demuestra su eficiencia con respecto al resto de algoritmos en el estudio estático, debido a que llega a converger con mayor rapidez y menor consumo de recursos computacionales, a pesar de que su eficacia no es la óptima.

En las Tablas XIII y XIV, se compara el desempeño del algoritmo memético planteado con la metaheurística DE-PBILc [3] para el estudio dinámico del escenario A en los sistemas Garver e IEEE de 24 nodos.

 Tabla XIII. *Desempeño de los algoritmos en el escenario A del sistema Garver para el estudio dinámico.*

	Tasa de Éxitos	Número de Iteraciones Promedio	Número de Evaluaciones Promedio de la F.O.
Memético	100%	22	7812
DE-PBILc	100%	115	9008

 Tabla XIV. *Desempeño de los algoritmos en el escenario A del sistema IEEE 24 nodos para el estudio dinámico.*

	Tasa de Éxitos	Número de Iteraciones Promedio	Número de Evaluaciones Promedio de la F.O.
Memético	78%	50	27060
DE-PBILc	40%	419	70360

En el estudio dinámico, el algoritmo memético demuestra un mejor desempeño frente al DE-PBILc, debido a que presenta una efectividad alta, con un número promedio de iteraciones y evaluaciones de la función objetivo bajo.

V. CONCLUSIONES

La combinación entre la metaheurística de Enjambre de Partículas (PSO) y la técnica de búsqueda local Hill Climbing en el algoritmo memético implementado, resultó ser eficiente para resolver problemas de PDEST, debido a su alta tasa de éxitos y a la rapidez de resolución con un bajo número de iteraciones.

Para los sistemas Garver e IEEE de 24 nodos, el algoritmo memético obtuvo los planes de expansión óptimos que garantizan un adecuado funcionamiento dentro del horizonte de planificación, demostrando así su confiabilidad.

En comparación con otras metaheurísticas, el algoritmo memético propuesto obtuvo mejor desempeño, reflejado en la alta tasa de éxitos y bajo esfuerzo computacional para los diferentes casos de estudio, demostrando ser un método de solución factible para resolver problemas de planificación de la expansión de los sistemas de transmisión.

Los beneficios del planeamiento dinámico frente al planeamiento estático son: inversión gradual y menor, adición progresiva de infraestructura eléctrica en base al incremento de la demanda, mayor confiabilidad y flexibilidad ante posibles escenarios no contemplados.

Para futuros trabajos de investigación, se recomienda evaluar este algoritmo memético con datos de sistemas eléctricos reales, para encontrar planes de expansión que puedan ser útiles para las empresas dedicadas a la transmisión y distribución de energía eléctrica. Además, se recomienda combinar metaheurísticas evolutivas empleadas en planificación con técnicas de búsqueda local, con el objetivo de obtener algoritmos meméticos más eficientes.

REFERENCIAS

- [1] P. Vilaça Gomes and J. Tomé Saraiva, "A novel efficient method for multiyear multiobjective dynamic transmission system planning", in *International Journal of Electrical Power & Energy Systems*, vol. 100, pp. 10-18, 2018, doi: 10.1016/j.ijepes.2018.02.020.
- [2] S. P. Torres and C. A. Castro, "Expansion planning for smart transmission grids using AC model and shunt compensation," in *IET Generation, Transmission & Distribution*, vol. 8, no. 5, pp. 966-975, May 2014, doi: 10.1049/iet-gtd.2013.0231.
- [3] E. G. Morquecho, S. P. Torres, N. E. Matute, F. Astudillo-Salinas, J. C. Lopez and W. C. Flores, "AC Dynamic Transmission Expansion Planning using a Hybrid Optimization Algorithm," 2020 IEEE PES Innovative Smart Grid Technologies Europe (ISGT-Europe), The Hague, Netherlands, 2020, pp. 499-503, doi: 10.1109/ISGT-Europe47291.2020.9248898.

- [4] S. P. Torres and C. A. Castro, "Specialized differential evolution technique to solve the alternating current model based transmission expansion planning problem", in *International Journal of Electrical Power & Energy Systems*, 2015, doi: 68. 10.1016/j.ijepes.2014.12.016.
- [5] J. C. Cortez Aucapiña. "Planificación óptima multietapa de la expansión de los sistemas de transmisión usando el modelo AC," B.S. Thesis. Cuenca, 2018. [Online]. Available: <http://dspace.ucuenca.edu.ec/handle/123456789/31425J>.
- [6] E. Chillogalli, S. P. Torres and C. A. Castro, "Biogeography based optimization algorithms applied to AC transmission expansion planning," 2017 IEEE PES Innovative Smart Grid Technologies Conference - Latin America (ISGT Latin America), Quito, 2017, pp. 1-6, doi: 10.1109/ISGT-LA.2017.8126682.
- [7] S. P. Torres, R. A. de Araujo, C. A. Castro and J. Pissolato, "Security constrained transmission expansion planning for smart transmission grids based on the AC network model," 2014 IEEE PES Transmission & Distribution Conference and Exposition - Latin America (PES T&D-LA), Medellin, 2014, pp. 1-6, doi: 10.1109/TDC-LA.2014.6955263.
- [8] F. S. Loja, "Comparación de técnicas de creación de soluciones iniciales usando el modelo AC y el algoritmo meta-heurístico Firefly para resolver el problema de planeamiento óptimo de la expansión del sistema de transmisión", 16 pág., Universidad de Cuenca, Cuenca-Ecuador, 2018.
- [9] Neri, Ferrante. Cotta, Carlos. Moscato, Pablo, 2012, "Handbook of Memetic Algorithms", Springer, Studies in Computational Intelligence, Volume 379, pp. 3-52.
- [10] D. Liu, K. C. Tan, C. K. Goh and W. K. Ho, "A Multiobjective Memetic Algorithm Based on Particle Swarm Optimization," in *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, vol. 37, no. 1, pp. 42-50, Feb. 2007, doi: 10.1109/TSMCB.2006.883270.
- [11] H. Kakuta and H. Mori, "A Multi-objective Memetic Algorithm for probabilistic transmission network expansion planning," 2010 IEEE International Conference on Systems, Man and Cybernetics, Istanbul, 2010, pp. 1414-1419, doi: 10.1109/ICSMC.2010.5642468.
- [12] Cotta, Carlos. Moscato, Pablo, 2019, "An Accelerated Introduction to Memetic Algorithms", *Handbook of Metaheuristics, Third Edition*, Springer, Volumen 272, 35 pag.
- [13] Hart, W. Krasnogor, N. Smith, J, 2005, "Recent Advances in Memetic Algorithms", Springer, Studies in Fuzziness and Soft Computing, Volume 166, pp. 11-30.
- [14] Dawkins, R.: *The Selfish Gene*. Clarendon Press, Oxford (1976)
- [15] Sun Y., Wang Z., van Wyk B.J. (2013) Local and Global Search Based PSO Algorithm. In: Tan Y., Shi Y., Mo H. (eds) *Advances in Swarm Intelligence*. ICSI 2013.
- [16] *Lecture Notes in Computer Science*, vol 7928. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-38703-6_15
- [17] R. Kumar, S. Tyagi, M. Sharma, "Memetic Algorithm: Hybridization of Hill Climbing with Selection Operator", in *International Journal of Soft Computing and Engineering (IJSCE)*, vol. 3, no. 2, pp. 140-145, May. 2013. ISSN: 2231-2307
- [18] Chi-Keong Goh, Yew-Soon Ong, and Kay Chen Tan, "Multi-Objective Memetic Algorithms", Springer, *Studies in Computational Intelligence*, Volume 171, pp. 3-49.
- [19] C. H. Lai, F. Magoulés, "Particle Swarm Optimisation: Classical and Quantum Perspectives", *Numerical Analysis and Scientific Computing*, CRC Press Taylor & Francis Group, vol. 1, pp. 23-104, 2012.
- [20] J. Kennedy and R. Eberhart, "Particle swarm optimization," *Proceedings of ICNN'95 - International Conference on Neural Networks*, Perth, WA, Australia, 1995, pp. 1942-1948 vol.4, doi: 10.1109/ICNN.1995.488968.
- [21] P. N. Suganthan, "Particle swarm optimiser with neighbourhood operator," *Proceedings of the 1999 Congress on Evolutionary Computation-CEC99* (Cat. No. 99TH8406), Washington, DC, USA, 1999, pp. 1958-1962 Vol. 3, doi: 10.1109/CEC.1999.785514.
- [22] Conejo, Antonio. Baringo, Luis, 2018, "Power System Operations", Springer, Springer International Publishing AG 2018, 165-194. <https://doi.org/10.1007/978-3-319-69407-8>.
- [23] Wood, Allen. Wollenberg, Bruce. Sheblé, Gerald, 2014, "Power Generation, Operation and Control", Wiley, Third edition, 350-386.
- [24] A. H. Escobar, R. A. Gallego and R. Romero, "Multistage and coordinated planning of the expansion of transmission systems," in *IEEE Transactions on Power Systems*, vol. 19, no. 2, pp. 735-744, May 2004, doi: 10.1109/TPWRS.2004.825920.
- [25] L. Gallego, L. Garces, M. Rahmani and R. Romero, "High-Performance Hybrid Algorithm to Solve Transmission Network Expansion Planning", in *IET Generation, Transmission & Distribution*, vol. 11, no. 5, pp. 1111-1118, December 2016, doi: 10.1049/iet-gtd.2016.0511.