



**UNIVERSIDAD DE CUENCA
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA ELÉCTRICA
MAESTRÍA EN SISTEMAS ELÉCTRICOS DE POTENCIA**

**PLANEAMIENTO DE LA EXPANSIÓN DE LOS
SISTEMAS ELÉCTRICOS DE TRANSMISIÓN
UTILIZANDO EL MODELO AC RESUELTO
MEDIANTE ALGORITMOS EVOLUTIVOS**

Autor: Agustín Peñaherrera Wilches

Director Principal: Prof. Dr. Ing. Santiago Torres Contreras

**GRADO ACADÉMICO:
MAGISTER EN SISTEMAS ELÉCTRICOS DE POTENCIA**

CUENCA

Diciembre 2015



Resumen

El Planeamiento de la Expansión de la Transmisión (PET) consiste en determinar todas las modificaciones necesarias de la infraestructura del sistema eléctrico de transmisión de energía, es decir, establecer cuáles deberían ser las ampliaciones o refuerzos, a fin de permitir el equilibrio entre la demanda prevista y el suministro de energía eléctrica, minimizando la inversión a lo largo del horizonte de planeamiento. El PET es un problema de optimización o programación no lineal entera-mixta, no convexo y de explosión combinatoria. Debido a la complejidad del problema, se requiere de mayor investigación en técnicas de optimización que busquen la solución del problema de manera eficiente. En este trabajo de investigación, el centro de atención del estudio fue el uso de métodos heurísticos y meta heurísticos de optimización basados en Algoritmos Evolutivos (AE) aplicados a la solución del problema del PET estático, empleando el modelo AC. Los algoritmos de implementación usados fueron la Programación Evolutiva (PE), la Estrategia Evolutiva (EE) y la Estrategia Evolutiva Modificada (EEM). Se evaluaron los desempeños de los algoritmos de forma gradual para diferentes escenarios del sistema de prueba de Garver y se aplicó el algoritmo de mejor rendimiento sobre el sistema de la IEEE de 24 barras. Su desempeño final fue comparado de manera relativa con otros algoritmos heurísticos disponibles en la bibliografía.

Palabras clave: Planeamiento de la expansión de la transmisión, modelo AC, optimización, meta heurística, algoritmos evolutivos, planificación estática, compensación de reactivos.



Abstract

The Transmission Expansion Planning (TEP) problem consists of determining all the changes needed in the transmission system infrastructure (i.e. additions and reinforcements) in order to allow the balance between the projected demand and the power supply, at minimum investment along the planning horizon. The TEP is a large scale, mixed-integer, non-linear and non-convex problem. Due to the complexity of the problem requires greater research in optimization techniques that seek a solution of the problem in an efficient manner. Therefore, more optimization techniques must be explored to solve the TEP problem in an efficient way. In this research work, the focus was on the study of the optimization heuristic and metaheuristics based on Evolutionary Algorithms (EA) applied to the problem of static TEP, using the AC model. The algorithms used were: Evolutionary Programming (EP), Evolutionary Strategy (EE) and Modified Evolutionary Strategy (MEE). The performance of the algorithms were evaluated in a gradual manner for different scenarios of the Garver test system. Then the better performance algorithm was applied to solve the TEP problem using the IEEE 24-bus system. Its final performance was compared with other heuristic algorithms available in the reference literature.

Keywords: Transmission expansion planning, AC model, optimization, metaheuristic, evolutionary algorithms, static planning, reactive power compensation.



Índice de Contenidos

Lista de Figuras.....	6
Lista de Tablas	9
Capítulo 1	15
1 Introducción.....	15
1.1 Objetivos.....	18
1.2 Estructura de contenidos	18
2 Planeamiento de la expansión del sistema eléctrico de transmisión.....	20
2.1 Introducción	20
2.2 Modelamiento Matemático	22
2.2.1 Modelo de Transportes.....	23
2.2.2 Modelo DC.....	28
2.2.3 Modelos Híbridos.....	30
2.2.4 Modelo Lineal Disyuntivo	33
2.2.5 Modelo AC.....	35
2.3 Técnicas de solución	40
2.3.1 Algoritmos heurísticos	40
2.3.2 Métodos clásicos de optimización	41
2.3.3 Técnicas Meta heurísticas	42
3 Optimización mediante Algoritmos Evolutivos (AE): Programación Evolutiva (PE), Estrategia Evolutiva (EE), Estrategia Evolutiva Modificada (EEM).....	45
3.1 Introducción	45
3.2 Programación Evolutiva (PE).....	47
3.2.1 Programación Evolutiva Continua (PEC).....	47
3.2.2 Programación Evolutiva Discreta (PED).....	49
3.3 Estrategias Evolutivas (EE).....	50
3.3.1 Estrategia Evolutiva ($1 + 1$)	51
3.3.2 Estrategia Evolutiva ($\mu + 1$)	52
3.3.3 Estrategias Evolutivas ($\mu + \lambda$) y (μ, λ)	53
3.3.4 Estrategias Evolutivas ($\mu, \kappa, \lambda, \rho$).....	54
3.3.5 Estrategias Evolutivas Auto adaptativas.....	54
3.3.6 Estrategias Evolutivas Auto adaptativas Modificadas (EEM)	56
3.3.7 Estrategias Evolutivas. Conclusión.....	65
3.4 Implementación de PE, EE y EEM.....	66
3.4.1 Formulación matemática	67
3.4.2 Implementación del algoritmo de solución mediante Programación Evolutiva (PE)	74
3.4.3 Implementación del algoritmo de solución mediante Estrategias Evolutivas (EE) auto adaptativas	83
3.4.4 Implementación del algoritmo de solución mediante Estrategias Evolutivas auto adaptativas modificadas (EEM)	88



4 Pruebas y resultados	93
4.1 Planeamiento Clásico	94
4.1.1 Sistema Garver de 6 barras	94
4.1.1.1. Garver con Re despacho (aplicando PE y EE)	95
4.1.1.2. Garver sin Re despacho (aplicando EE).....	104
4.1.1.3. Garver sin Re despacho (aplicando EEM).....	111
4.1.2 Sistema IEEE de 24 barras	119
4.1.2.1. Sistema IEEE de 24 barras con re despacho (aplicando EEM).....	120
4.1.2.2. Sistema IEEE de 24 barras sin re despacho (aplicando EEM).....	121
5 Conclusiones y trabajos posteriores.....	126
5.1 Conclusiones	126
5.2 Propuestas para trabajos futuros	127
Referencias Bibliográficas	128



Lista de Figuras

2.1	Sistema Inicial de 3 barras.....	.26
3.1	Pseudocódigo del algoritmo PEC para minimizar la función $f(x)$	47
3.2	Pseudocódigo del algoritmo meta PEC para minimizar la función $f(x)$	48
3.3	Pseudocódigo del algoritmo PED para minimizar la función $f(x)$	48
3.4	Pseudocódigo que describe la estrategia evolutiva $(1 + 1)$	50
3.5	Pseudocódigo que describe la estrategia evolutiva $(\mu + 1)$	51
3.6	Pseudocódigo que describe las estrategias evolutiva $(\mu + \lambda)$ (μ, λ)	52
3.7	Pseudocódigo que describe las estrategias evolutivas auto adaptativa $(\mu + \lambda)$ (μ, λ)	55
3.8	Pseudocódigo que describe la estrategia “Torneo de Selección”.....	60
3.9	Pseudocódigo que describe la estrategia de “Sobreselección”.....	61
3.10	Función de costos para la compensación de reactivos.....	72
3.11	Diagrama de Flujo. Programación Evolutiva Continua sin adaptación.....	76
3.12	Diagrama de Flujo. Programación Evolutiva Continua con adaptación.....	80
3.13	Diagrama de Flujo. Estrategia Evolutiva autoadaptativa.....	85
3.14	Diagrama de Flujo. Estrategia Evolutiva auto adaptativa Modificada.....	90
4.1	Sistema de Garver. Topología Base.....	93
4.2	Solución del Sistema Garver con redespacho.....	98
4.3	Representación de la convergencia de PE sin adaptación para 10 ensayos. Garver AC con compensación shunt \$0/Mvar. Población de 100 individuos.....	99
4.4	Representación de la convergencia de PE con adaptación para 10 ensayos. Garver AC con compensación shunt \$0/Mvar. Población 120 individuos.....	99
4.5	Representación de la convergencia de EE auto adaptativa para 10 ensayos. Garver AC con compensación shunt \$0/Mvar. Población 100 individuos.....	100
4.6	Representación de la convergencia de PE sin adaptación para 10 ensayos. Garver AC sin compensación shunt. Población 120 individuos.....	100
4.7	Representación de la convergencia de PE con adaptación para 10 ensayos. Garver AC sin compensación shunt. Población 120 individuos	101
4.8	Representación de la convergencia de EE auto adaptativa para 10 ensayos. Garver AC sin compensación shunt. Población 120 individuos	101
4.9	Representación de la convergencia de EE auto adaptativa para 10 ensayos. Población 80 individuos. Garver AC sin re despacho, sin límite de reactivos. Garver_AC-a1.....	104
4.10	Representación de la convergencia de EE auto adaptativa para 10 ensayos. Población 100 individuos. Garver AC sin re despacho, sin límite de reactivos. Garver_AC-a1.....	105



4.11 Representación de la convergencia de EE auto adaptativa para 10 ensayos.120 individuos. Garver AC sin re despacho, sin límite de reactivos. Garver_AC-a1.....	105
4.12 Representación de la convergencia de EE auto adaptativa para 10 ensayos. Población 80 individuos. Garver AC sin re despacho, sin compensación shunt. Garver_AC-a2.....	106
4.13 Representación de la convergencia de EE auto adaptativa para 10 ensayos. Población 100 individuos. Garver AC sin re despacho, sin compensación shunt. Garver_AC-a2.....	106
4.14 Representación de la convergencia de EE auto adaptativa para 10 ensayos. Población 120 individuos. Garver AC sin re despacho, sin compensación shunt. Garver_AC-a2.....	107
4.15 Representación de la convergencia de EE auto adaptativa para 10 ensayos. Población 80 individuos. Garver AC sin re despacho, compensación shunt US\$1000/MVar. Garver_AC-a3.....	107
4.16 Representación de la convergencia de EE auto adaptativa para 10 ensayos.100 individuos. Garver AC sin re despacho, compensación shunt US\$1000/MVar. Garver_AC-a3.....	108
4.17 Representación de la convergencia de EE auto adaptativa para 10 ensayos. Población120 individuos. Garver AC sin re despacho, compensación shunt US\$1000/MVar. Garver_AC-a3.....	108
4.18 Representación de la convergencia de EEM auto adaptativa para 10 ensayos. Población 120 individuos. Torneo de selección al 20%. Garver AC sin re despacho. Sin límite de reactivos. Garver_AC-a1.....	112
4.19 Representación de la convergencia de EEM auto adaptativa para 10 ensayos. Población 120 individuos. Torneo de selección al 40%. Garver AC sin re despacho. Sin límite de reactivos. Garver_AC-a1.....	112
4.20 Representación de la convergencia de EEM auto adaptativa para 10 ensayos. Población 100 individuos. Torneo de selección al 60%. Garver AC sin re despacho. Sin límite de reactivos. Garver_AC-a1.....	113
4.21 Representación de la convergencia de EEM auto adaptativa para 10 ensayos. Población 120 individuos. Sobre selección distribución exponencial. Garver AC sin re despacho. Sin límite de reactivos. Garver_AC-a1.....	113
4.22 Representación de la convergencia de EEM auto adaptativa para 10 ensayos. Población 100 individuos. Torneo de selección al 60%. Garver AC sin re despacho. Sin compensación shunt. Garver_AC-a2.....	115
4.23 Representación de la convergencia de EEM auto adaptativa para 10 ensayos. Población 100 individuos. Torneo de selección al 60%. Garver AC sin re despacho. Con compensación shunt US\$1000/MVar. Garver_AC-a3.....	115
4.24 Solución del Sistema Garver sin redespacho.....	116
4.25 Sistema IEEE de 24 barras – topología base.....	117
4.26 Representación de la convergencia de EEM auto adaptativa para 10 ensayos. Población 100 individuos. Torneo de selección al 60%. IEEE 24 nodos AC con re despacho. Sin límite de reactivos.....	119



- 4.27 Representación de la convergencia de EEM auto adaptativa para 10 ensayos. Población 100 individuos. Torneo de selección al 60%. IEEE 24 nodos AC sin re despacho. Sin límite de reactivos. IEEE24_AC_a1..... **122**
- 4.28 Representación de la convergencia de EEM auto adaptativa para 10 ensayos. Población 100 individuos. Torneo de selección al 60%. IEEE 24 nodos AC sin re despacho. Sin compensación shunt. IEEE24_AC_a2..... **122**



Lista de Tablas

2.1	Etapas del Planeamiento de la expansión de la transmisión.....	21
4.1	Desempeño de Programación Evolutiva sin adaptación (PE). Modelo de Garver AC sin restricción de reactivos. Max 300 iteraciones.....	94
4.2	Desempeño de Programación Evolutiva con adaptación (PE). Modelo de Garver AC sin restricción de reactivos. Max 300 iteraciones	95
4.3	Desempeño de Estrategia Evolutiva auto adaptativa (EE). Modelo de Garver AC sin restricción de reactivos. Max 300 iteraciones.....	95
4.4	Desempeño de Programación Evolutiva sin adaptación (PE). Modelo de Garver AC sin compensación de reactivos. Max 300 iteraciones.....	95
4.5	Desempeño de Programación Evolutiva con adaptación (PE). Modelo de Garver AC sin compensación de reactivos. Max 300 iteraciones.....	96
4.6	Desempeño de Estrategia Evolutiva auto adaptativa (EE). Modelo de Garver AC sin compensación de reactivos. Max 300 iteraciones	96
4.7	Desempeño de Estrategia Evolutiva auto adaptativa (EE). Modelo de Garver AC sin re despacho, sin límite de reactivos US\$0/MVar. Max 100 iteraciones. Garver_AC-a1.....	103
4.8	Desempeño de Estrategia Evolutiva auto adaptativa (EE). Modelo de Garver AC sin re despacho, sin compensación shunt. Max 100 iteraciones. Garver_AC-a2.....	103
4.9	Desempeño de Estrategia Evolutiva auto adaptativa (EE). Modelo de Garver AC sin re despacho, sin límite de reactivos US\$1000/MVar. Max 100 iteraciones. Garver_AC-a3.....	104
4.10	Desempeño de Estrategia Evolutiva Modificada (EEM). Selección aleatoria de características del 20% de los mejores individuos como mejores padres. Modelo de Garver AC sin re despacho, sin límite de reactivos US\$0/MVar. Max 50 iteraciones. Garver_AC-a1.....	110
4.11	Desempeño de Estrategia Evolutiva Modificada (EEM). Selección aleatoria de características del 40% de los mejores individuos como padres. Modelo de Garver AC sin re despacho, sin límite de reactivos US\$0/MVar. Max 50 iteraciones. Garver_AC-a1.....	110
4.12	Desempeño de Estrategia Evolutiva Modificada (EEM). Selección aleatoria de características del 60% de los mejores individuos como padres. Modelo de Garver AC sin re despacho, sin límite de reactivos US\$0/MVar. Max 50 iteraciones. Garver_AC-a1.....	110
4.13	Desempeño de Estrategia Evolutiva Modificada (EEM). Selección aleatoria mediante la distribución de probabilidad exponencial de los individuos pertenecientes a la generación de padres. Modelo de Garver AC sin re despacho, sin límite de reactivos US\$0/MVar. Max 50 iteraciones. Garver_AC-a1.....	111
4.14	Desempeño de Estrategia Evolutiva Modificada (EEM). Selección aleatoria de características del 60% de los mejores individuos como padres. Modelo de Garver AC	



sin re despacho, sin compensación shunt. Max 50 iteraciones. Garver_AC-a2.....	114
4.15 Desempeño de Estrategia Evolutiva modificada (EEM). Selección aleatoria de características del 60% de los mejores individuos como padres. Modelo de Garver AC sin re despacho, sin límite de reactivos US\$1000/MVar. Max 50 iteraciones. Garver_AC-a3.....	114
4.16 Desempeño de Estrategia Evolutiva modificada (EEM). Selección aleatoria de características del 60% de los mejores individuos como padres. Modelo IEEE 24 nodos, sin re despacho, sin límite de reactivos	118
4.17 Desempeño de Estrategia Evolutiva modificada (EEM). Selección aleatoria de características del 60% de los mejores individuos como padres. Modelo IEEE 24 nodos, sin re despacho, sin límite de reactivos. IEEE24_AC-a1.....	121
4.18 Desempeño de Estrategia Evolutiva modificada (EEM). Selección aleatoria de características del 60% de los mejores individuos como padres. Modelo IEEE 24 nodos, sin re despacho, sin compensación shunt. IEEE24_AC-a2.....	121
4.19 Desempeño de Estrategia Evolutiva modificada (EEM). Selección aleatoria de características del 60% de los mejores individuos como padres. Modelo IEEE 24 nodos, sin re despacho, con compensación shunt \$100/Mvar. IEEE24_AC-a3.....	121



Yo, **Agustín Peñaherrera Wilches**, autor de la tesis “**Planeamiento de la expansión de los sistemas eléctricos de transmisión utilizando el modelo AC resuelto mediante algoritmos evolutivos**”, reconozco y acepto el derecho de la Universidad de Cuenca, en base al Art. 5 literal c) de su Reglamento de Propiedad Intelectual, de publicar este trabajo por cualquier medio conocido o por conocer, al ser este requisito para la obtención de mi título de **Magister en Sistemas Eléctricos de Potencia**. El uso que la Universidad de Cuenca hiciere de este trabajo, no implicará afección alguna de mis derechos morales o patrimoniales como autor.

Cuenca, 27 de Noviembre de 2015

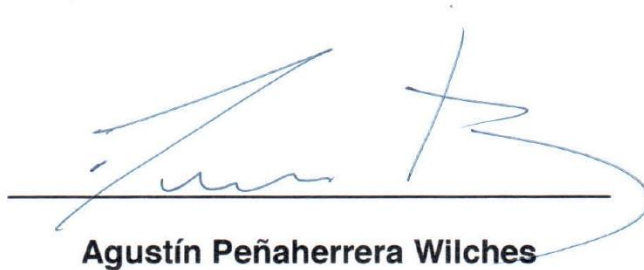
Agustín Peñaherrera Wilches

C.I: 0102260882



Yo, **Agustín Peñaherrera Wilches**, autor de la tesis **“Planeamiento de la expansión de los sistemas eléctricos de transmisión utilizando el modelo AC resuelto mediante algoritmos evolutivos”**, certifico que todas las ideas, opiniones y contenidos expuestos en la presente investigación son de exclusiva responsabilidad de su autor.

Cuenca, 27 de Noviembre de 2015



Agustín Peñaherrera Wilches

C.I: 0102260882



Dedicatoria

A mi esposa María Soledad, a mis hijos Sofía y Emilio, por las horas y días durante los cuales mi ausencia fue reemplazada por fe y apoyo incondicional. Este resultado es esfuerzo compartido.



Agradecimiento

A la Universidad de Cuenca, por haberme indicado el sendero del Conocimiento y acogido en sus aulas todos estos años. A los profesores de esta Maestría por su generosidad y entusiasmo, de manera especial al Prof. Dr. Ingeniero Santiago Torres Contreras, que sin su apoyo y guía incondicional este proyecto no hubiera sido posible, sobre todo por su entrañable amistad.



Capítulo 1

Introducción

Un Sistema Eléctrico de Potencia (SEP) tiene el propósito de suministrar energía eléctrica a los usuarios finales bajo condiciones de eficiencia económica, confiabilidad y calidad. Para ello es importante asegurar en todo momento que la generación cubra el crecimiento continuo de la demanda así como las pérdidas de potencia propias del sistema. El Sistema de Transmisión de Energía juega un rol muy importante, pues permite que los nuevos proyectos de generación puedan evacuar la energía producida hacia los centros de consumo. Con esta perspectiva, uno de los problemas importantes en Ingeniería Eléctrica de Potencia trata de resolver la Expansión del Sistema de Transmisión (de aquí en adelante PET *Planeamiento de la Expansión de la Transmisión*). Esta actividad, en su forma más básica, consiste en determinar la cantidad de elementos de red a implementar en el futuro cumpliendo algunas restricciones técnicas al mismo tiempo que se busca minimizar la inversión necesaria para el crecimiento del sistema.

El PET busca determinar, de entre un conjunto de circuitos candidatos, los que se necesitan construir para un horizonte de tiempo dado, de manera que las restricciones de operación sean satisfechas y la inversión sea la mínima posible. Los horizontes del PET son variables en cada país o región pero en promedio obedecen a una clasificación básica: largo plazo (20 años), mediano plazo (10 años) y corto plazo (5 años). En Ecuador se trabaja con un horizonte de planificación de 10 años para el largo plazo. Por otra parte el abordaje puede ser multietapa (dinámico) o estático. La planificación estática procura conocer el circuito óptimo para el abastecimiento de la demanda en un único y determinado horizonte de planeamiento, es decir, no se tiene interés en saber cuándo se deben instalar los

elementos necesarios para completar el circuito, sino más bien, en encontrar la topología final óptima para una futura situación definida. Por otro lado, si se consideran múltiples años para una estrategia de expansión óptima durante todo el período, se habla entonces de una planificación dinámica o multietapa; en este caso, el modelo debe contener restricciones de tiempo para considerar la expansión a lo largo de los años de tal manera que el valor presente de los costos a lo largo del período sea minimizado mientras todas las restricciones planteadas son atendidas.

La planificación de la transmisión es un problema complejo de toma de decisiones a corto, mediano y largo plazo. Una de las principales dificultades en la resolución de este problema es que lleva a un elevado número de alternativas de solución, debido a que su naturaleza combinatorial representa un problema no convexo con múltiples óptimos locales. En general, usando algoritmos de optimización matemáticos, este problema se plantea como uno de Programación No lineal Entera Mixta (PNLEM). Alternativamente existe la posibilidad de usar algoritmos de optimización heurísticos para encontrar soluciones apropiadas con un moderado esfuerzo de cálculo.

El enfoque para resolver el problema TEP utiliza dos componentes: el modelo de red y el método de solución.

Es usual abordar la representación de la red mediante modelos matemáticos relajados que usan solamente una parte de los elementos de un sistema eléctrico. En la literatura especializada, los modelos simplificados que se utilizan para resolver el problema de planeamiento son: modelo de transporte, modelo DC, modelos híbridos y el modelo lineal disyuntivo. [69]. Tradicionalmente el modelo utilizado es el DC [2], [6], [10], sin embargo trabajos recientes han sido desarrollados utilizando el modelo AC [7], [9], [62], [64] el cual permite la incorporación de restricciones propias de este modelo tales como: los límites de potencia reactiva de los generadores, límites de tensión en barras, límites de flujos de potencia aparente por las líneas. Además, este modelo permite la inclusión valorada de la compensación shunt; esto contribuye a que la solución del PET se ajuste de una manera más realista a las necesidades de expansión y condiciones de operación del SEP.

Desde la perspectiva de las técnicas de solución, los métodos heurísticos o meta heurísticos han dado muestras de ser bastante eficientes para conseguir la solución de este tipo de problemas con un costo computacional razonable. Meta heurísticas con un alto nivel de desempeño y adaptabilidad al problema están los *Algoritmos Evolutivos*(AE) entre los cuales están la *Optimización por Enjambre de Partículas* y sus variantes [9], [12], [13], [32], [33], [50], [51], [52], [53], [54], [55], [56], [57], [58], [59], [60], [61], [62]. Otros AE sobre los cuales se han presentado trabajos de investigación están los *Algoritmos Genéticos* [5], [8], [17], [26], [27]. Dentro de la misma categoría tenemos los *Algoritmos de Recocido Simulado* [28], [43], [44]. También algoritmos evolutivos utilizados son la *Búsqueda Tabú* [29], [30], [46], [47]. Una aplicación de AE para solucionar el problema del PET mediante algoritmos de búsqueda por *Colonia de Hormigas* lo encontramos en las referencias [49], [68].

Por la particular capacidad de adaptación de los AE a la solución del problema del PET, se ha decidido en el presente trabajo de investigación abordar la exploración del desempeño de tres técnicas adicionales de optimización heurística y meta heurística respectivamente, estas son: la Programación Evolutiva [PE], las Estrategias Evolutivas [EE] y las Estrategias Evolutivas Modificadas [EEM].

En el presente trabajo se estudiará el problema del PET estático a largo plazo, utilizando el modelo AC, resuelto mediante AE. Para ello se analizará el desempeño de tres variantes de los algoritmos evolutivos indicados precedentemente, los cuales se aplicarán a los sistemas de prueba Garver de 6 nodos y al sistema IEEE de 24 nodos. No se consideran condiciones de contingencia así como tampoco son incorporadas restricciones de seguridad dinámica.

La implementación se realizará mediante Matlab®[62] reutilizando código existentes de trabajos previos. Para resolver el flujo óptimo de potencia para cada solución candidata se utilizará el paquete de software Matpower®[34].

En el problema se plantean los siguientes datos de entrada: la red de transmisión del modelo de pruebas con una topología base de circuitos para el inicio del período, generación y demanda esperadas para el final del período en cada una de las barras, costos de generación, costos de adiciones de líneas, restricciones y

parámetros del modelo. Los resultados son la topología de la red y los costos de la misma para cada escenario estudiado.

1.1 Objetivos.

El objetivo general es desarrollar y aplicar tres tipos de algoritmos evolutivos: Programación Evolutiva (PE), Estrategias Evolutivas (EE) y Estrategias Evolutivas Modificadas (EEM) para resolver el PET usando el modelo AC. Los objetivos específicos están descritos a continuación:

- Estudiar el desempeño de las variantes de AE, que serán utilizados para obtener la solución del problema del PET estática de largo plazo usando el modelo AC.
- Analizar la robustez de los AE utilizados considerando diferentes escenarios: con y sin re despacho, con y sin costos de compensación shunt.
- Efectuar una comparación del rendimiento obtenido con los algoritmos evolutivos para solucionar el PET frente a otros algoritmos con meta heurísticas de similar naturaleza empleados para resolver el mismo problema, utilizados en trabajos de investigación anteriores.
- Reutilizar el código existente en Matlab® de trabajos de investigación anteriores, MATPOWER® como herramienta para solucionar el flujo óptimo de potencia AC, para obtener la solución del problema de PET y adaptar los AE a una estructura de programación predefinida, con el propósito de aportar a la librería de código abierto. Esta servirá para continuar con los futuros trabajos académicos de investigación con nuevas y mejoradas técnicas de solución.

1.2 Estructura de contenidos

La estructura de contenidos es la siguiente:

Capítulo 2: Se presenta una breve revisión del estado del arte sobre el planeamiento de la expansión de la transmisión, una descripción de los diferentes modelos matemáticos utilizados para representar la red



eléctrica y las técnicas de solución encontradas en la literatura especializada.

Capítulo 3: Se presenta los AE correspondientes a la Programación Evolutiva, Estrategias Evolutivas y Estrategias Evolutivas Modificadas, utilizados en este trabajo de investigación para resolver el PET. Se describen los pseudocódigos básicos.

Capítulo 4: Se exponen los resultados de los algoritmos aplicados sobre los sistemas de prueba en diferentes escenarios. Se efectúa un análisis comparativo de desempeño entre ellos a lo largo del proceso de investigación. Finalmente se hace una contrastación referencial entre el algoritmo de mejor desempeño de este trabajo y alguna técnica de optimización meta heurística desarrollada en la bibliografía de referencia donde se haya usado el modelo AC para resolver el PET.

Capítulo 5: Se presentan las conclusiones y consideraciones finales.

Capítulo 2

Planeamiento de la expansión del sistema eléctrico de transmisión

2.1 Introducción

“El problema del planeamiento de la expansión a largo plazo consiste en encontrar una solución óptima de expansión del sistema eléctrico, lo que significa que se debe ampliar la capacidad de la red eléctrica a través de la instalación de líneas de transmisión con la finalidad que el sistema opere de forma adecuada para el horizonte de tiempo especificado” [4], [6], [70].

Es importante tener una idea clara cuando hablamos de horizontes de planeamiento. En la Tabla 2.1 se presenta una información resumen que permite entender el alcance de las etapas de planeamiento asociadas a cada período de planificación:

Como se había descrito en el capítulo 1, el abordaje para el PET puede ser estático o dinámico (multietapa). En el análisis dinámico se consideran múltiples etapas donde además de determinar donde es necesario ampliar la infraestructura de transmisión, se debe contestar a la pregunta de cuando hacerlo. Existen pocos trabajos sobre planeamiento multietapa, algunos de los cuales se pueden encontrar en [3], [4], [14], [15], [16], [17], [22]. Para el caso estático, se define una sola etapa u horizonte de tiempo para la cual la instalación de nueva infraestructura o el refuerzo de infraestructura existente son necesarias. En el presente trabajo de investigación se considerará el PET estático a largo plazo.

El problema PET es de naturaleza compleja e involucra programación no lineal entera mixta. (PNLEM) [69]. El enfoque para su resolución contiene dos elementos: el primero relacionado con el modelo matemático para representar la red de

transmisión y el segundo correspondiente a la técnica de solución aplicada al modelo.

Tabla 2.1 Etapas del Planeamiento de la expansión de la transmisión

HORIZONTE DE PLANEAMIENTO DE LA EXPANSIÓN DE LA TRANSMISIÓN	PERÍODO	OBJETIVO
LARGO PLAZO	20 años	Incorporación de líneas troncales asociadas a la aparición de nuevos proyectos de generación.
MEDIANO PLAZO	10 años	Se determinan mayores detalles sobre líneas de interconexión. Usualmente son desarrollos de sistemas regionales.
CORTO PLAZO	5 años	Estudios y ajustes finales a la alternativa de expansión determinada en los horizontes anteriores. Ej.: Compensación reactiva, estudios dinámicos (estabilidad transitoria, estabilidad de tensión), estudios de cortocircuito, confiabilidad, etc. A este nivel se corren flujos de carga utilizando el modelo AC que permitirá evaluar la compensación de reactivos

Lo datos de entrada son: la configuración base o red básica del sistema de prueba al inicio del período de análisis, los costos involucrados con cada inversión de la solución candidata, así como el plan de expansión de la generación y la demanda al finalizar el período de estudio. Los datos de salida corresponden a la topología de red que representa la solución candidata final con los menores costos de inversión “posibles” y que al mismo tiempo garantiza el cumplimiento de las restricciones operacionales. [1], [2].

En la primera parte de este capítulo se efectuará una revisión de los principales modelos matemáticos usados para representar la red eléctrica de transmisión, con

un especial enfoque en el modelo AC el cual será utilizado en el desarrollo de este trabajo de investigación. En la segunda parte se analizarán el estado del arte de las diferentes técnicas de solución utilizadas para el PET.

2.2 Modelamiento Matemático

Un modelo matemático es una representación de un problema de la vida real para lo cual se usa la formulación matemática como herramienta para implementar dicha representación. En el modelo se relacionan diversas variables de decisión que pueden asumir formas y tipos muy variados. Esta representación puede ser exacta o simplificada. Es usual que mientras más exacta es la representación más complejo se vuelve el proceso para encontrar una solución. Debe existir, por tanto, un compromiso entre el modelamiento matemático adoptado y la técnica de solución del problema analizado. Usualmente, en problemas complejos el uso de herramientas computacionales resulta mandatorio. Dentro de este contexto y con la aparición de procesadores de alto rendimiento, los modelos y técnicas de solución de este tipo de problemas, que anteriormente resultaban poco prácticos, ahora cobran relevancia y despiertan interés en su estudio e implementación. Este es el caso del Planeamiento de la Expansión de la Transmisión [69].

En el planeamiento de sistemas eléctricos de transmisión, el problema de la vida real consiste en definir qué equipos se deben adicionar y donde colocarlos para que partiendo de una topología actual se llegue a la topología óptima que permita satisfacer la demanda y conectar los nuevos centros de generación al sistema eléctrico. En la actualidad se utilizan varios modelos matemáticos para representar el sistema de transmisión, entre ellos: el modelo DC, el modelo de transporte, el modelo híbrido no lineal y el modelo disyuntivo, los cuales comparten una característica común de ser modelos simplificados de la red.

Usando los modelos anteriores, nos lleva a tratar el PET como un problema de optimización matemático que involucra relaciones algebraicas lineales y/o no lineales con variables de decisión entera y real. En el campo de la Investigación de Operaciones la solución de este tipo de problemas se aborda mediante técnicas de Programación No Lineal Entera Mixta (PNLEM), sin embargo cuando se presenta una explosión combinatorial como en el caso del PET, el problema podría volverse

de difícil manejo computacional o incluso el problema podría no converger. Por lo dicho, el desarrollo de algoritmos de solución basados en técnicas meta heurísticas resulta de especial interés debido a las posibilidades de los mismos para lidiar con este tipo de problemas.

Tradicionalmente, el modelo más utilizado para abordar el PET a largo plazo es el DC, el cual, como veremos más adelante es una versión simplificada del modelo completo AC. Los flujos de potencia activa obtenidos en el modelo DC son consistentes o cercanos a los encontrados al utilizar el modelo completo AC. Este hecho es uno de los elementos que ha popularizado su uso. Varias técnicas de solución utilizando el modelo DC las encontramos en [6], [18].

El modelo DC utiliza las dos leyes de Kirchhoff para la representación matemática de la red, por otro lado los modelos de transporte e híbrido son versiones aproximadas del modelo DC.

Por otro lado, el modelo AC representa un modelo completo, que de principio presenta ciertas dificultades en su uso especialmente para tratar sistemas no conexos o que tienen barras aisladas. Para tratar esta dificultad se han desarrollado alternativas de tratamiento del problema al utilizar el modelo AC. Una metodología interesante lo encontramos en [62]. Esta estrategia será utilizada para el presente trabajo de investigación.

A continuación se presentan y se explican de manera conceptual los diferentes modelos utilizados y su alcance conforme se describe en [69].

2.2.1 Modelo de Transportes

El modelo de transporte fue una primera propuesta sistemática de usar programación lineal [1], [15] para resolver el problema del PET y fue presentado por Garver [19] como una alternativa para superar los grandes problemas que surgen al usar el modelo de flujo de carga AC, el cual es empleado para operación. Garver sugiere que utilizar modelos más relajados permitirá encontrar topologías o configuraciones atractivas de solución. Con esto en mente, propone satisfacer únicamente la primera ley de Kirchhoff, la cual especifica que la sumatoria de los flujos de potencia que entran a una barra del sistema debe ser igual a la sumatoria de los flujos de potencia que salen de la misma, adicionalmente el modelo considera

las restricciones de los generadores, los cuales deberán operar dentro de sus límites especificados.

La formulación matemática de este modelo adopta la siguiente forma:

$$= \sum_{(k,l) \in \Omega} c_{kl} n_{kl} \quad \text{Min } v \quad (2.1)$$

s.a.

$$Sf + g = d \quad (2.2)$$

$$|f_{kl}| \leq (n_{kl}^0 + n_{kl}) \bar{f}_{kl} \quad (2.3)$$

$$0 \leq g \leq \bar{g} \quad (2.4)$$

$$0 \leq n_{kl} \leq \bar{n}_{kl} \quad (2.5)$$

$$n_{kl} \text{ Entero}$$

$$f_{kl} \text{ Irrestricto}$$

$$(k, l) \in \Omega$$

Donde:

v : Inversión total debido a adiciones de circuitos en el sistema

c_{kl} : Costo de un circuito que puede ser adicionado en el camino kl

n_{kl} : Número de circuitos adicionados en el camino kl

n_{kl}^0 : Número de circuitos en la topología base

\bar{n}_{kl} : Número máximo de circuitos que pueden ser adicionados en el camino kl

f_{kl} : Flujo de potencia total a través de los circuitos en el camino kl

f : Vector de flujos con elementos f_{kl}

\bar{f}_{kl} : Capacidad de transmisión de un circuito en el camino kl

S : Matriz de incidencia de ramas del sistema eléctrico

g : Vector de generación cuyos elementos, g_i , corresponden al nivel de generación en la barra i

\bar{g} : Vector de máxima generación en las barras generadoras

d : Vector de demanda

Ω : Conjunto de caminos del sistema

La ecuación (2.1) representa la función objetivo, que establece la minimización de las inversiones debido a la incorporación de nuevas líneas de transmisión a lo largo del horizonte de planeamiento.

Las restricciones de la ecuación (2.2) corresponden a la primera ley de Kirchhof, lo que genera una ecuación por cada barra del sistema. Las restricciones de la ecuación (2.3) representan los límites de capacidad de transmisión del flujo de potencia de los circuitos (líneas y transformadores). Las restricciones en la ecuación (2.4) representan los límites de generación de potencia activa. En la ecuación (2.5) se representan las restricciones de la cantidad de circuitos que puede ser adicionado entre dos barras consecutivas.

Desde el ámbito de la investigación de operaciones, esta modelación corresponde a un problema de programación lineal entera mixta (PLEM). Encontrar una solución a este problema no siempre es simple, pues depende del tamaño del sistema bajo análisis. La restricción de tener adición entera de líneas n_{kl} genera una mayor complejidad al problema. Considerar que estas características son aprovechadas para desarrollar varios tipos de algoritmos para resolver el PET cuando se usa el modelo de transportes.

La ventaja del modelo de transporte radica en que es capaz de resolver tanto redes conexas como aquellas altamente aisladas, debido a que el modelo no ocupa las reactancias de los circuitos. Una desventaja radica en el hecho que la solución presentada puede estar muy distante de la solución del modelo DC considerado como el modelo ideal. Aplicaciones de este modelo lo encontramos en las siguientes referencias: [20], [21], [22], [23], [24].

A continuación se ilustra mediante un ejemplo la aplicación de este modelo para un sistema de transmisión de 3 barras y 3 circuitos. Este y otros ejemplos para los diferentes modelos lo podemos encontrarlos en la referencia [69]. Los datos del problema ejemplo a continuación:

Costo de los circuitos: $c_{12} = 3, c_{13}=2$ y $c_{23} = 2$ US\$

Suceptancias: $\gamma_{12} = \frac{1}{3}, \gamma_{13} = \frac{1}{2}$ y $\gamma_{23} = \frac{1}{2}$ (p.u. para una base de 100 MW).

Flujo máximo por línea: $\bar{f}_{12} = 35$ MW, $\bar{f}_{13} = 40$ MW y $\bar{f}_{23} = 40$ MW.

Número máximo de adiciones permitidas por camino: $\bar{n}_{12} = \bar{n}_{13} = \bar{n}_{23} = 2$.

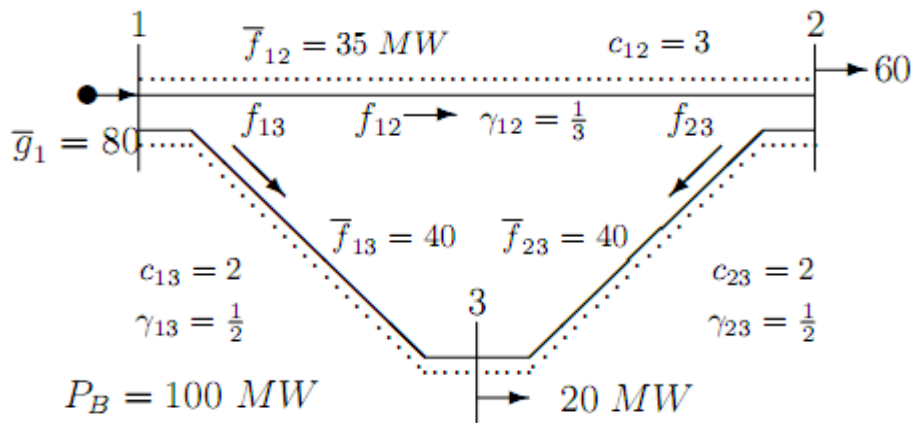


Figura 2.1 Sistema inicial de 3 barras.

En el ejemplo el sentido de los flujos ha sido escogido de manera arbitraria, puesto que la solución mostrará el sentido correcto de los flujos. Las ecuaciones correspondientes a la primera ley de Kirchhoff, aplicadas para cada barra, considerando positivo el sentido de flujo que entra a la barra son:

$$\text{Barra 1:} \quad -f_{12} - f_{13} + g_1 = 0$$

$$\text{Barra 2:} \quad f_{12} - f_{23} - 0,6 = 0$$

$$\text{Barra 3:} \quad f_{13} + f_{23} - 0,2 = 0$$

Las inecuaciones correspondientes a los límites de capacidad de transmisión producen las siguientes relaciones:

$$\text{Circuito 1-2:} \quad |f_{12}| \leq 0,35(1 + n_{12})$$

$$\text{Circuito 1-3:} \quad |f_{13}| \leq 0,40(1 + n_{13})$$

$$\text{Circuito 2-3:} \quad |f_{23}| \leq 0,40(1 + n_{23})$$

La restricción sobre la capacidad de generación produce la siguiente restricción:

$$\text{Barra de generación 1: } 0 \leq g_1 \leq 0,80$$

Las restricciones sobre el número máximo de adiciones permitidas en cada camino candidato producen las siguientes restricciones:

$$\text{Camino 1-2: } 0 \leq n_{12} \leq 2$$

$$\text{Camino 1-3: } 0 \leq n_{13} \leq 2$$

$$\text{Camino 2-3: } 0 \leq n_{23} \leq 2$$

La función objetivo asume la siguiente forma: $\min v = 3n_{12} + 2n_{13} + 2n_{23}$

Así, para el ejemplo, el modelamiento matemático asume la siguiente forma:

$$\min v = 3n_{12} + 2n_{13} + 2n_{23}$$

s.a.

$$-f_{12} - f_{13} + g_1 = 0$$

$$f_{12} - f_{23} = 0,6$$

$$f_{13} + f_{23} = 0,2$$

$$|f_{12}| \leq 0,35(1 + n_{12})$$

$$|f_{13}| \leq 0,40(1 + n_{13})$$

$$|f_{23}| \leq 0,40(1 + n_{23})$$

$$0 \leq g_1 \leq 0,80$$

$$n_{12} \in \{0,1,2\}$$

$$n_{13} \in \{0,1,2\}$$

$$n_{23} \in \{0,1,2\}$$

$$f_{12}, f_{13}, f_{23} \text{ Irrestringidos}$$

Las incógnitas del problema son: $v, n_{12}, n_{13}, n_{23}, f_{12}, f_{13}, f_{23}, g_1$. Esto es equivalente a decir que en el problema del PET, se deben encontrar la cantidad de líneas o circuitos por derecho de vía que son requeridos para un sistema específico, calculando los flujos de potencia y la generación necesaria para abastecer la demanda. En ejemplo se ha aplicado el modelo de transporte en donde se aplica únicamente la primera ley de Kirchhoff, se consideran las restricciones de flujos por

líneas, las restricciones de generación y no se consideran las restricciones de tensión en barras y potencia reactiva.

2.2.2 Modelo DC

Este modelo ha sido utilizado ampliamente en el problema de planeamiento estático de sistemas de transmisión [4], [6], [15]. Este modelo utiliza en su formulación las dos leyes de Kirchhoff, para nodos y para ramas [18]. Por lo indicado, este modelo matemático es un problema de PNLEM.

La formulación matemática presentada a continuación tiene una ligera variante en relación al modelamiento básico. Esta estrategia se utiliza con el propósito de facilitar la aplicación de las técnicas de solución. La modificación utilizada es la incorporación de generadores artificiales en todas las barras de carga, lo que desde el punto de vista matemático representa un incremento en las incógnitas mas no afecta la estructura del modelo en sí. Para que la formulación básica como la formulación modificada sean equivalentes, todas las variables correspondientes a los generadores artificiales deben ser igual a cero [69].

La formulación matemática del modelo DC modificado asume la siguiente forma:

$$\text{Min } v = \sum_{(k,l) \in \Omega} c_{kl} n_{kl} + \alpha \sum_{p \in \Gamma} r_p \quad (2.6)$$

s.a.

$$Sf + g + r = d \quad (2.7)$$

$$f_{kl} - \gamma_{kl}(n_{kl}^0 + n_{kl})(\theta_k - \theta_l) = 0 \quad (2.8)$$

$$|f_{kl}| \leq (n_{kl}^0 + n_{kl}) \bar{f}_{kl} \quad (2.9)$$

$$0 \leq g \leq \bar{g}$$

(2.10)

$$0 \leq r \leq d$$

(2.11)

$$0 \leq n_{kl} \leq \bar{n}_{kl}$$

(2.12)

$$n_{kl} \text{ Entero}$$

$$f_{kl} \text{ e } \theta_l \text{ irrestrictos}$$

$$(k, l) \in \Omega$$

Donde:

v : Inversión total debido a la adición de nuevos circuitos.

c_{kl} : Costo de un circuito que puede ser adicionado en el camino kl

γ_{kl} : Susceptancia de un circuito en el camino kl

n_{kl} : Número de circuitos adicionados

n_{kl}^0 : Número de circuitos en la topología base

\bar{n}_{kl} : Número máximo de circuitos que pueden ser adicionados en el camino kl

f_{kl} : Flujo de potencia total a través de los circuitos en el camino kl

f : Vector de flujos con elementos f_{kl} dados entre la barra k y la barra l

\bar{f}_{kl} : Capacidad de transmisión de potencia de un circuito en el camino kl

S : Matriz de incidencia de ramas del sistema eléctrico

θ_l : Ángulo de fase en la barra l

θ_k : Ángulo de fase en la barra k adyacente a la barra l

g : Vector de generación cuyos elementos, g_i , corresponden al nivel de generación en la barra i

\bar{g} : Vector de generación máxima

d : Vector de demanda

r : Vector de generadores artificiales

α : Factor de penalidad para los generadores artificiales

Ω : Conjunto de caminos del sistema

Γ : Conjunto de todas las barras p en donde existe demanda.

Como se indicó en el párrafo anterior, la función objetivo (2.6) se encuentra ligeramente modificada en relación al modelo DC básico, debido a la incorporación de una nueva variable de decisión. Estas variables son llamados generadores artificiales o de corte de carga r_p asociadas a un factor de penalidad α , el cual es suficientemente grande para convertir poco atractivas las propuestas de inversión con valores de r_p diferentes de cero. La inclusión de estas variables artificiales en la función objetivo permite una solución siempre factible al problema. Cuando se escoge un valor de α suficientemente grande, la solución final deberá ser tal que todos los valores de los generadores artificiales sean iguales a cero, con lo que se

garantiza la equivalencia del modelamiento en relación a su formulación básica [1], [4], [15].

El conjunto de restricciones (2.7) representa las ecuaciones equivalentes a la primera ley de Kirchhoff, una para cada barra del sistema. Las restricciones (2.8) representan las ecuaciones correspondientes a la segunda ley de Kirchhoff dentro de la red equivalente DC del sistema, aquí se puede verificar que el flujo de potencia activa entre dos nodos adyacentes de la red es igual al producto de la diferencia del ángulo de las tensiones en las barras multiplicado por la susceptancia equivalente de la línea o líneas en ese camino o derecho de vía. Las restricciones (2.9) representan los límites de capacidad de transmisión de los circuitos o ramas que conectan a cada nodo adyacente considerando el flujo de potencia bidireccional. Las restricciones (2.10) y (2.11) representan los límites de generación tanto para los generadores existentes como para los generadores artificiales. La restricción (2.12) representa los circuitos adicionados en cada derecho de vía o camino candidato. Las variables f_{kl} e θ_l que representan al flujo neto entre barras adyacentes y los valores del ángulo de tensión en barras son irrestrictas. Las variables correspondientes al número de circuitos por derecho de vía n_{kl} deben ser enteras. Las aplicaciones de este modelo pueden ser verificadas en [1], [4], [6], [9], [17], [20], [22], [25-33], entre otros.

Otras formulaciones equivalentes a este modelo pueden ser encontrados en [69].

La presencia de la segunda ley de Kirchhoff transforma el modelo de Transportes anterior en un problema de programación no lineal entera mixta (PNLEM), como lo es el modelo DC. Además mantiene una característica de explosión combinatorial. Existen diversas técnicas para abordar la solución de este tipo de problemas, como el método de punto interior que se encuentra ya implementado en el software MATPOWER® [34].

2.2.3 Modelos Híbridos

El modelo híbrido es una combinación entre el modelo de transportes y el modelo DC [18]. En este se considera la aplicación de la segunda ley de Kirchhoff como restricción, pero no lo es para todos los circuitos. Se pretende que en este modelo se encuentren soluciones lo más próximas a las obtenidas por el modelo DC, pero sin

incrementar la complejidad de este último. El modelo híbrido según su estructura de programación se clasifica en lineal o no lineal.

Modelo Híbrido no Lineal

En este modelo se efectúan las siguientes consideraciones:

- La parte del sistema eléctrico que corresponde a los caminos de la configuración base debe satisfacer las dos leyes de Kirchhoff.
- La parte del sistema eléctrico donde aparecen los caminos nuevos o donde no existen circuitos de la configuración, debe satisfacer únicamente la primera ley de Kirchhoff.

Por lo indicado el modelo híbrido es una combinación del modelo DC y del modelo de transportes. Visto de otra manera, el modelo híbrido debe satisfacer la primera ley de Kirchhoff para todas las barras del sistema y la segunda ley únicamente para los caminos existentes en la configuración base. Esta modelación fue utilizada en [21].

El modelo híbrido busca combinar las ventajas de la aplicación del modelo de transportes para trabajar con redes no conexas y aproximarse a las soluciones óptimas encontradas por el modelo DC. Sin embargo trabajar con el modelo híbrido no lineal significa mantener aún un nivel de complejidad similar que trabajar directamente con el modelo DC. Por lo indicado, esta versión del modelo híbrido se utiliza con el propósito de ayudar a la solución del modelo DC [4], [6], [18].

La estructura matemática del modelo híbrido asume la siguiente forma:

$$\text{Min } v = \sum_{(k,l) \in \Omega} c_{kl} n_{kl} \quad (2.13)$$

s.a.

$$Sf + g = d \quad (2.14)$$

$$f_{kl} - \gamma_{kl}(n_{kl}^0 + n_{kl})(\theta_k - \theta_l) = 0 \quad \forall (k, l) \in \Omega_1 \quad (2.15)$$

$$|f_{kl}| \leq (n_{kl}^0 + n_{kl}) \bar{f}_{kl} \quad (2.16)$$

$$0 \leq g \leq \bar{g} \quad (2.17)$$

$$0 \leq n_{kl} \leq \bar{n}_{kl} \quad (2.18)$$

n_{kl} Entero
 f_{kl} Irrestringido
 θ_l Irrestringido $\forall l \in \Omega_3$

Donde:

Ω : Conjunto de caminos del sistema eléctrico

Ω_1 : Conjunto de circuitos existentes en la configuración base

Ω_2 : Conjunto de circuitos correspondientes a los nuevos caminos

Ω_3 : Conjunto de barras que forman parte de la configuración base

θ_l : Ángulo de tensión en las barras existentes de la configuración base

Modelo Híbrido Lineal

Un enfoque más simplificado lo constituye el modelo híbrido lineal, porque el problema resultante es uno de Programación Lineal Entera Mixta (PLEM). En este modelamiento, las nuevas adiciones de circuitos en caminos existentes o por nuevos caminos, deben cumplirse únicamente la primera ley de Kirchhoff. Es un modelamiento equivalente a considerar dos redes superpuestas: la configuración base que cumple las dos leyes de Kirchhoff y los nuevos circuitos adicionados que cumplirán únicamente la primera ley de Kirchhoff. Es una versión más relajada del modelo híbrido lineal [18]. El modelo híbrido lineal es un problema de programación lineal entera mixta (PLEM).

El modelamiento matemático del modelo híbrido lineal tiene la siguiente estructura:

$$\text{Min } v = \sum_{(k,l) \in \Omega} c_{kl} n_{kl} \quad (2.19)$$

s.a.

$$Sf' + S_0f^0 + g = d \quad (2.20)$$

$$f_{kl}^0 - \gamma_{kl}n_{kl}^0(\theta_k - \theta_l) = 0 \quad \forall (k, l) \in \Omega_1 \quad (2.21)$$

$$|f_{kl}^0| \leq n_{kl}^0 \bar{f}_{kl} \quad \forall (k, l) \in \Omega_1 \quad (2.22)$$

$$|f'_{kl}| \leq n_{kl} \bar{f}_{kl} \quad \forall (k, l) \in \Omega_2 \quad (2.23)$$

$$0 \leq g \leq \bar{g} \quad (2.24)$$

$$0 \leq n_{kl} \leq \bar{n}_{kl} \quad (2.25)$$

n_{kl} Entero

f_{kl}^0 e f'_{kl} irrestrictos

θ_l Irrestricto $\forall l \in \Omega_3$

Donde:

S : Matriz de incidencia de ramas del sistema completo

S_0 : Matriz de incidencia de ramas del sistema existente en la configuración base

f_{kl}^0 : Vector dos flujos en los circuitos existentes de la configuración base

f'_{kl} : Vector de flujos de los circuitos adicionados

Aplicaciones de este modelaje se encuentran en: [20], [22], [35].

2.2.4 Modelo Lineal Disyuntivo

El modelo lineal disyuntivo corresponde a una transformación del modelo DC. Este proceso se consigue insertando un parámetro M de valor muy grande y se basa en el hecho que siempre es posible transformar un problema cuadrático de variables binarias y reales en un problema lineal con variables binarias y reales, a través de la separación de los términos cuadráticos en relaciones lineales. Este modelo permite encontrar soluciones óptimas que son las mismas que las del modelo DC [4].

La modelación matemática del modelo lineal disyuntivo tiene la siguiente forma:

$$+ \alpha \sum_{p \in \Gamma} r_p$$

$$\text{Min } v = \sum_{(k,l) \in \Omega} c_{kl} y_{kl} \quad (2.26)$$

s.a.

$$S_0 f^0 + S_1 f^1 + g + r = d \quad (2.27)$$

$$f_{kl}^0 - \gamma_{kl}^0 (\theta_k - \theta_l) = 0 \quad \forall (k, l) \in \Omega_1 \quad (2.28)$$

$$f_{kl}^1 - \gamma_{kl}^1 (\theta_k - \theta_l) \leq M(1 - y_{kl}) \quad (2.29)$$

$$f_{kl}^1 - \gamma_{kl}^1 (\theta_k - \theta_l) \geq -M(1 - y_{kl}) \quad (2.30)$$

$$|f_{kl}^0| \leq \bar{f}_{kl} \quad (2.31)$$

$$|f_{kl}^1| \leq \bar{f}_{kl} y_{kl} \quad (2.32)$$

$$0 \leq g \leq \bar{g} \quad (2.33)$$

$$0 \leq r \leq d \quad (2.34)$$

$$y_{kl} \in \{0,1\} \quad \forall (k, l) \in \Omega_T$$

f_{kl}^0 , f_{kl}^1 e θ_l irrestrictos

Donde:

y_{kl} : Variable binaria igual a 1 si se adiciona el circuito al camino $k - l$, caso contrario es igual a 0

S_0 : Matriz de incidencia de ramas de los circuitos existentes en la configuración base con flujos f^0

S_1 : Matriz de incidencia de ramas de los circuitos candidatos considerados como variables binarias y con flujos f^1

γ_{kl}^0 : Susceptancia equivalente de los circuitos existentes en la configuración base

Una ventaja del modelo lineal disyuntivo está relacionada con el hecho que es lineal, lo que permite aplicar algoritmos con propiedades de convergencia teóricas interesantes. Las desventajas, por otra parte, se relacionan con el incremento de la dimensión del problema con la introducción de variables binarias y con la escogencia adecuada del valor del parámetro M , que pasa a ser un factor de orden práctico que podría complicar la resolución del problema [4], [6], [18]. Este modelamiento fue aplicado en: [20], [36], [37].

2.2.5 Modelo AC

El uso de modelos de red exactos como lo es el modelo AC para el problema de PET tenía restricciones en cuanto a representar las redes no conexas, es decir redes que poseen barras desconectadas del sistema principal, lo que desde el punto de vista operativo se traduce en una dificultad matemática de convergencia durante el cálculo de flujos de carga, una parte esencial para solucionar el problema del PET. Esta es una de las razones por las que se han utilizado modelos más relajados, como los descritos hasta ahora, dejando el modelo AC para el análisis de la operación del sistema de transmisión. Sin embargo, el uso de los modelos relajados hacía que, muchas de las veces, para completar el trabajo de planeamiento relacionadas con: ubicación de reactivos, análisis de estabilidad de tensión, estudios de estabilidad transitoria, etc., se tomen decisiones empíricas que muchas de las veces no corresponden a soluciones óptimas integrales del problema del PET. Con esta perspectiva y la aparición de métodos y técnicas de solución más eficientes, así como el incremento de la potencia de cálculo de los nuevos computadores, el uso del modelo AC para el PET se ha vuelto interesante y demanda la ejecución de trabajos de investigación que produzcan mayor cantidad de información en cuanto a su aplicación y el desempeño de las técnicas de solución asociadas.

El modelo DC, de uso común en diversos estudios de PET, hace que el planeador de los sistemas, tenga que ajustar o modificar el plan con el propósito de cumplir con las restricciones impuestas por el comportamiento no lineal de los flujos de potencia activa y reactiva que ocurren en las redes eléctricas reales. Este problema se hace cada vez más complicado con el creciente incremento de grandes cantidades de energía no renovable que tienen limitadas posibilidades de control.

[62]. Esto, aparejado a que el uso de modelos DC podría producir resultados subestimados o sobreestimados en los valores de inversión, hace que utilizar el modelo AC para resolver el problema de PET sea un requerimiento que permita tratar estos tópicos, muy poco estudiados, de manera eficiente.

Pocos trabajos han sido desarrollados utilizando el modelo AC [7], [9], [62], [64]. De entre las referencias indicadas, [7] presenta un algoritmo constructivo heurístico (CHA) para resolver el problema, donde los costos de compensación shunt no son considerados. Recientemente en [71] se ha propuesto un modelo de optimización tipo caja negra, que de cierta manera, permiten la compensación shunt, el cual de cierta manera es una generalización del algoritmo heurístico constructivo de optimización donde únicamente generación no despachable es manejada. En [62] se propone una formulación AC más completa la cual toma en consideración la compensación shunt, es capaz de manejar la generación no despachable de manera eficiente, hace una generalización de la estrategia de corte de carga usada en el modelo DC modificado y utiliza como método de solución el eficaz algoritmo de optimización de Enjambre de Partículas con resultados muy interesantes en cuanto a su comportamiento y rendimiento incluso en sistemas de alto nivel de complejidad como lo es el Sistema Brasileño de 87 barras, el cual tiene una cantidad similar de líneas al modelo IEEE de 118 barras. Los resultados de la última bibliografía citada, han sido motivadores para usar el modelo AC en la presente investigación y los algoritmos evolutivos como técnicas de solución

En este trabajo se propone un enfoque estático para la PET, basado en un esquema de corte de carga, usando el modelo AC y tomando en cuenta la compensación shunt con las variantes de enfoque presentadas en [62].

Una propuesta de uso del modelo AC para la solución del problema del PET, fue efectuada en [7] y asume la siguiente forma matricial:

$$\min v = \mathbf{c}^T \mathbf{n} \quad (2.35)$$

s.a.

$$\mathbf{P}(\mathbf{V}, \boldsymbol{\theta}, \mathbf{n}) - \mathbf{P}_G + \mathbf{P}_D = 0 \quad (2.36)$$

$$\mathbf{Q}(\mathbf{V}, \boldsymbol{\theta}, \mathbf{n}) - \mathbf{Q}_G + \mathbf{Q}_D = 0 \quad (2.37)$$

$$\underline{\mathbf{P}}_G \leq \mathbf{P}_G \leq \overline{\mathbf{P}}_G \quad (2.38)$$

$$\underline{Q}_G \leq Q_G \leq \overline{Q}_G \quad (2.39)$$

$$\underline{V} \leq V \leq \overline{V} \quad (2.40)$$

$$(N + N^0)S^{from} \leq (N + N^0)\overline{S} \quad (2.41)$$

$$(N + N^0)S^{to} \leq (N + N^0)\overline{S} \quad (2.42)$$

$$0 \leq n \leq \overline{n} \quad (2.43)$$

n Entero

θ Irrestringido

Donde:

c, n : Representan el vector de costos del circuito y el vector de circuitos añadidos al sistema base respectivamente.

N, N^0 : Son matrices diagonales que contienen la primera el vector n de circuitos añadidos, y la segunda contiene los circuitos de la configuración base.

v : Es la inversión asociada a añadir circuitos a la configuración base.

\overline{n} : Es el vector que contiene el máximo número de circuitos que puede ser añadido

θ : Es el vector de ángulos de fase.

P_G, Q_G : Son los vectores de generación de potencia activa y reactiva.

P_D, Q_D : Son los vectores de demanda de potencia activa y reactiva.

V : Es el vector de magnitudes de tensión.

$\overline{P}_G, \overline{Q}_G$: Son los vectores de máximo límite de generación de potencia activa y reactiva.

\overline{V} : Vector de límite máximo de magnitudes de tensión. Usualmente corresponde al 105% del valor nominal.

$\underline{P}_G, \underline{Q}_G$: Son los vectores de mínimo límite de generación de potencia activa y reactiva.

\underline{V} : Vector de límite mínimo de magnitudes de tensión. Usualmente corresponde al 95% del valor nominal.

S^{from}, S^{to} : Son los vectores de flujo de potencia aparente en ambos extremos de una rama.

\overline{S} : Vector de límite máximo de transporte de potencia aparente por las ramas.

En el modelo anterior, se considera la minimización del costo asociado únicamente con la expansión de las líneas de transmisión y se asume que las fuentes de generación están construidas para el horizonte de planificación. Un modelo más general debería tomar en cuenta los costos de generación llegando a ser un modelo matemático aún más complejo.

Las ecuaciones (2.36) y (2.37) representan las ecuaciones convencionales de flujo de potencia AC, las cuales consideran el vector \mathbf{n} (el número de circuitos), como las variables del problema. Los elementos de los vectores $\mathbf{P}(\mathbf{V}, \boldsymbol{\theta}, \mathbf{n})$ y $\mathbf{Q}(\mathbf{V}, \boldsymbol{\theta}, \mathbf{n})$ corresponden a las potencias activas y reactivas del modelo lo cuales se calculan de acuerdo a las siguientes ecuaciones:

$$P_i(\mathbf{V}, \boldsymbol{\theta}, \mathbf{n}) = V_i \sum_{j \in N} V_j [G_{ij}(\mathbf{n}) \cos \theta_{ij} + B_{ij}(\mathbf{n}) \sin \theta_{ij}] \quad (2.44)$$

$$Q_i(\mathbf{V}, \boldsymbol{\theta}, \mathbf{n}) = V_i \sum_{j \in N} V_j [G_{ij}(\mathbf{n}) \sin \theta_{ij} - B_{ij}(\mathbf{n}) \cos \theta_{ij}] \quad (2.45)$$

Donde:

$i, j \in N$: Representan las barras y N es el set de todas las barras

ij : Son los circuitos entre la barra i y la barra j .

$\theta_{ij} = \theta_i - \theta_j$: Representa la diferencia entre los ángulos de fase entre barra i y la barra j .

Los elementos (\mathbf{G}, \mathbf{B}) de la matriz de admitancia de barras se calculan de la siguiente manera:

$$\mathbf{G} = \left\{ \begin{array}{l} G_{ij}(\mathbf{n}) = -(n_{ij}g_{ij} + n_{ij}^0g_{ij}^0) \\ G_{ii}(\mathbf{n}) = \sum_{j \in \Omega_i} (n_{ij}g_{ij} + n_{ij}^0g_{ij}^0) \end{array} \right\} \quad [2.46]$$

$$\mathbf{B} = \left\{ \begin{array}{l} B_{ij}(\mathbf{n}) = -(n_{ij}b_{ij} + n_{ij}^0b_{ij}^0) \\ B_{ii}(\mathbf{n}) = b_i^{sh} + \sum_{j \in \Omega_i} [n_{ij}(b_{ij} + b_{ij}^{sh}) + n_{ij}^0(b_{ij}^0 + (b_{ij}^{sh})^0)] \end{array} \right\} \quad [2.47]$$

Donde:

Ω_i : Representa el grupo de todas las barras que están directamente conectadas a la barra i .

$g_{ij}, b_{ij}, b_{ij}^{sh}$: Son la conductancia, susceptancia y susceptancia shunt de la línea de transmisión o transformador ij (si ij es un transformador entonces $b_{ij}^{sh} = 0$) respectivamente.

b_i^{sh} : Es la susceptancia shunt en la barra i .

Los elementos (ij) de los vectores S^{from}, S^{to} están dados por:

$$S_{ij}^{from} = \sqrt{(P_{ij}^{from})^2 + (Q_{ij}^{from})^2} \quad [2.48]$$

$$P_{ij}^{from} = V_i^2 g_{ij} - V_i V_j (g_{ij} \cos \theta_{ij} + b_{ij} \sin \theta_{ij}) \quad [2.49]$$

$$Q_{ij}^{from} = -V_i^2 (b_{ij}^{sh} + b_{ij}) - V_i V_j (g_{ij} \sin \theta_{ij} - b_{ij} \cos \theta_{ij}) \quad [2.50]$$

$$S_{ij}^{to} = \sqrt{(P_{ij}^{to})^2 + (Q_{ij}^{to})^2} \quad [2.51]$$

$$P_{ij}^{to} = V_j^2 g_{ij} - V_i V_j (g_{ij} \cos \theta_{ij} - b_{ij} \sin \theta_{ij}) \quad [2.52]$$

$$Q_{ij}^{to} = -V_j^2 (b_{ij}^{sh} + b_{ij}) + V_i V_j (g_{ij} \sin \theta_{ij} + b_{ij} \cos \theta_{ij}) \quad [2.53]$$

Más adelante, se presentará una variante de la formulación del modelo AC descrito, la cual fue empleada en [62] y que tiene ventajas interesantes que no posee el modelo AC anterior. Estas ventajas han sido utilizadas en el desarrollo de este trabajo de investigación ya que permiten una exploración de las técnicas metaheurísticas de solución de una forma mucho más flexible.

2.3 Técnicas de solución

Como se encuentra descrito detalladamente en [72], las técnicas de optimización utilizadas en la literatura para resolver el problema PET pueden ser agrupadas en las siguientes:

- Algoritmos heurísticos
- Métodos Clásicos
- Técnicas Meta heurísticas

2.3.1 Algoritmos heurísticos

Un algoritmo heurístico es un procedimiento paso a paso que, de manera sistemática, determina una buena propuesta de expansión del sistema de transmisión a partir de una configuración base. En cada paso es adicionado al sistema uno o varios circuitos de manera que el sistema eléctrico expandido pueda operar adecuadamente [15]; por tanto, la configuración del sistema eléctrico es modificada recibiendo adiciones de nuevos circuitos, y esta configuración obtenida pasa a ser denominada la configuración actual. En cada iteración del algoritmo, el circuito escogido pasa a ser incorporado a la llamada configuración actual de un circuito que corresponde al camino más atractivo identificado por criterios de sensibilidad, indicadores de sensibilidad o índices de desempeño [18].

El primer método heurístico de gran difusión utilizado en el planeamiento de sistemas de transmisión que apareció fue el de Garver [10] el mismo que utiliza el modelo de transportes. La idea de Garver fue usar la programación lineal (PL) como una estrategia para encontrar una buena solución para el problema original. La propuesta de Garver sugiere resolver su propio modelo de transportes después de relajar la integridad de las variables enteras de inversión. De esta forma, el modelo de transporte se reduce a un simple problema de PL, y la solución de este puede ser usada para identificar el camino más atractivo para adicionar una línea de transmisión del sistema eléctrico. Entonces, la propuesta de Garver consiste en adicionar un circuito en la configuración actual del camino más atrayente que resulta ser el que tiene el mayor flujo de potencia, y actualizar la configuración corriente de acuerdo a la adición seleccionada [6].

En la literatura del planeamiento de sistemas de transmisión existen muchos algoritmos heurísticos que utilizan el modelo DC [1], [4], [18]. Como ejemplos, se puede citar el algoritmo de mínimo esfuerzo [38], el algoritmo de mínimo corte de carga [39], el algoritmo de Villasana-Garver-Salon [40], entre otros. En la metodología propuesta por Monticelli [38] el indicador de sensibilidad del algoritmo identifica que, en cada paso del proceso, en cada paso del proceso, se añade al sistema eléctrico de la topología base aquel circuito que produzca la mayor reducción de sobrecarga del sistema eléctrico. En el algoritmo de mínimo corte de carga el indicador de sensibilidad identifica que en cada paso del proceso, se adiciona al sistema eléctrico de la topología base aquel circuito que tiende a producir una mayor disminución de corte de carga, haciendo uso de generadores artificiales para evitar los problemas de operación del sistema eléctrico. El algoritmo de Villasana-Garver-Salon utiliza como índice de sensibilidad la resolución del modelo híbrido lineal relajando la integralidad de las variables de inversión. En cada paso se resuelve el modelo híbrido lineal para la topología corriente con el fin de identificar el circuito del camino más atrayente que debe ser adicionado al sistema eléctrico con la misma lógica fundamental del algoritmo de Garver. La diferencia es que todo circuito adicionado al sistema eléctrico durante el proceso debe obedecer las dos leyes de Kirchhoff, lo que significa que al final del proceso la solución encontrada es factible para el modelo DC.

2.3.2 Métodos clásicos de optimización

Los métodos de optimización de este tipo, generalmente usan técnicas de descomposición matemática, presentan una característica de encontrar la solución óptima del problema de planeamiento de expansión de la transmisión y son muy eficientes en sistemas de tamaño pequeño y medio. Para sistemas de gran tamaño estos métodos todavía presentan problemas de convergencia y elevado esfuerzo computacional [18].

Una alternativa para la solución del problema de PET fue usar la descomposición de Benders, que explora la descomposición natural del problema de planeamiento en dos partes, un subproblema de inversión y un subproblema de operación. El subproblema de inversión, en el que se escoge un plan de expansión candidato y

son calculados los costos de inversión asociados al mismo, y un subproblema de programación lineal entera mixta. El subproblema de operación es un problema de programación lineal, donde es probado el plan de expansión candidato en términos del adecuado atendimento de la carga [1], [15]. En [41] se utiliza la descomposición de Benders con el modelo de transportes y el modelo DC por separado. En [21], Romero y Monticelli proponen el planeamiento jerarquizado con descomposición de Benders para el modelo DC donde fueron encontradas soluciones óptimas para sistemas pequeños y medianos aún no conocidos. En [42] se propone un esquema de descomposición jerarquizado en dos fases y en [36] se presenta un algoritmo de descomposición de Benders para un modelo lineal disyuntivo.

El algoritmo *Branch and Bound*, es un algoritmo enumerativo, cuya estructura de resolución se basa en la construcción de un árbol donde los nodos representan los problemas candidatos y los caminos representan las nuevas restricciones que deben ser consideradas. Por medio de este árbol, todas las soluciones enteras de la región factible del problema son enumeradas de modo implícito o explícito, lo que garantiza que todas las soluciones óptimas sean encontradas [4]. Las aplicaciones de este algoritmo para resolver el problema de planeamiento de la expansión fueron presentadas en [6], [10], [16], [22-25], [35].

2.3.3 Técnicas Meta heurísticas

Las meta heurísticas representan un conjunto de técnicas de optimización adaptadas para lidiar con problemas complejos que presentan características de explosión combinatorial, particularmente aquellos en los que los métodos heurísticos no son suficientes. Por tanto las meta heurísticas son métodos de solución que combinan procedimientos de búsqueda local con estrategias de más alto nivel, desarrollando un proceso capaz de escapar a los mínimos locales y realizar una búsqueda más robusta dentro del espacio de soluciones de un problema. Algunas meta heurísticas usadas en el planeamiento de expansión de sistemas de transmisión son: los métodos de recocido simulado (*simulated annealing*), algoritmos genéticos (*genetic algorithms*), busca tabu (*tabu search*), GRASP (*Greedy Randomized Adaptive Search Procedure*), enjambre de partículas (*particle swarm*),

colonia de hormigas (*ant colony*), entre otros. La mayor parte de estas técnicas pertenecen a lo que en optimización se conoce como Algoritmos Evolutivos (AE).

La utilización de meta heurísticas para resolver el problema de planeamiento de la transmisión tuvo sus inicios con el trabajo de Romero [28], en base a la técnica de recocido simulado. Posteriormente en [1], [43] fue propuesto el Recocido Simulado Paralelo el cual permitió obtener soluciones reduciendo el tiempo de ejecución. En [44] fue empleado un método híbrido, que al usar el recocido simulado, incorporó una fase de búsqueda local permitiendo una mejora en el desempeño del algoritmo.

Los Algoritmos Genéticos también fueron aplicados a la solución del problema de planeamiento. En [1], [26], Gallego utilizó un algoritmo genético presentando buenas soluciones para el problema PET. Una versión de los algoritmos genéticos, el algoritmo de Chu-Beasley fue aplicado con éxito en [4], [17]. Otros abordajes utilizando algoritmos genéticos fueron propuestos en [3], [5], [8], [14], [15], [27], [45].

En [1], el método de optimización de búsqueda tabú fue aplicado al problema PET. Otras aplicaciones que utilizan búsqueda tabú pueden ser encontradas en [29], [30], [46], [47].

La meta heurística GRASP también fue aplicada al problema PET en [31], [37].

En [48], [49] fue empleado el algoritmo de optimización o colonia de hormigas para la resolución del problema de planeamiento.

La técnica de optimización por enjambre de partículas (*particle swarm optimization* – PSO) fue aplicada en [50], [51] para sistemas de pequeño tamaño. En [13], [32], [33], [52] algunas variantes de PSO fueron también aplicadas con éxito pero para sistemas de tamaño medio. En [32], fue presentada una versión Local PSO (LPSO) paralelo, que permitió acelerar el tiempo computacional de ejecución. Posteriormente en [9], algunas variantes de PSO fueron aplicadas al problema PET usando sistemas de tamaño pequeño, medio y grande.

Las técnicas meta heurísticas, si bien encuentran soluciones de muy buena calidad, no garantizan llegar siempre a la solución óptima, debido a su naturaleza de búsqueda aleatoria. El tiempo de computación empleado para llegar a la solución, depende en gran medida del tamaño del sistema, por lo que el uso de una técnica de este tipo, para que resulte atractiva cuando es aplicada para resolver sistemas de gran tamaño, el tiempo de cálculo no deberá ser mayor que aquel usado en



programación matemática clásica. Este criterio, podrá ser usado como un elemento de evaluación de la técnica de solución.

Capítulo 3

Optimización mediante Algoritmos Evolutivos (AE): Programación Evolutiva (PE), Estrategia Evolutiva (EE), Estrategia Evolutiva Modificada (EEM)

3.1 Introducción

Los Algoritmos Evolutivos (AE) son técnicas empleadas para la solución de problemas de optimización. Muchos autores utilizan de modo equivalente la terminología Algoritmos Evolutivos y Computación Evolutiva, para enfatizar el hecho que los AE son implementados en computadoras. Sin embargo, la Computación Evolutiva no necesariamente refiere al estudio de problemas de optimización. Los AE son específicamente algoritmos de optimización evolutiva, hecho que los distingue de la Computación Evolutiva. En contraparte, el uso de la terminología “*optimización basada en poblaciones*” como un equivalente de los AE sugiere de manera directa la naturaleza de este tipo de técnicas, las cuales usualmente se basan en una población de soluciones candidatas las cuales con el paso del tiempo evolucionan cada vez hacia poblaciones que tienen mejor respuesta como una solución del problema planteado. Tal es el caso de algoritmos evolutivos conocidos como: *Particle Swarm Optimization*, *Simulated Annealing*, *Genetic Algorithm*, *Ant Colony*, *Differential Evolution*, entre otros.

Los AE forman parte de los métodos de optimización heurísticos (del término griego εὕρισκειν que significa: hallar, inventar). Estas metodologías de búsqueda de soluciones están fuertemente basadas en el sentido común, en el conocimiento específico del problema a resolver o incluso la imitación del comportamiento de poblaciones en el mundo animal. Los algoritmos heurísticos no pretenden encontrar

la mejor solución de un problema pero llegar a una solución lo suficientemente buena y cercana a la solución óptima. Su desempeño es potenciado por el conocimiento del problema a resolver el cual ayuda a sintonizar el algoritmo de solución con la finalidad de acelerar su convergencia desarrollando al mismo tiempo la capacidad de explorar el espacio de soluciones de un problema particular.

El término meta heurístico es utilizado para referirse a un conjunto de algoritmos heurísticos que tienen en común una técnica similar de solución pero con parámetros y esquemas de modelamiento diferentes, o patrones de búsqueda de más alto nivel que mejoran los resultados o la velocidad de convergencia. En general la mayoría de los AE son meta heurísticos.

Los AE tienen la característica común de operar sobre una búsqueda iterativa de soluciones. Se espera que el resultado de cada iteración mejore en relación al resultado de la iteración anterior. Es común llamar “generación” al resultado de cualquier iteración. La búsqueda de la mejor solución trae implícita la necesidad de evaluar la fortaleza o robustez de cada una de ellas para luego preservarla o desecharla en beneficio de cualquier solución existente o venidera. La robustez de las soluciones que produzca el algoritmo determinará la robustez del algoritmo en sí mismo. Sin perder de vista que el propósito principal es encontrar las soluciones que maximicen o minimicen la función objetivo, la robustez de cada solución será evaluada si contribuye a maximizar o minimizar dicha función.

Los AE son usualmente categorizados dentro de lo que se conoce como inteligencia computacional. Ello exige que tengan ciertos atributos asociados a dicha inteligencia, tales como

i) Adaptación del algoritmo para producir mejor convergencia en virtud de la naturaleza específica de cada problema.

ii) Capacidad de tomar decisiones de manera aleatoria pero con restricciones que ayuda a multiplicar los espacios de búsqueda de soluciones siempre evaluando la robustez de cada solución

iii) Capacidad de comunicación, la cual tiene un despliegue particular en los AE, pues involucran una población de soluciones candidatas de algún problema las cuales son conocidas como individuos que se comunican entre sí a través del algoritmo con el propósito de determinar cuál es el más exitoso y señalar la ruta de las siguientes búsquedas.

iv) La realimentación es otra característica de la inteligencia, la cual en el caso de los AE se manifiesta a través de la adaptabilidad al revisar en cada iteración la condición de la solución y escoger entre los individuos los más aptos para generar nuevas soluciones, pero adicionalmente a ello es necesario que el sistema tenga capacidad de aprendizaje para no retomar grupos de soluciones que ya han sido desechadas.

v) Finalmente el balance adecuado entre exploración y explotación es otro atributo de la inteligencia, por una parte la exploración para buscar nuevas soluciones basada en la aleatoriedad es característica intrínseca de los AE y por otro, basarse en soluciones iniciales de un problema que aprovechan el conocimiento previo del mismo está relacionado con la explotación.

3.2 Programación Evolutiva (PE)

La Programación Evolutiva (PE) es un tipo particular de AE heurístico. Fue desarrollada por Lawrence Fogel, Al Owens y Jack Walsh [74], [75]. Es la técnica que se utilizará para el desarrollo de este trabajo de investigación en su etapa inicial. Posteriormente se abordará el uso de otro tipo de algoritmos en la implementación final.

3.2.1 Programación Evolutiva Continua (PEC)

Suponga que deseamos minimizar la función $f(x)$, donde x es un vector n -dimensional. Asumiendo que $f(x) \geq 0 \quad \forall x$. La PEC inicia el algoritmo con una población de individuos generada aleatoriamente $\{x_i\}, i \in [0, N]$. La descendencia de esta población la denotamos como $\{x'_i\}$ la cual es generada de acuerdo a la siguiente regla:

$$x'_i = x_i + r_i \sqrt{\beta f(x_i) + \gamma}, \quad i \in [1, N] \quad (3.1)$$

Donde:

r_i : Es un vector aleatorio cuyos elementos son tomados de una distribución Gaussiana con una media de 0 y una varianza de 1.

β y γ : Son parámetros de sintonía de la PEC.

La varianza de la mutación es $(\beta f(x_i) + \gamma)$. Usualmente se asigna los siguientes valores para los parámetros de sintonía: $\beta = 1$ y $\gamma = 0$, sin embargo para cada tipo de problema, sintonizar estos parámetros es necesario para conseguir una mejor convergencia en la solución. [73]

El proceso iterativo del algoritmo anterior puede ser resumido en el siguiente

Seleccionar parámetros no negativos de la PEC β y γ . Nominalmente $\beta = 1$ y $\gamma = 0$.
 $\{x_i\} \leftarrow \{\text{aleatoriamente generar una población}\}, i \in [1, N]$
Mientras no se active el criterio de finalización:
 Evaluar la función de costo $f(x_i)$ para cada uno de los individuos de la población.
 Para cada individuo $\{x_i\}, i \in [1, N]$
 Generar un vector aleatorio r_i cuyos elementos pertenezcan al intervalo $N(0,1)$

$$x'_i \leftarrow x_i + r_i \sqrt{\beta f(x_i) + \gamma}$$

 Siguiendo individuo.
 $\{x_i\} \leftarrow$ Los mejores N individuos de la población resultante $\{x_i, x'_i\}$
Siguiendo generación.

pseudocódigo que tiene el propósito minimizar la función objetivo $f(x)$

Figura 3.1 Pseudocódigo del algoritmo PEC para minimizar la función $f(x)$

Se pueden utilizar diferentes opciones para seleccionar la siguiente generación $\{x_i, x'_i\}$. La primera opción es seleccionar los mejores N individuos, tal como lo establece el pseudocódigo anterior, alternativamente es posible hacer una selección aleatoria del conjunto $\{x_i, x'_i\}$ utilizando diferentes métodos como son: la ruleta, selección por competencia, etc.

Un algoritmo de PEC, puede ser escrito de modo que no solo estén involucradas las soluciones candidatas, sino también involucrar las mutaciones de sus varianzas.

Seleccionar parámetros no negativos de la PEC c y ε . Nominalmente $\varepsilon \ll 1$ y $c = 1$.

$\{x_i\} \leftarrow \{\text{aleatoriamente generar una población}\}, i \in [1, N]$

$\{v_i\} \leftarrow \{\text{aleatoriamente generar una varianza}\}, i \in [1, N]$

Mientras no se active el criterio de finalización:

Evaluar la función de costo $f(x_i)$ para cada uno de los individuos de la población.

Para cada individuo $\{x_i\}, i \in [1, N]$

Generar vectores aleatorios r_{xi}, r_{vi} cuyos elementos pertenezcan al intervalo $N(0,1)$

$x'_i \leftarrow x_i + r_{xi}\sqrt{v_i}$

$v'_i \leftarrow v_i + r_{vi}\sqrt{cv_i}$

$v'_i \leftarrow \max(v'_i, \varepsilon)$

Siguiendo individuo.

$\{x_i\} \leftarrow$ Los mejores N individuos de la población resultante $\{x_i, x'_i\}$

$\{v_i\} \leftarrow$ Varianzas que corresponden a $\{x_i\}$

Siguiente generación.

En este último caso hablamos de meta PEC, la cual es resumida en la Figura 3.2. En un algoritmo meta PEC, cada individuo x_i está asociado con la varianza de la mutación v_i . Las varianzas por si mismas mutan en la búsqueda de una varianza de mutación óptima. Se restringen las varianzas a un valor mínimo de ε , el cual es un parámetro de sintonía definido por el usuario. El propósito de un algoritmo meta PEC es acelerar el proceso de convergencia a través de la adaptación automática de las varianzas de mutación. La calibración de los parámetros de sintonía es por tanto una actividad importante para conseguir un algoritmo eficiente para determinado tipo de problema.

Figura 3.2 Pseudocódigo del algoritmo meta PEC para minimizar la función $f(x)$

3.2.2 Programación Evolutiva Discreta (PED)

La propuesta original de Fogel para la PE era ligeramente diferente que la descrita

```
{xi} ← {aleatoriamente generar una población}, i ∈ [1, N]
Mientras no se active el criterio de finalización:
    Evaluar la función de costo f(xi) para cada uno de los individuos de la
    población.
    Para cada individuo {xi}, i ∈ [1, N]
        Generar un vector aleatorio ri cuyos elementos pertenezcan al
        intervalo N(0,1)
        x'i ← mutación aleatoria entera de xi
    Siguiendo individuo.
    {xi} ← Los mejores N individuos de la población resultante {xi, x'i}
    Siguiendo generación.
```

Figura 3.3 Pseudocódigo del algoritmo PED para minimizar la función $f(x)$

en el apartado anterior, pues su implementación era aplicable directamente al dominio de los enteros. El pseudocódigo de la Programación Evolutiva Discreta (PED) se describe en la Figura 3.3.

3.3 Estrategias Evolutivas (EE)

Un nivel de afinamiento más sutil de las técnicas de PE se da en el desarrollo de los que se conoce como Estrategias Evolutivas (EE), que no son otra cosa sino una categorización los modelos de cada uno de los algoritmos evolutivos. Por su naturaleza esta es una técnica de búsqueda y optimización meta heurística. Existe sin embargo una diferencia en el enfoque, mientras la PE trabaja con una solución la cual es actualizada en función de procesos de búsqueda aleatoria y selección de mejores soluciones de manera iterativa, las EE operan con un criterio de búsqueda más amplio al utilizar elementos de selección y mutación. Existen métodos de selección simples o altamente desarrollados para escoger los individuos que producirán la siguiente generación de soluciones. Por otra parte, se utiliza el “crossover” o recombinación de las características esenciales de los individuos de cada población utilizados para producir la descendencia perteneciente a la siguiente generación. La robustez de cada individuo en determinada generación es evaluada a lo largo de las iteraciones con el propósito de modular la búsqueda de soluciones siguientes. Se pretende que este proceso permita acelerar los procesos de

convergencia. En este punto se describirán algunas estrategias evolutivas con fines didácticos o explicativos hasta llegar a la estrategia auto adaptativa y a la estrategia auto adaptativa modificada, utilizadas en el desarrollo de este trabajo de investigación.

3.3.1 Estrategia Evolutiva (1 + 1)

Suponga que $f(x)$ es una función de un vector real aleatorio x n-dimensional. Sea σ^2 la varianza no negativa de la mutación del proceso de búsqueda aleatoria podemos plantear el siguiente pseudocódigo:

```
Inicializar la varianza no negativa de la mutación  $\sigma^2$ 
Generar de manera aleatoria el vector de la población inicial  $x_0$ 
Mientras no se active el criterio de finalización:
    Generar el vector aleatorio  $r$  con  $r_i$  en el rango  $N(0, \sigma^2)$  para  $i \in [1, n]$ .
         $x_1 \leftarrow x_0 + r$ 
        Si  $x_1$  es mejor que  $x_0$  entonces
             $x_0 \leftarrow x_1$ 
        Fin del lazo condicional.
Siguiendo generación.
```

Figura 3.4 Pseudocódigo que describe la estrategia evolutiva (1 + 1)

La varianza σ^2 es un parámetro de sintonía el cual debería ser suficientemente grande para alcanzar todos los espacios de búsqueda en un período de tiempo razonable y por otra parte suficientemente pequeño para alcanzar la solución óptima con la precisión requerida por el usuario. Variantes del algoritmo básico han sido desarrolladas afinando la estrategia de búsqueda, los cuales no van a ser descritos en este espacio pues está fuera del alcance de este trabajo.

La mutación del pseudocódigo anterior es isotrópica debido a que cada individuo de la población tiene la misma varianza. En la práctica se requiere que la varianza sea diferente para cada uno de los individuos lo que se consigue con unas pequeñas variantes al algoritmo anterior. Adicionalmente cuando se implementa dentro del algoritmo base, el cambio de la varianza de alguna manera en forma, cuando cierto número de generaciones ha sido exitosa, hablamos que el código es adaptativo. Esto se verá más claramente en las siguientes estrategias evolutivas.

3.3.2 Estrategia Evolutiva ($\mu + 1$)

Es la primera generalización de la estrategia anterior (1 + 1). En este caso μ padres son usados para cada generación. A su vez cada padre es asociado con un vector σ el cual controla la magnitud de las mutaciones. Los padres se combinan entre ellos para formar un único hijo o descendencia, y entonces el hijo es mutado produciendo la siguiente generación. Los padres de la siguiente generación se escogen entonces entre los σ mejores individuos los cuales son escogidos de entre los padres de la generación anterior y los hijos mutados de la generación recientemente obtenida.

Diferentes métodos de recombinación pueden ser utilizados entre los padres para obtener el hijo antes de aplicar la mutación y obtener la nueva generación. En este documento no se detallarán las alternativas de recombinación Sin embargo puede ser consultadas en la bibliografía de referencia [73].

$\{(x_k, \sigma_k)\} \leftarrow$ Generar aleatoriamente individuos y su varianza asociada, $k \in [1, \mu]$. Con μ como la cantidad de padres de la generación.
Cada x_k es una solución candidata, y cada σ_k es un vector de desviación estándar.
Observar que $x_k \in R^n$, y $\sigma_k \in R^n$ con cada uno de los elementos positivos.
Mientras no se active el criterio de finalización:
 Aleatoriamente seleccionar dos padres de la población $\{(x_k, \sigma_k)\}$
 Usar un método de recombinación entre los padres seleccionados para obtener un hijo el cual se denota como $(x_{\mu+1}, \sigma_{\mu+1})$
 $\Sigma_{\mu+1} \leftarrow \text{diag}(\sigma_{\mu+1,1}^2, \dots, \sigma_{\mu+1,n}^2) \in R^{n \times n}$, es una matriz diagonal de varianzas
 Generar el vector aleatorio r dentro del rango $N(0, \Sigma_{\mu+1})$
 $x_{\mu+1} \leftarrow x_{\mu+1} + r$
 Remover el peor individuo de la población, de tal manera que:
 $\{(x_k, \sigma_k)\} \leftarrow$ Sean los mejores individuos del conjunto
 $\{(x_1, \sigma_1), \dots, (x_{\mu+1}, \sigma_{\mu+1})\}$
Siguiente generación.

Figura 3.5 Pseudocódigo que describe la estrategia evolutiva ($\mu + 1$), donde n es la dimensión del problema, o equivalentemente el número de variables implicadas en su solución.

3.3.3 Estrategias Evolutivas $(\mu + \lambda)$ y (μ, λ)

La siguiente generalización de las estrategias evolutivas es $(\mu + \lambda)$. En este caso el tamaño de la población lo define la cantidad μ padres, los cuales en cada generación producen λ hijos. En este punto tendremos $(\mu + \lambda)$ individuos los cuales incluyen tanto a padres como a hijos. Se seleccionaran entonces los mejores μ individuos como los padres de la siguiente generación.

Otra estrategia evolutiva comúnmente utilizada es la (μ, λ) . La diferencia con la estrategia anterior radica en que los padres de la siguiente generación son seleccionados de entre los mejores μ individuos de los λ hijos. En otras palabras ninguno de los padres de la generación anterior sobreviven, y solo un subconjunto de los hijos es elegido como la siguiente generación de padres. Para asegurar esta estrategia se debe cumplir siempre que $\lambda \geq \mu$. Ninguno de los padres de la generación anterior sobreviven a la siguiente generación y la vida de cada individuo está restringida a la de su propia generación.

La eficacia, medida como una mejor convergencia de cualquiera de las estrategias descritas en este punto depende de la naturaleza del problema que se quiera resolver, y en unos casos una estrategia funciona mejor que la otra.

$\{(x_k, \sigma_k)\} \leftarrow$ Generar aleatoriamente individuos y su varianza asociada, $k \in [1, \mu]$.
Con μ como la cantidad de padres de la generación.
Cada x_k es una solución candidata, y cada σ_k es un vector de desviación estándar.
Observar que $x_k \in R^n$, y $\sigma_k \in R^n$ con cada uno de los elementos positivos.
Mientras no se active el criterio de finalización:
 Para cada $k = 1, \dots, \lambda$
 Aleatoriamente seleccionar dos padres de la población $\{(x_k, \sigma_k)\}$
 Usar un método de recombinación entre los padres seleccionados para obtener un hijo el cual se denota como (x'_k, σ'_k)
 $\Sigma'_k \leftarrow \text{diag}((\sigma'_{k1})^2, \dots, (\sigma'_{kn})^2) \in R^{n \times n}$, es una matriz diagonal de varianzas
 Generar el vector aleatorio r dentro del rango $N(0, \Sigma'_k)$
 $x'_k \leftarrow x'_k + r$
 Incrementar k
Si la estrategia es $(\mu + \lambda)$ entonces:
 $\{(x_k, \sigma_k)\} \leftarrow$ Los mejores μ individuos del conjunto $\{(x_k, \sigma_k)\} \cup \{(x'_k, \sigma'_k)\}$
Caso contrario si la estrategia es (μ, λ) entonces:
 $\{(x_k, \sigma_k)\} \leftarrow$ Los mejores μ individuos del conjunto $\{(x'_k, \sigma'_k)\}$
Fin de la selección
Siguiete generación.

Figura 3.6 Pseudocódigo que describe las estrategia evolutivas $(\mu + \lambda)$ y (μ, λ) , donde n es la dimensión del problema, o equivalentemente el número de variables implicadas en su solución.

3.3.4 Estrategias Evolutivas $(\mu, \kappa, \lambda, \rho)$

En las estrategias anteriores se asume que dos padres se recombinan para formar un hijo, sin embargo no existe ninguna restricción matemática para que puedan ser más de dos los padres que puedan recombinarse. En este caso se designa con la letra ρ el número de padres que contribuyen a la generación de un hijo.

Adicionalmente, si limitamos la vida de cada individuo a una generación utilizamos el parámetro κ que en este caso $\kappa = 1$. En contraparte, si no limitamos la vida de cualesquiera de los individuos y este podría sobrevivir de generación en generación en función de su robustez, decimos que $\kappa = \infty$. La selección adecuada de esta condición depende del tipo y naturaleza del problema tratado.

Entonces, de acuerdo a lo que se ha planteado hasta el momento, cualquier estrategia evolutiva se puede generalizar como $(\mu, \kappa, \lambda, \rho)$, la cual tiene μ padres, cada individuo de una población puede tener una vida de κ generaciones, y cada generación puede producir λ hijos, cada uno de los cuales desciende de una combinación de ρ padres.

3.3.5 Estrategias Evolutivas Auto adaptativas.

Hasta el momento, las estrategias evolutivas no dan mayores opciones que permitan ajustar las desviaciones estándar σ_k de las mutaciones. De esta manera, al igual que mutamos las características de los individuos $\{x_i\}$ en búsqueda de valores óptimos, también podemos mutar los elementos del vector de las desviaciones estándar $\{\sigma_i\}$ con el propósito de encontrar los mejores valores de σ . Después que un hijo (x', σ') es creado, se desarrolla una mutación de acuerdo a la siguiente regla:

$$\sigma'_i \leftarrow \sigma'_i e^{(\tau' \rho_0 + \tau \rho_i)} \quad (3.2)$$

$$x'_i \leftarrow x'_i + \sigma'_i r_i \quad (3.3)$$

Donde:

- $i \in [1, n]$: Subíndice que identifica a cada uno de los individuos de la población
- ρ_0, ρ_i, r_i : Variables aleatorias tomadas de $N(0,1)$
- τ, τ' : Son parámetros de sintonización del algoritmo. Se deberán ajustar para cada problema.

Schwefel recomienda que para que el enfoque de este algoritmo sea robusto se deberán calcular los parámetros de sintonía como sigue:

$$\tau = P_1 \left(\sqrt{2\sqrt{n}} \right)^{-1} \quad (3.4)$$

$$\tau' = P_2 (\sqrt{2n})^{-1} \quad (3.5)$$

Donde:

n : Es la dimensión del problema o equivalentemente la cantidad de variables cuyo valor óptimo se quiere encontrar.

P_1, P_2 : Son constantes de proporcionalidad típicamente iguales a 1

De la ecuación anterior, podemos notar que es siempre necesario obtener la mutación de la varianza antes de que el individuo sea mutado. Al evaluar la robustez del individuo se determinará también la validez de la varianza asociada a la mutación que lo generó. Este proceso iterativo se vuelve entonces auto adaptativo, pues tanto los mejores individuos como las varianzas asociadas a su generación se utilizarán para la producción de las nuevas poblaciones de solución. La intuición nos indica que este enfoque deberá mejorar la exploración de los espacios de búsqueda, consiguiendo mejor convergencia del algoritmo. La estrategia evolutiva auto adaptativa, introducida en [Rechenberg, 1973], es quizá la contribución más importante de las estrategias evolutivas a la investigación y aplicación de los algoritmos evolutivos.

En la siguiente Figura 3.7 se describe el pseudocódigo que puede ser utilizado para la implementación de la estrategia evolutiva auto adaptativa.

Inicializar las constantes τ y τ' .
 $\{(x_k, \sigma_k)\} \leftarrow$ Generar aleatoriamente individuos y su varianza asociada, $k \in [1, \mu]$.
Con μ como la cantidad de padres de la generación.
Cada x_k es una solución candidata, y cada σ_k es un vector de desviación estándar.
Observar que $x_k \in R^n$, y $\sigma_k \in R^n$ con cada uno de los elementos positivos.
Mientras no se active el criterio de finalización:
 Para cada $k = 1, \dots, \lambda$
 Aleatoriamente seleccionar dos padres de la población $\{(x_k, \sigma_k)\}$
 Usar un método de recombinación entre los padres seleccionados para obtener un hijo el cual se denota como (x'_k, σ'_k)
 Generar un escalar aleatorio ρ_0 de $N(0,1)$
 Generar un vector aleatorio $[\rho_1, \rho_2 \dots \rho_n]$ de $N(0,1)$
 $\sigma'_i \leftarrow \sigma_i e^{(\tau' \rho_0 + \tau \rho_i)}$ para $i \in [1, n]$
 $\Sigma'_k \leftarrow \text{diag}((\sigma'_{k1})^2, \dots, (\sigma'_{kn})^2) \in R^{n \times n}$, es una matriz diagonal de varianzas
 Generar el vector aleatorio r dentro del rango $N(0, \Sigma'_k)$
 $x'_k \leftarrow x'_k + r$
 Incrementar k
 Si la estrategia es $(\mu + \lambda)$ entonces:
 $\{(x_k, \sigma_k)\} \leftarrow$ los mejores μ individuos del conjunto $\{(x_k, \sigma_k)\} \cup \{(x'_k, \sigma'_k)\}$
 Caso contrario si la estrategia es (μ, λ) entonces:
 $\{(x_k, \sigma_k)\} \leftarrow$ los mejores μ individuos del conjunto $\{(x'_k, \sigma'_k)\}$
 Fin de la selección
Siguiente generación.

Figura 3.7 Pseudocódigo que describe las estrategias evolutivas auto adaptativas $(\mu + \lambda)$ y (μ, λ) , donde n es la dimensión del problema, o equivalentemente el número de variables implicadas en su solución.

3.3.6 Estrategias Evolutivas Auto adaptativas Modificadas (EEM)

Debido a que el problema del PET es complejo y de difícil solución debido a su naturaleza no lineal y de explosión combinatorial, es necesario explorar estrategias de AE más robustas en relación a los algoritmos descritos hasta ahora. Basado en esta necesidad, y soportado en la literatura existente [73], en los siguientes párrafos se describen algunas variantes que permitirían repotenciar las características de desempeño de la Estrategia Evolutiva. Resultado de la aplicación de estos criterios obtenemos la Estrategia Evolutiva Modificada (EEM).

3.3.6.1 Diversidad de la Población.

Aquí se describe como se puede gestionar de manera adecuada la implementación del algoritmo de búsqueda para manejar la duplicidad de la población. Se exponen dos temas de interés tanto conceptual como práctico que ayudarán al desarrollo del algoritmo para solucionar el problema de TEP.

Duplicidad de individuos:

En una población que es repetidamente recombinada de una generación a la siguiente, se muestra una tendencia a la uniformidad en las características de sus individuos, lo que significa que la población entera llega a ser producto de clonación de individuos. Este hecho es más común en problemas discretos que en los de tipo continuo. El potencial problema con esta condición es que en determinadas condiciones limitaría la capacidad del algoritmo de explorar el espacio de búsqueda. A pesar que el candidato a solución al cual el AE converge usualmente corresponde a una buena solución, sin embargo pueden existir mejores soluciones en otras regiones del espacio de búsqueda. Cuando ocurre la uniformidad en la población tenemos una condición de convergencia prematura. En una manera simple se podría prevenir esta condición con coeficientes de mutación elevados, pero si estos valores son demasiado altos el algoritmo podría degenerar en un proceso de búsqueda aleatoria. Una manera común de evitar la convergencia prematura es establecer un procedimiento de búsqueda continua en la población y reemplazarlos. Esto puede ser implementado de diferente manera:

- Cada vez que se cree un descendiente, se debe asegurar que otro de idénticas características no exista ya. De haberlo se descartará y ejecutará una recombinación adicional con diferentes padres o con diferentes parámetros de recombinación que permitan obtener un descendiente no duplicado.
- Cada vez que se efectúa la mutación en un individuo, se puede rastrear la población para asegurarse que no estamos creando un duplicado. Si es así se deberá repetir el proceso de mutación.
- Al final de cada generación, escanear la población para identificar duplicados. Podemos reemplazar los duplicados de diferente manera. Por ejemplo, podemos reemplazarlos a través de individuos generados aleatoriamente, podemos mutar los duplicados o podríamos ejecutar una operación de recombinación para reemplazar cada duplicado.
- Si es beneficioso para el problema, se podría permitir la presencia de duplicados con una incidencia no mayor a un valor de umbral establecido para aquellos individuos que producen las mejores soluciones del problema.

Conservación de nichos:

Es una variante que se puede incorporar al algoritmo de optimización y está basado en el concepto que es necesario mantener la supervivencia de individuos en diferentes regiones del espacio de búsqueda. Esta característica es especialmente útil en problemas multimodales.

Existen algunas estrategias conocidas para su implementación, entre ellas se presenta una de interés que puede adaptarse de manera natural a la solución del problema de PET: reasignación de aptitud o robustez.

La reasignación de aptitud.

En los AE, algunas veces los individuos pertenecientes a una buena región del espacio de búsqueda pueden tomar el control sobre la población y prevalecer en las generaciones subsiguientes, lo cual puede degenerar en una convergencia prematura hacia la solución que representará un óptimo local. Un algoritmo eficiente deberá pretender por una parte retener a los individuos de buen desempeño en la población pero adicionalmente mantener la diversidad con la posibilidad de explorar nuevas regiones del espacio de búsqueda durante el progreso del AE de una generación a la siguiente. Con este criterio, para alentar la diversidad en la población, podemos de manera artificial, incrementar la robustez de individuos que son relativamente únicos y decrementar la robustez de individuos que son relativamente comunes. En un problema de minimización tendremos que aplicar esta modificación de manera inversa, es decir cambiar artificialmente el valor de la función de costo asociada a individuos únicos de manera que sea menor a la que realmente poseen y alternativamente incrementar el valor de la función de costo para individuos comunes en la población.

Suponga que tenemos una población $\{x_i\}$ de N individuos, y que f_i corresponde a la función de costos asociada al individuo x_i . La reasignación de aptitud consiste en recalcular un nuevo valor de función de costo f'_i artificial asociada al individuo, de la siguiente manera:

$$f'_i = f_i \times m_i \quad (3.6)$$

$$m_i = \sum_{j=1}^N s(d_{ij}) \quad (3.7)$$

Donde:

m_i : Es un parámetro que relacionado con el número de individuos que son similares a x_i

$s(\cdot)$: Es la función de aptitud

d_{ij} : Es la distancia euclideana entre dos individuos x_i y x_j

La función de aptitud puede ser calculada de la siguiente manera:

$$s(d) = \begin{cases} 1 - \left(\frac{d}{\sigma}\right)^\alpha & \text{si } d < \alpha \\ 0 & \text{resto de los casos} \end{cases} \quad (3.8)$$

Donde:

σ : Es un parámetro definido por el usuario llamado umbral de disimilitud,

d : Es la distancia de corte o distancia euclidiana entre dos elementos de la población.

α : Es un parámetro definido por el usuario. Usualmente $\alpha = 1$

Los investigadores han sugerido varios métodos para establecer el umbral de disimilitud [Deb and Goldberg, 1989]. Entre ellos los definidos en las ecuaciones siguientes:

$$\sigma = r \times q^{-1/n} \quad (3.9)$$

$$r = \frac{1}{2} \sum_{k=1}^n (\max_i x_i(k) - \min_i x_i(k))^2 \quad (3.10)$$

Donde:

n : Es la dimensión del problema,

$x_i(k)$: Es el k –ésimo elemento del individuo x_i ,

q : Es el número esperado de óptimos locales en la función de costo.

Esta estructura de cálculo puede ser aplicada para la selección de los padres que producirán los individuos de las siguientes generaciones. El propósito es mantener la diversidad en el proceso de búsqueda para no perder información de regiones del espacio de búsqueda que pueden tener alta probabilidad de contener individuos que representen mejores soluciones para el problema.

3.3.6.2 Opciones de Selección.

Antes que podamos combinar los individuos de un Algoritmo Evolutivo para obtener la descendencia, necesitamos seleccionar aquellos individuos para serán los padres de la siguiente generación de soluciones. Existen muchos mecanismos de selección, no obstante cualquiera que sea usado para implementar este proceso, el

denominador común será privilegiar a aquellos que son más robustos, es decir los que produzcan un menor valor en la función de costos.

Una métrica útil para cuantificar la diferencia entre diferentes algoritmos es la presión por selección ϕ , el cual se define como:

$$\phi = \frac{P_r(\text{selección del individuo más robusto})}{P_r(\text{selección del individuo promedio})} \quad (3.11)$$

Donde:

$P_r(\text{selección de } x)$: Es la probabilidad que el individuo x sea seleccionado para recombinación.

El parámetro anterior cuantifica la probabilidad relativa de que un individuo altamente robusto tome parte en una recombinación para la generación de la descendencia de la siguiente generación.

Torneo de Selección:

Es de particular interés el método de selección conocido como “torneo de selección”. Este proceso consiste en seleccionar aleatoriamente de una población de N miembros, una cantidad de τ individuos, donde $\tau \geq 2$ es la dimensión del torneo definido por el usuario. Entonces se compara la robustez de los individuos seleccionados y se escogen los más robustos para recombinación. En este método particular de selección, el parámetro presión por selección es igual a:

$$\phi = 2^{\tau-1} \quad (3.12)$$

La implementación de este método tiene un bajo costo computacional con un nivel de desempeño razonable. En la Figura 3.8 se describe un pseudocódigo utilizado para implementar este concepto.

$\{x_i\} \leftarrow$ Conjunto de la población de todos los posibles padres de una generación, $i \in [1, N]$. Con N la cantidad de individuos.
Siendo $x_i(k)$ la k -ésima característica del i -ésimo individuo para $k \in [1, n]$ donde n es la cantidad de características del individuo o equivalentemente corresponde a la dimensión del problema.
Sea x'_i la matriz ordenada en base a su robustez de cada uno de los individuos de la población x_i
Se requiere seleccionar de manera aleatoria una característica por vez de los padres, para formar la descendencia y_k , $k \in [1, N]$.
Se generarán números aleatorios enteros $index_i$, $i \in [1, N - \beta]$ basado en la distribución de probabilidad uniforme β representa el porcentaje de padres no seleccionados para recombinación, los que usualmente son los menos robustos.

Generación de la descendencia $\{y_i\}$:
Desde $i=1$ hasta N
 Asignar la k -ésima característica del i -ésimo individuo $y_i(k)$, para $k \in [1, n]$ perteneciente a la población de hijos o descendencia de acuerdo a los de números aleatorios $index_i$

$y_i(k) \leftarrow x'_{(index)_i}(k)$ Donde $k \in [1, n]$ $i \in [1, N - \beta]$

Fin

Figura 3.8 Pseudocódigo que describe la estrategia de selección de padres basado en el Torneo de Selección. Padres seleccionados aleatoriamente del conjunto de x'_i con $i \in [1, N - \beta]$

Sobre selección:

Es un método originalmente propuesto por John Koza en el contexto de la “programación genética” [Koza, 1992]. Este método es una modificación de la selección “ruleta de la suerte” mediante la asignación desequilibrada de robustez hacia los mejores individuos de la población de tal manera que se incremente su posibilidad de ser seleccionados como padres de las poblaciones siguientes. En la versión de sobre selección original de Koza, los mejores 32% de una población tenían el 80% de oportunidades de ser elegidos, y el restante 68% de la población tenía el 20% de oportunidades de ser seleccionados. La exactitud de los porcentajes no es tan importante como el hecho de establecer una estrategia sesgada en la selección de los individuos de una población. Este es un tipo de escalamiento de la robustez para un conjunto de soluciones.

La implementación de la sobre selección podría realizarse de muchas maneras, una de ellas es el uso de distribuciones de probabilidad para generar números aleatorios que sirvan como índices para seleccionar los padres de un conjunto dado de población. A continuación en la Figura 3.9 se presenta un pseudocódigo propuesto para la selección de características de padres y recombinación uniforme, utilizando las distribuciones de probabilidad de Weibull y Exponencial como índices para dicha selección:

$\{x_i\} \leftarrow$ Conjunto de la población de todos los posibles padres de una generación, $i \in [1, N]$. Con N la cantidad de individuos.
Siendo $x_i(k)$ la k -ésima característica del i -ésimo individuo para $k \in [1, n]$ donde n es la cantidad de características del individuo o equivalentemente corresponde a la dimensión del problema.
Sea x'_i la matriz ordenada en base a su robustez de cada uno de los individuos de la población x_i
Se requiere seleccionar de manera aleatoria una característica por vez de los padres, para formar la descendencia $y_k, k \in [1, N]$.
Se generarán números aleatorios enteros $index_i, i \in [1, N]$ basados en las siguientes distribuciones de probabilidad.
Sea $f(x) = \begin{cases} \lambda e^{-\lambda x} & \text{para } x \geq 0 \\ 0 & \text{para } x < 0 \end{cases}$ la función Exponencial de densidad de probabilidad de la variable x , con $\lambda > 0$ un parámetro de la función de distribución.
Sea $g(x) = \begin{cases} \frac{k}{\lambda} \left(\frac{x}{\lambda}\right)^{k-1} e^{-\left(\frac{x}{\lambda}\right)^k} & \text{para } x \geq 0 \\ 0 & \text{para } x < 0 \end{cases}$ la función de Weibull de densidad de probabilidad de la variable x , con $\lambda > 0$ es un parámetro de escala y $k > 0$ es un parámetro de forma de la función de distribución.
Generación de la descendencia $\{y_i\}$:
Desde $i=1$ hasta N
 Asignar la k -ésima característica del i -ésimo individuo $y_i(k)$, para $k \in [1, n]$ perteneciente a la población de hijos o descendencia de acuerdo a los de números aleatorios $index_i$:
$$y_i(k) \leftarrow x'_{(index)_i}(k) \text{ Donde } k \in [1, n] \text{ } i \in [1, N]$$

Fin

Figura 3.9 Pseudocódigo que describe la estrategia de selección de padres y generación de descendencia basada en las distribuciones Exponencial y Weibull. (Sobre selección).

Los métodos de sobre selección y de torneo comparten características comunes pues, establecen un sesgo para escoger aleatoriamente de entre los individuos del conjunto de padres aquellos más robustos seleccionándolos para

convertirse en padres de las siguientes generaciones. En este proceso además está implícita la ejecución de la operación de recombinación que se describe en el siguiente apartado.

3.3.6.3 Recombinación.

Los métodos de recombinación consisten en los mecanismos mediante los cuales los padres de una generación son utilizados para producir los hijos o grupos de soluciones de dicha generación. En la implementación de dichos algoritmos tanto la selección de padres como la recombinación suelen estar incorporados en un solo proceso de ejecución. Con el propósito de entender los mecanismos de recombinación haremos una descripción muy breve de lo que estos significan.

Supongamos que tenemos una población de individuos $\{x_1, x_2, \dots, x_N\}$. Cada individuo de la población posee n características (en el caso del problema de TEP las características de cada individuo representan la cantidad de líneas por derecho de vía). Si denotamos la k -ésima característica del i -ésimo individuo como $x_i(k)$ para $k \in [1, n]$. Entonces podemos representar el x_i individuo de una población como el vector:

$$x_i = [x_i(1) \ x_i(2) \ \dots \ x_i(n)] \quad (3.13)$$

Un individuo o descendencia resultante de un proceso de recombinación padres de generaciones anteriores puede ser denotado como y_i . La k -ésima característica del i -ésimo individuo de esta descendencia será $y_i(k)$ para $k \in [1, n]$. Así:

$$y_i = [y_i(1) \ y_i(2) \ \dots \ y_i(n)] \quad (3.14)$$

Si tenemos dos padres x_a y x_b de una población, donde $a \in [1, N]$ y $b \in [1, N]$, existen muchos métodos de recombinación que pueden ser usados para obtener cada uno de los y_i individuos de la siguiente generación. Describiremos uno de ellos: “La recombinación global” que utiliza las características de todos los padres para la generación de descendencia. Por otra parte, de acuerdo al método de selección de los individuos como padres, se diferencian dos tipos, los cuales fueron utilizados para la implementación de la Estrategia Evolutiva mejorada (EEM), y que son los siguientes:

Recombinación global uniforme de múltiples padres:

En éste tipo de recombinación, se escoge de manera aleatoria las características de múltiples padres para conformar cada una de las características de los individuos de la descendencia siguiente. Siguiendo la notación anterior, si designamos como $x_i(k)$ cada una de la k -ésima característica del i -ésimo individuos pertenecientes a la generación de padres, entonces la característica de cada uno de los i -ésimo individuos de la generación de hijos puede ser obtenida como:

$$y_i(k) \leftarrow x_i(k) \text{ aleatoriamente } \forall k, k \in [1, n], i \in [1, N] \quad (3.15)$$

Donde n corresponde al número total de características de un individuo y N es el número total de individuos de la población. La característica $x_i(k)$ ha sido escogida de manera aleatoria basada en la función de distribución uniforme, de entre todos los N individuos de la población de padres o generación anterior.

Esta metodología para obtener los hijos o descendencia a través de recombinación uniforme, asegura que cada una de las n características de cada uno de los N individuos tenga la misma posibilidad de supervivencia. Esto tiende a asegurar la diversidad de individuos en el proceso iterativo de manera que el algoritmo mantenga una capacidad amplia de exploración del espacio de búsqueda. Sin embargo esto también podría hacer que la capacidad de convergencia del algoritmo disminuya o sea altamente aleatorio. A pesar que no haya sido descrito anteriormente, este mecanismo de combinación ha sido ya implementado en la Estrategia Evolutiva auto adaptativa (EE).

Recombinación global no uniforme de múltiples padres:

Como se mencionó anteriormente, el proceso de recombinación y selección de padres usualmente está incorporado en la misma ejecución dentro del algoritmo. En este contexto, se requiere implementar la recombinación selectiva utilizando únicamente los padres con mayor robustez. La selección de padres puede ser efectuada de manera uniforme y aleatoria como en el párrafo anterior o puede ser escogida de manera aleatoria no uniforme, favoreciendo los individuos más robustos en el proceso de selección. Se explican dos opciones de implementación para conseguir este propósito:

- Selección aleatoria uniforme de las características de una fracción de los mejores individuos (20%, 40% o 60%, etc.) de la población de padres ordenada por su robustez. Este método se implementó en una de las opciones del algoritmo de Estrategia Evolutiva Modificada (EEM). Aquí ya se

establece un sesgo de selección de los mejores individuos, lo que mejora la convergencia, pero sin embargo se pierden las características del 80%, 60% o 40% del resto de individuos menos favorecidos, lo que podría limitar la capacidad de exploración del espacio de soluciones.

- Selección aleatoria no uniforme, basada en las distribuciones de probabilidad Exponencial o de Weibull, generando una mayor posibilidad de selección de los individuos más robustos y disminuyendo la probabilidad de selección de los menos aptos. Es una forma de implementar la sobre selección explicada en el acápite 3.3.6.2. Esto conseguiría conciliar la capacidad de convergencia del algoritmo con su diversidad. Se busca obtener una solución de compromiso que haga que el algoritmo mantenga su capacidad de salir de los óptimos locales. La recombinación de los individuos también será del tipo global.

3.3.6.4 Mutación.

La mutación es una operación que permite el cambio de las características de una población basados en alguna regla. La definición de esta regla usualmente hace que el proceso de búsqueda sea inteligente, permitiendo que el algoritmo tenga capacidad de explorar el espacio de búsqueda de manera controlada. Existen algunas reglas de mutación como las indicadas en la referencia [73]. Sin embargo nos orientaremos a aquella que es parte del algoritmo de Estrategia Evolutiva (EE), debido a que la misma es la que se utiliza en las dos variantes de la Estrategia Evolutiva modificada (EEM). El método de mutación está basado en la definición de desviación estándar asociada a cada individuo de la próxima generación, como un indicador de que ese es el margen de mutación que tiene a la solución óptima. El pseudocódigo está detalladamente indicado en la Figura 3.7.

Otros métodos de mutación de mejor adaptación al problema pueden ser aplicados sin desmedro de la estructura del algoritmo de EEM.

3.3.7 Estrategias Evolutivas. Conclusión

Hemos observado en los párrafos anteriores, de una manera somera, como los investigadores han desarrollado los conceptos de estrategias evolutivas desde sus conceptos básicos, hasta llegar a la incorporación de conceptos más elaborados. Son tres los elementos sobre los que operan las estrategias de búsqueda de las Estrategias Evolutivas: la selección, la recombinación y mutación. La selección de

los mejores individuos se basa en la robustez de cada uno de ellos (selección del mejor) sin perder de vista la varianza (herramienta de mutación) que produjo a estos individuos óptimos, la cual se utilizará a su vez para direccionar la producción de nuevas varianzas que se utilizarán para mutar los individuos de las siguientes generaciones. Estos conceptos marcan la tendencia de las estrategias evolutivas para la optimización de problemas multi variables. Los problemas con grandes espacios de búsqueda y de naturaleza combinatorial, son candidatos para aplicar las EE. Esta particularidad es uno de los motivadores para la aplicación de estas técnicas para la solución del problema de la Planificación de la Expansión de la Transmisión (PET). El estudio de estas técnicas y sus resultados se describirá de manera específica en los siguientes capítulos de este documento.

3.4 Implementación de PE, EE y EEM.

En este trabajo de investigación se ha efectuado la implementación de tres algoritmos para solucionar el problema del PET. El primero correspondiente a uno de Programación Evolutiva (PE), con y sin adaptación. El segundo algoritmo utilizando una Estrategia Evolutiva auto adaptativa (EE). Finalmente luego del rendimiento observado con el algoritmo de la Estrategia Evolutiva se hizo necesario incorporar algunas mejoras en el proceso de selección de padres y métodos de recombinación, lo que dio lugar al algoritmo de la Estrategia Evolutiva Modificada (EEM) con dos variantes de selección. Esta es la estrategia de solución analizada al final del trabajo de investigación.

La aplicación de los algoritmos han sido ligeramente modificados de su propuesta matemática original, para adaptarlos al problema del PET y de manera específica al entorno en Matlab donde se han completado los códigos que implementan estas propuestas.

Adicionalmente la sintonización de los parámetros ha sido efectuada en un proceso de prueba y error, por lo que no necesariamente representa los valores de ajuste óptimo, y dependerá el tamaño y particularidades del sistema eléctrico sobre el que se aplique. En este trabajo se utilizaron los sistemas de prueba Garver de 6 nodos e IEEE de 24 nodos. Los algoritmos de PE y EE han sido aplicados

solamente al sistema de Garver bajo diferentes escenarios de análisis, mientras que la EEM se ha aplicado tanto al sistema de Garver como al de la IEEE de 24 nodos.

3.4.1 Formulación matemática

En este trabajo, se ha utilizado el modelo AC el cual, de acuerdo a lo planteado en [62] para su implementación se ha dividido en dos problemas: a) El problema principal de expansión y b) El problema operacional.

El problema de expansión minimiza el costo total de adición de líneas de transmisión y el costo de corte de carga utilizando la función objetivo de la Ecuación (3.16). El costo de corte de carga es una estrategia incorporada al modelo que sirve por una parte para cuantificar los diferentes planes de expansión y por otra para penalizar la función objetivo, de una manera fácil, en caso de que una determinada topología de transmisión no sea operacionalmente factible. Luego de cada iteración, una serie de topologías de transmisión es generada por la meta heurística de Programación Evolutiva o sus correspondientes Estrategia Evolutiva y Estrategia Evolutiva modificada. Adicionalmente la factibilidad operacional de cada topología tiene que ser evaluada. Esta última parte es realizada a través de un problema de optimización independiente que proporciona al problema de expansión de la transmisión una medida de factibilidad por medio del costo de corte de carga.

La formulación del problema principal de expansión de la transmisión esta descrita matemáticamente de la siguiente manera:

$$\text{Min } v = \sum_{(k,l) \in \Omega} c_{kl} n_{kl} + w \quad (3.16)$$

s.a.

$$0 \leq n_{kl} \leq \bar{n}_{kl}$$

n_{kl} Entero

Donde:

v : Es la inversión total debido a la adición de nuevos circuitos.

c_{kl} : Costo del circuito que va a ser adicionado al camino kl

n_{kl} : Número de circuitos adicionados al camino kl

w : Costo de corte de carga activa

\bar{n}_{kl} : Número máximo de circuitos que pueden ser añadidos al camino kl

Ω : Conjunto de caminos del sistema eléctrico, correspondientes a los circuitos (existentes y adicionados) a la topología base.

El problema operacional proporciona información respecto al costo del corte de carga, para cada topología de transmisión. Corresponde a la formulación de un Flujo Optimo de Potencia AC (AC- OPF) con ciertas restricciones operacionales, similares a las del bien conocido modelo DC. En la formulación, la función objetivo incluye el corte de carga de potencia activa y reactiva, lo cual es modelado, añadiendo generadores artificiales en los nodos PQ de tal manera que el corte de carga sea minimizados para determinada topología. En el presente trabajo se resuelve mediante un algoritmo de punto interior de MATPOWER [34]. La evaluación de cada topología transmisión se referirá como la evaluación de la función (FE) en el presente documento. La formulación matemática se completaría con lo descrito a continuación:

$$\text{Min } w = \sum_{k \in M} (\alpha_1 r_{Pk} + \alpha_2 r_{Qk}) \quad (3.17)$$

s.a.

$$\mathbf{P}(\mathbf{V}, \boldsymbol{\theta}) - \mathbf{P}_G + \mathbf{P}_D - \mathbf{r}_P = 0 \quad (3.18)$$

$$\mathbf{Q}(\mathbf{V}, \boldsymbol{\theta}) - \mathbf{Q}_G + \mathbf{Q}_D - \mathbf{r}_Q = 0 \quad (3.19)$$

$$\underline{\mathbf{P}}_G \leq \mathbf{P}_G \leq \bar{\mathbf{P}}_G \quad (3.20)$$

$$\underline{\mathbf{Q}}_G \leq \mathbf{Q}_G \leq \bar{\mathbf{Q}}_G \quad (3.21)$$

$$\underline{\mathbf{r}}_P \leq \mathbf{r}_P \leq \bar{\mathbf{r}}_P \quad (3.22)$$

$$\underline{\mathbf{r}}_Q \leq \mathbf{r}_Q \leq \bar{\mathbf{r}}_Q \quad (3.23)$$

$$\underline{\mathbf{V}} \leq \mathbf{V} \leq \bar{\mathbf{V}} \quad (3.24)$$

$$\mathbf{s}^{from} \leq \bar{\mathbf{s}} \quad (3.25)$$

$$\mathbf{s}^{to} \leq \bar{\mathbf{s}} \quad (3.26)$$

θ Irrestricto

Donde:

r_p : Representa el corte de carga activa.

α_1 : Es el costo del corte de carga activa.

\bar{r}_p : Representa la carga total conectada a la barra respectiva.

\underline{r}_p : Representa la mínima carga conectada a la barra. En este caso es igual a 0.

r_q : Representa el corte de carga reactiva, el cuál en esta formulación también representa la compensación de potencia reactiva necesaria en algunas barras. Es el vector de ángulos de fase.

$\bar{r}_q, \underline{r}_q$: Representan los límites superiores e inferiores del corte de carga reactiva. O los valores máximos y mínimos de compensación de potencia reactiva.

$\mathbf{P}_G, \mathbf{Q}_G$: Son los vectores de generación de potencia activa y reactiva.

$\mathbf{P}_D, \mathbf{Q}_D$: Son los vectores de demanda de potencia activa y reactiva.

\mathbf{V} : Es el vector de magnitudes de tensión.

$\bar{\mathbf{P}}_G, \bar{\mathbf{Q}}_G$: Son los vectores de máximo límite de generación de potencia activa y reactiva.

$\bar{\mathbf{V}}$: Vector de límite máximo de magnitudes de tensión. Usualmente corresponde al 105% del valor nominal.

$\underline{\mathbf{P}}_G, \underline{\mathbf{Q}}_G$: Son los vectores de mínimo límite de generación de potencia activa y reactiva.

$\underline{\mathbf{V}}$: Vector de límite mínimo de magnitudes de tensión. Usualmente corresponde al 95% del valor nominal.

$\mathbf{s}^{from}, \mathbf{s}^{to}$: Son los vectores de flujo de potencia aparente en ambos extremos de una rama.

$\bar{\mathbf{s}}$: Vector de límite máximo de transporte de potencia aparente por las ramas.

Las ecuaciones (3.18) y (3.19) representan la formulación convencional del flujo de potencia AC. Los elementos de estos vectores se calculan de acuerdo a las ecuaciones (3.27) y (3.28) descritas a continuación:

$$P_k(\mathbf{V}, \boldsymbol{\theta}) = V_k \sum_{l \in M} V_l [G_{kl} \cos \theta_{kl} + B_{kl} \sin \theta_{kl}] \quad (3.27)$$

$$Q_k(\mathbf{V}, \boldsymbol{\theta}) = V_k \sum_{l \in M} V_l [G_{kl} \sin \theta_{kl} - B_{kl} \cos \theta_{kl}] \quad (3.28)$$

Los componentes S^{from}, S^{to} , pueden ser calculados de acuerdo a las ecuaciones (3.29) y (3.30) respectivamente.

$$S_{kl}^{from} = \sqrt{(P_{kl}^{from})^2 + (Q_{kl}^{from})^2} \quad (3.29)$$

$$S_{kl}^{to} = \sqrt{(P_{kl}^{to})^2 + (Q_{kl}^{to})^2} \quad (3.30)$$

Donde:

M : Representa el set de todas las barras del sistema.

kl : Son los circuitos entre la barra k y la barra l .

$\theta_{kl} = \theta_k - \theta_l$: Representa la diferencia entre los ángulos de fase entre barra k y la barra l .

El cálculo de los elementos de la matriz de admitancias G_{kl}, B_{kl} así como el cálculo de las potencias $P_{kl}^{from}, P_{kl}^{to}, Q_{kl}^{from}, Q_{kl}^{to}$, está descrito a detalle en el modelo AC original el cual fue expuesto anteriormente en este mismo documento en las ecuaciones de la 2.46 a la 2.53.

En la formulación descrita, la compensación shunt es modelada a través de corte de carga reactivo en términos del problema operacional ($\alpha_2 r_{Qk}$) en la ecuación (3.17), lo cual hace que el problema sea más fácil de resolver. En ese caso la compensación shunt obtenida será una variable continua a pesar de su naturaleza discreta. El costo de la compensación shunt es modelado usando solo el costo

variable a través de una función lineal de la forma indicada en la Figura 3.10. De esta manera la función de costos proporciona valores positivos tanto para la compensación capacitiva como inductiva, lo cual es conveniente para el proceso de optimización. A pesar de estas simplificaciones, el problema completo del PET podría ser más complejo, debido a que sería necesario usar técnicas de programación entera-mixta para resolver solamente la parte operacional, lo cual haría más difícil aun la aplicación de cualquier técnica de solución.

La formulación asume que no habrá variación en el consumo de potencia reactiva, basado en el factor de potencia, cuando ocurre el corte de carga.

En [62] se describen las ventajas principales de la formulación propuesta frente al estado del arte de la literatura existente en relación a la formulación AC:

- Es una formulación que puede ser considerada una extensión y generalización del popular enfoque de “corte de carga” usado en el modelo DC modificado.
- El enfoque de la propuesta puede manejar tanto generación despachable como generación no despachable.
- Esta formulación toma en cuenta la compensación shunt, la cual permite la optimización conjunta entre líneas de transmisión y fuentes de potencia reactiva en un solo paso.
- Esta formulación permite la aplicación de cualquier técnica de optimización (programación matemática, CHA, meta heurísticas, etc.)

Este trabajo de investigación se centrará por tanto en la solución del problema mediante los siguientes algoritmos meta heurísticos evolutivos siguientes: PE (Programación Evolutiva) con sin adaptación y una técnica consolidada de Estrategia Evolutiva auto adaptativa (EE) y Estrategia Evolutiva Auto adaptativa Modificada (EEM). Las mismas se han acoplado a la solución del problema del PET utilizando el modelo AC con técnicas de corte de carga. Varios escenarios y condiciones son aplicados al modelo durante los procesos de simulación.

Es importante tener un entendimiento claro en relación al esquema de corte de carga utilizado en el método propuesto [62], situación que se intenta aclarar con la siguiente descripción:

En el algoritmo de optimización, algunas topologías de transmisión generadas son evaluadas por un flujo de potencia óptimo AC (OPFAC) conforme las Ecuaciones de la (3.17) a la (3.26). Si una topología particular es factible, el OPFAC tendrá convergencia incluso en el caso de violación de restricciones. Una violación a una restricción es compensada inicialmente por el OPFAC a través del re despacho (lo cual es la vía más económica). Si esto no es posible, el OPFAC usará generadores artificiales (la vía más costosa). En este caso las siguientes situaciones pueden ocurrir:

- I) No existe corte de carga de potencia activa. Esto significa que los generadores ficticios no generan potencia activa ($\alpha_1 r_p = 0$). Esta situación solo es posible cuando la topología actual satisface las necesidades de potencia activa del sistema y no existe violación de las restricciones. Sin embargo, esto no necesariamente significa que la topología actual es la óptima debido a que en posteriores iteraciones planes más económicos que también cumplen todas las restricciones pueden ser encontrados.
- II) Existe corte de carga de potencia activa. Esto significa que los generadores ficticios generan potencia activa ($\alpha_1 r_p > 0$) y algunas violaciones a restricciones están presentes. En caso que esta opción sea permitida, los costos de producción α_1 de los generadores ficticios pueden ser establecidos, por ejemplo, como los costos actuales de la energía no suministrada o a un costo más alto que los costos actuales de expansión de aquella topología (es decir el costo de la topología de transmisión más costosa). Seleccionado los generadores artificiales con el costo de la energía no suministrada, nosotros estamos aceptando que el plan de transmisión final podría tener algún corte de carga. Seleccionando tales costos con un valor mucho mayor de manera que se penalice la función objetivo, entonces se conseguirá que el algoritmo de optimización en iteraciones subsiguientes discrimine los planes costosos producto de este

ajuste. Esta es una manera de rechazar la posibilidad de tener corte de carga en el plan final.

- III) No existe corte de carga de potencia reactiva. Esto significa que los generadores ficticios no generan potencia reactiva ($\alpha_2 r_Q = 0$). Por tanto no existe violaciones a las restricciones relacionadas con la potencia reactiva. Esta condición puede ser lograda en dos situaciones. La primera corresponde al caso cuando la topología de transmisión actual permite los caminos de potencia reactiva que requiere la carga, de tal suerte que no se requiere fuentes adicionales de potencia reactiva en el sistema. La segunda situación se relaciona con la definición de fuentes de potencia reactiva sin límites. Esta condición puede ser conseguida estableciendo el costo de producción α_2 de generación reactiva de los generadores iguales a cero ($\alpha_2 = 0$).
- IV) Existe corte de carga de potencia reactiva. La potencia reactiva es producida cuando existe alguna violación a las restricciones relacionadas. Cuando la topología actual contiene estas restricciones se necesita una producción de potencia reactiva ($\alpha_2 r_Q > 0$). Esta condición requiere que el costo de la compensación “shunt” sea siempre positiva. Para ello el coeficiente de costo es $\alpha_2 > 0$ en caso de la compensación capacitiva y $\alpha_2 < 0$ en el caso de compensación inductiva.

En el caso que determinada topología de transmisión no sea factible, el OPFAC del problema operacional no convergirá. Incluso, a pesar que la formulación de este problema se encuentra definido teniendo en mente la creación de soluciones factibles debido al abordaje por corte de carga, algunas ocasiones pueden producirse soluciones no factibles si el rango de generación de potencia de los generadores ficticios es demasiado estricto. En este caso, una manera de evitar la aparición de soluciones no factibles es establecer unos límites de generación suficientemente amplios. Adicionalmente, algunas soluciones no factibles pueden aparecer en aquellos escenarios donde no se permite compensación “shunt” ($\alpha_2 r_Q = 0$) y la topología actual de transmisión no tiene capacidad de manejar tal condición. Por lo tanto, en general, la manera de

abordar soluciones no factibles es penalizar w en la ecuación (3.16) con valores suficientemente altos de manera que aquella topología sea discriminada.

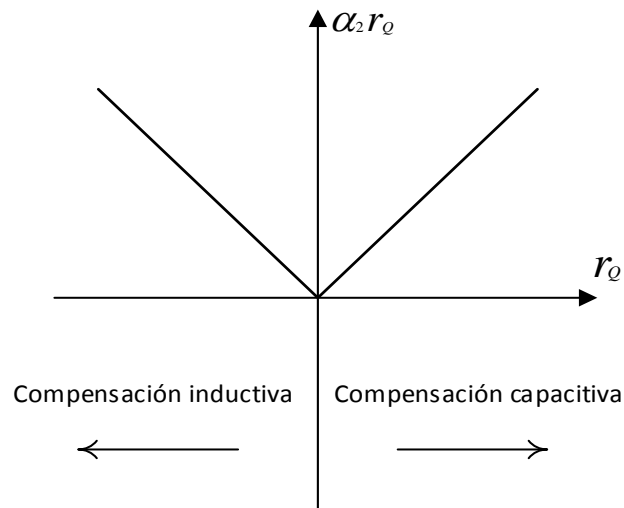


Figura 3.10 Función de costos para compensación de reactivos.

3.4.2 Implementación del algoritmo de solución mediante Programación Evolutiva (PE)

En el capítulos anteriores, se ha descrito lo formulación de los algoritmos de optimización mediante programación evolutiva, utilizando para ello pseudocódigos para describir su estructura de operación. En los siguientes párrafos se describirá como se utilizarán estos algoritmos de búsqueda para hallar soluciones aplicados al problema del PET.

Se abordarán la PE no adaptativa y adaptativa. La última como una mejora de la primera. Con las redes de prueba de Garver escenario con re despacho se validará el rendimiento de cada uno de ellos.

Programación Evolutiva Continua (PEC) sin adaptación

A pesar que el problema de PET es un problema con soluciones discretas, el uso del algoritmo de la PEC se adaptará para hacer que las búsquedas produzcan soluciones enteras. Como se manifestó anteriormente, en el presente trabajo, se ha reutilizado código de MATLAB existente tanto para el problema principal de expansión como para el problema operacional, los cuales están incorporados en un mismo código. Los algoritmos primarios se basan en [62]. Se destaca el uso del MATPOWER® y su herramienta de Flujo Óptimo de Potencia con el modelo de red AC (runopf.m). Con el propósito de entender de mejor manera como se ha abordado la solución del PET mediante este método de búsqueda se explica el siguiente pseudocódigo:

- I) **Ingresar los datos de la red.** Se cargan los datos del modelo de prueba. En el presente trabajo se utilizarán los modelos de Garver de 6 barras y el IEEE de 24 nodos con y sin re despacho.
- II) **Ajuste de parámetros generales.** Son parámetros importantes que tienen que ver con la convergencia del algoritmo y el método de solución heurístico o meta heurístico escogido. Estos son: número de individuos de la población de soluciones, número de iteraciones o generaciones, cantidad máxima de circuitos permitidos por cada derecho de vía en la red, cargar los datos del modelo de la red de pruebas a utilizar.
- III) **Inicializar los parámetros del PEC.** El modelo de búsqueda de soluciones se basa en la siguiente fórmula: $x'_i = x_i + r_i \sqrt{\beta f(x_i) + \gamma}$. La sintonización de los parámetros que han dado buenos resultados para los procesos de convergencia son los siguientes: $\beta = \#máximo\ de\ líneas / 10$, $\gamma = 0$.
- IV) **Creación inicial de la población de soluciones.** La población de soluciones consistirá en una matriz $m \times n$, con m igual a la cantidad de individuos de la población de soluciones y n corresponde a la dimensión del problema, que para el caso del PET son cada una de las ramas de la red eléctrica sobre las cuales se puede incorporar un camino adicional. Los valores de cada elemento de la matriz indicada corresponden a la cantidad de caminos o circuitos por cada derecho de vía que conecta dos barras. Con los parámetros establecidos en II, se genera de forma

aleatoria la población inicial de soluciones, usando para ello una distribución normal uniforme. Con un sencillo método de restricción se garantizará que la población inicial de soluciones no tenga individuos que tengan caminos que superen el límite máximo de circuitos por derechos de vía.

- V) **Evaluación inicial de costos.** El método iterativo propone una evaluación permanente de la función de costos de cada solución, por lo que incluso la población inicial requiere ser evaluada una vez que ha sido creada. Esto corresponde a la parte del problema principal de expansión. Una vez hecho esto se ordenan los individuos de la población por prelación, desde la solución más conveniente (la menos costosa) hasta la solución menos conveniente (la más costosa)
- VI) **Evaluación del criterio de parada.** Hasta que el criterio de parada sea satisfecho hacer:
- a. Normalizar el costo o la evaluación de la función objetivo FE. En este caso se hace que $1 \leq FE \leq 2$ de manera que su valor sea consistente con el rango de los parámetros de sintonía escogidos.
 - b. Actualiza la población de acuerdo a la ecuación
$$x'_i = x_i + r_i \sqrt{\beta f(x_i) + \gamma}.$$
 - c. Se restringe los individuos de la población de manera que la cantidad de circuitos por derecho de vía no supere el valor máximo permitido así como el número mínimo de circuitos no sea inferior a la topología inicial.
 - d. Se evalúan los costos de todos los individuos de la población generada. En este proceso se ejecutan secuencialmente las siguientes acciones:
 - i. Se calculan los parámetros de línea equivalentes para cada rama debido a la incorporación de circuitos en cada derecho de vía.

- ii. Para cada individuo (solución) de la población generada en cada iteración (generación) se calcula el flujo óptimo de potencia mediante la herramienta de MATPOWER® (runopf.m).
- iii. Se calculan los costos totales de cada solución (individuo de la población) como la sumatoria de los costos de adición de líneas nuevas más los costos de generación para la configuración óptima de despacho resultante del flujo óptimo de potencia AC. En este cálculo se penalizan (se colocan costos sumamente altos) a las soluciones que operacionalmente no sean factibles, es decir que no hayan satisfecho los criterios técnicos. Los costos de generación de potencia activa y reactiva están embebidos en los datos de los modelos de red, y es donde se puede controlar su impacto.
- e. Se actualizan las posiciones de los individuos de la población en función de su costo. Se incluye en esta comparación tanto los individuos de la generación anterior (padres) como los individuos de la población generada (hijos). Se seleccionan los mejores m individuos los cuales formarán parte de la próxima generación de padres.

VII) Fin.

En la figura No. 3.11 se muestra el diagrama de flujo que sintetiza el proceso anteriormente descrito.

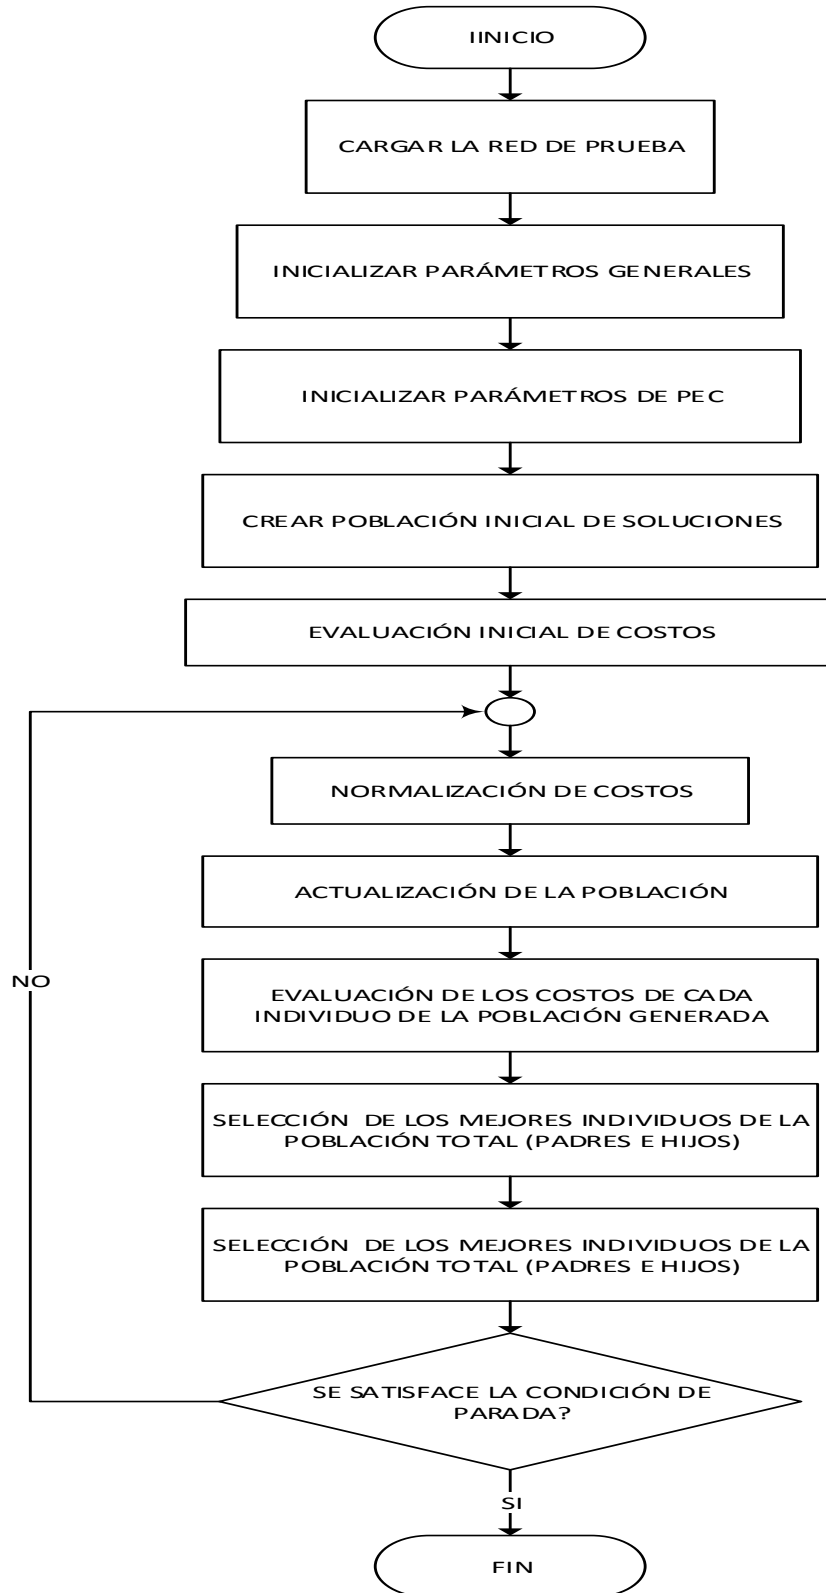


Figura 3.11 Diagrama de Flujo. Programación Evolutiva Continua sin adaptación.

Programación Evolutiva Continua (PEC) con adaptación

Es una variante del algoritmo de PEC sin adaptación. Como se indicó anteriormente, el algoritmo es modificado de tal manera que se identifiquen las varianzas de las mutaciones seleccionando aquellas asociadas a individuos de poblaciones anteriores que hayan tenido mayor éxito. El algoritmo se convierte en uno de tipo meta-heurístico con la inclusión de la mejora señalada precedentemente. El objetivo es mejorar la convergencia de la solución especialmente cuando el sistema se vuelve más grande. Lo descrito está plasmado en el siguiente pseudocódigo:

- I) **Ingresar los datos de la red.** Se cargan los datos del modelo de prueba. En el presente trabajo se utilizarán los modelos de Garver de 6 barras y el IEEE de 24 nodos con y sin re despacho.
- II) **Ajuste de parámetros generales.** Son parámetros importantes que tienen que ver con la convergencia del algoritmo y el método de solución heurístico o meta heurístico escogido. Estos son: número de individuos de la población de soluciones, número de iteraciones o generaciones, cantidad máxima de circuitos permitidos por cada derecho de vía en la red, cargar los datos del modelo de la red de pruebas a utilizar.
- III) **Inicializar los parámetros del PEC adaptativa.** El modelo de búsqueda de soluciones se basa en las fórmulas: $x'_i \leftarrow x_i + r_{xi}\sqrt{v_i}$, $v'_i \leftarrow v_i + r_{vi}\sqrt{cv_i}$. La sintonización de los parámetros que han dado buenos resultados para los procesos de convergencia son los siguientes: $\beta = \#máximo\ de\ líneas/10$, $\gamma = 0$. Los límites superior e inferior de las varianzas se sintonizaron en $var_{min} = \beta / 2$ y $var_{max} = \beta \times 2$. Se inicializan el parámetro $c = 1$ el cual sirve para la generación aleatoria de las varianzas.
- IV) **Creación inicial de la población de soluciones.** La población de soluciones consistirá en una matriz $m \times n$, con m igual a la cantidad de individuos de la población de soluciones y n corresponde a la dimensión del problema, que para el caso del PET son cada una de las ramas de la red eléctrica sobre las cuales se puede incorporar un camino adicional.

Los valores de cada elemento de la matriz indicada corresponden a la cantidad de caminos o circuitos por cada derecho de vía que conecta dos barras. Con los parámetros establecidos en II, se genera de forma aleatoria la población inicial de soluciones, usando para ello una distribución normal uniforme. Con un sencillo método de restricción se garantizará que la población inicial de soluciones no tenga individuos que tengan caminos que superen el límite máximo de circuitos por derechos de vía.

- V) **Creación inicial de la matriz de varianzas.** Se crea una matriz asociada a la población inicial. El método de creación hace uso de la varianza mínima var_{min} al cual se le suma la diferencia de la varianza máxima y la varianza mínima ($var_{max} - var_{min}$) multiplicada por un número aleatorio de distribución normal dentro del intervalo (0,1).
- VI) **Evaluación inicial de costos.** El método iterativo propone una evaluación permanente de la función de costos de cada solución, por lo que incluso la población inicial requiere ser evaluada una vez que ha sido creada. Esto corresponde a la parte del problema principal de expansión. Una vez hecho esto se ordenan los individuos de la población por orden de prelación, desde la solución más conveniente (la menos costosa) hasta la solución menos conveniente (la más costosa)
- VII) **Evaluación del criterio de parada.** Hasta que el criterio de parada sea satisfecho hacer:
- Normalizar el costo o la evaluación de la función objetivo FE. En este caso se hace que $1 \leq FE \leq 2$ de manera que su valor sea consistente con el rango de los parámetros de sintonía escogidos.
 - Actualiza la población de acuerdo a la ecuación $x'_i \leftarrow x_i + r_{xi} \sqrt{v_i}$. Actualiza la varianza de la población siguiente conforme la ecuación $v'_i \leftarrow v_i + r_{vi} \sqrt{cv_i}$, se calcula la máxima varianza de la matriz de varianzas de acuerdo a $v'_i \leftarrow \max(v'_i, var_{min})$. Esta última servirá para la generación de la siguiente generación.

- c. Se restringen los individuos de la población de manera que la cantidad de circuitos por derecho de vía no supere el valor máximo permitido.
- d. Se evalúan los costos de todos los individuos de la población generada. En este proceso se ejecutan secuencialmente las siguientes acciones:
 - i. Se calculan los parámetros de línea equivalentes para cada rama debido a la incorporación de circuitos en cada derecho de vía.
 - ii. Para cada individuo (solución) de la población generada en cada iteración (generación) se calcula el flujo óptimo de potencia mediante la herramienta de MATPOWER® (runopf.m).
 - iii. Se calculan los costos totales de cada solución (individuo de la población) como la sumatoria de los costos de adición de líneas nuevas más los costos de generación para la configuración óptima de despacho resultante del flujo óptimo de potencia AC. En este cálculo se penalizan (se colocan costos sumamente altos) a las soluciones que operacionalmente no sean factibles, es decir que no hayan satisfecho los criterios técnicos. Los costos de generación de potencia activa y reactiva están embebidos en los datos de los modelos de red, y es donde se puede controlar su impacto.
- e. Se actualizan las posiciones de los individuos de la población en función de su costo. Se incluye en esta comparación tanto los individuos de la generación anterior (padres) como los individuos de la población generada (hijos). Se seleccionan los mejores m individuos los cuales formarán parte de la próxima generación de padres.
- f. Se seleccionan las varianzas que produjeron las mutaciones de los mejores individuos de la población. Estas serán utilizadas para las siguientes iteraciones

VIII) Fin.

En la figura No. 3.12 se muestra el diagrama de flujo que sintetiza el proceso anteriormente descrito.

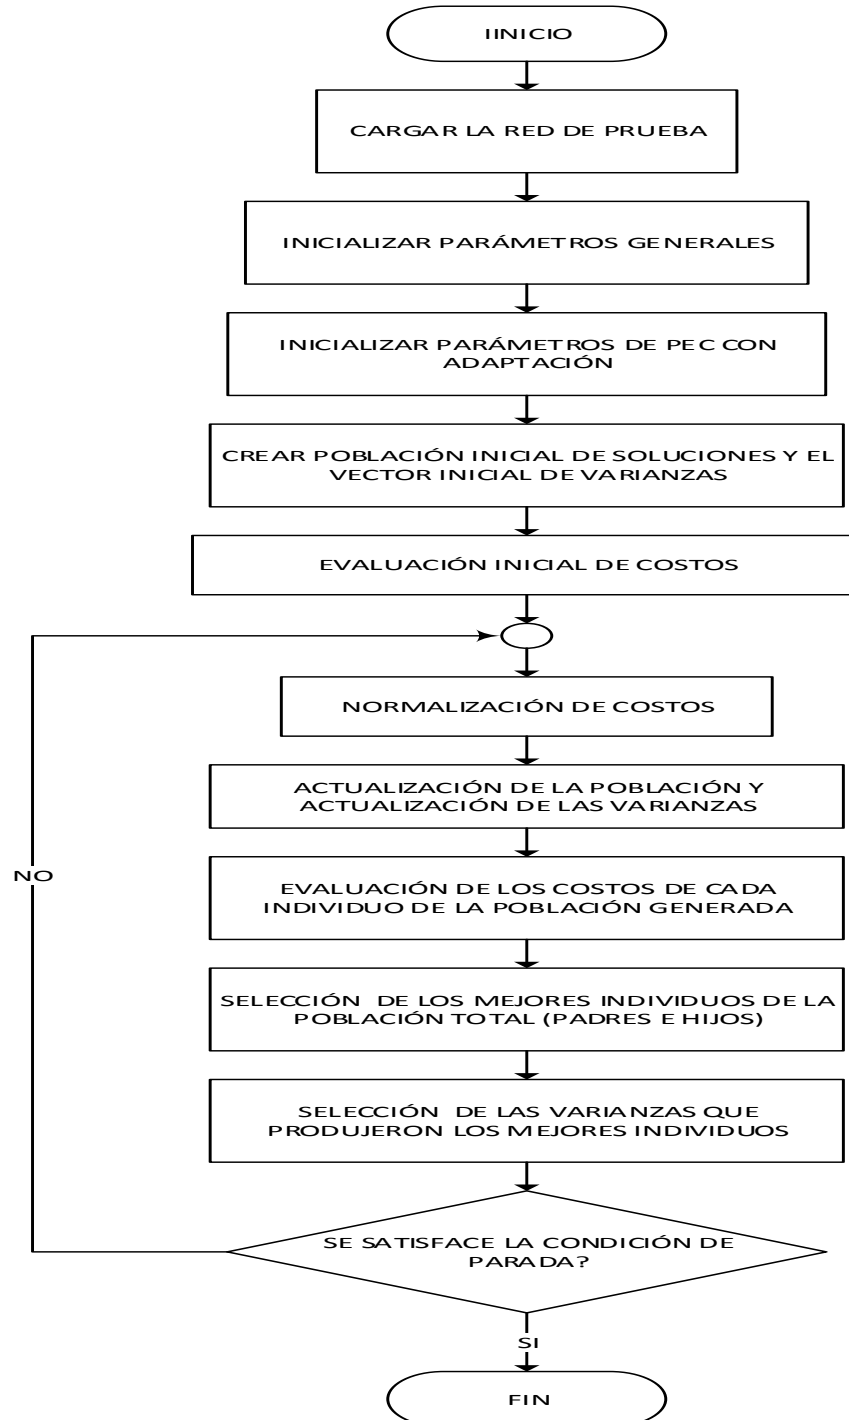


Figura 3.12 Diagrama de Flujo. Programación Evolutiva Continua con adaptación.

Para el presente trabajo, se ha visto que no existe mejora en el rendimiento cuando se utiliza el algoritmo de PEC adaptativo en relación al algoritmo simple de PEC.

3.4.3 Implementación del algoritmo de solución mediante Estrategias Evolutivas (EE) auto adaptativas

Una exploración de los algoritmos evolutivos nos lleva a buscar herramientas de un mayor nivel de eficiencia en el proceso de convergencia. El uso de estrategias auto adaptativas es una opción con una clara ventaja frente a la aplicación de la programación evolutiva simple. Esta estrategia de búsqueda de nuevas soluciones ha sido utilizada en el presente trabajo de investigación. Las variantes se presentan en el siguiente pseudocódigo:

- I) **Ingresar los datos de la red.** Se cargan los datos del modelo de prueba. En el presente trabajo se utilizarán los modelos de Garver de 6 barras y el IEEE de 24 nodos con y sin re despacho.
- II) **Ajuste de parámetros generales.** Son parámetros importantes que tienen que ver con la convergencia del algoritmo y el método de solución heurístico o meta heurístico escogido. Estos son: número de individuos de la población de soluciones, número de iteraciones o generaciones, cantidad máxima de circuitos permitidos por cada derecho de vía en la red, cargar los datos del modelo de la red de pruebas a utilizar.
- III) **Inicializar los parámetros de la EE auto adaptativa.** El modelo de búsqueda de soluciones se basa en las fórmulas: $x'_i \leftarrow x'_i + \sigma'_i r_i$ $\sigma'_i \leftarrow \sigma'_i e^{(\tau' \rho_0 + \tau \rho_i)}$. La sintonización de los parámetros que han dado buenos resultados para los procesos de convergencia en el problema tratado son los siguientes: $\tau = 150 (\sqrt{2\sqrt{n}})^{-1}$, $\tau' = 150 (\sqrt{2n})^{-1}$.
- IV) **Creación inicial de la población de soluciones.** La población de soluciones consistirá en una matriz $m \times n$, con m igual a la cantidad de

individuos de la población de soluciones y n corresponde a la dimensión del problema, que para el caso del PET son cada una de las ramas de la red eléctrica sobre las cuales se puede incorporar un camino adicional. Los valores de cada elemento de la matriz indicada corresponden a la cantidad de caminos o circuitos por cada derecho de vía que conecta dos barras. Con los parámetros establecidos en II, se genera de forma aleatoria la población inicial de soluciones, usando para ello una distribución normal uniforme. Con un sencillo método de restricción se garantizará que la población inicial de soluciones no tenga individuos con caminos que superen el límite máximo de circuitos por derechos de vía y no debe ser inferior a los circuitos de la topología base. Consiste en comparar luego de cada iteración la cantidad de caminos de cada solución y si superan el límite máximo forzar el valor generado aleatoriamente al máximo. Cosa semejante se hará para el valor mínimo.

- V) **Creación inicial del vector de desviaciones estándar.** Se crea una matriz de desviaciones estándar asociada a la población inicial. El rango de las desviaciones estándar se establece de forma aleatoria en los valores comprendidos entre $(-X_{max}, X_{max})$. Los cuales corresponden a la máxima cantidad de circuitos por derecho de vía. El signo menos en este rango permite que la búsqueda de nueva soluciones tenga una mejor flexibilidad en la búsqueda de soluciones, pues posibilita incrementar o disminuir circuitos por derecho de vía a lo largo del proceso meta heurístico.
- VI) **Evaluación inicial de costos.** El método iterativo propone una evaluación permanente de la función de costos de cada solución, por lo que incluso la población inicial requiere ser evaluada una vez que ha sido creada. Esto corresponde a la parte del problema principal de expansión. Una vez hecho esto se ordenan los individuos de la población por prelación, desde la solución más conveniente (la menos costosa) hasta la solución menos conveniente (la más costosa)
- VII) **Evaluación del criterio de parada.** Hasta que el criterio de parada sea satisfecho hacer:

- a. Se efectúa la mutación cruzada de padres. La generación de cada individuo de la siguiente población es obtenida por medio de la mutación cruzada de los mejores padres de la generación anterior a través de una selección aleatoria de circuitos por cada derecho de vía perteneciente a una solución o individuo de la población. Esta estrategia pretende ampliar el espacio de búsqueda de manera más eficiente.
- b. Actualiza la población y el vector de desviaciones estándar de acuerdo a las ecuaciones siguientes: $\sigma'_i \leftarrow \sigma'_i e^{(\tau' \rho_0 + \tau \rho_i)}$ para $i \in [1, n]$, $x'_k \leftarrow x'_k + \sigma'_i$. Se ha efectuado una modificación al algoritmo original pues se trabaja directamente con las desviaciones estándar y no con sus varianzas, pues permite al algoritmo “escapar” más fácilmente de los óptimos locales.
- c. Se restringe los individuos de la población de manera que la cantidad de circuitos por derecho de vía no supere el valor máximo permitido. Igual a lo señalado en el paso IV.
- d. Se evalúan los costos de todos los individuos de la población generada. En este proceso se ejecutan secuencialmente las siguientes acciones:
 - i. Se calculan los parámetros de línea equivalentes para cada rama debido a la incorporación de circuitos en cada derecho de vía.
 - ii. Para cada individuo (solución) de la población generada en cada iteración (generación) se calcula el flujo óptimo de potencia mediante la herramienta de MATPOWER® (runopf.m).
 - iii. Se calculan los costos totales de cada solución (individuo de la población) como la sumatoria de los costos de adición de líneas nuevas más los costos de generación para la configuración óptima de despacho resultante del flujo óptimo de potencia AC. En este cálculo se penalizan (se colocan costos sumamente altos) a las soluciones que operacionalmente no sean factibles,

es decir que no hayan satisfecho los criterios técnicos. Los costos de generación de potencia activa y reactiva están embebidos en los datos de los modelos de red, y es donde se puede controlar su impacto.

- e. Se actualizan las posiciones de los individuos de la población en función de su costo. Se incluye en esta comparación tantos los individuos de la generación anterior (padres) como los individuos de la población generada (hijos). Se seleccionan los mejores m individuos los cuales formarán parte de la próxima generación de padres.
- f. Se seleccionan las desviaciones estándar que produjeron las mutaciones de los mejores individuos de la población. Estas serán utilizadas para las siguientes iteraciones

VIII) Fin.

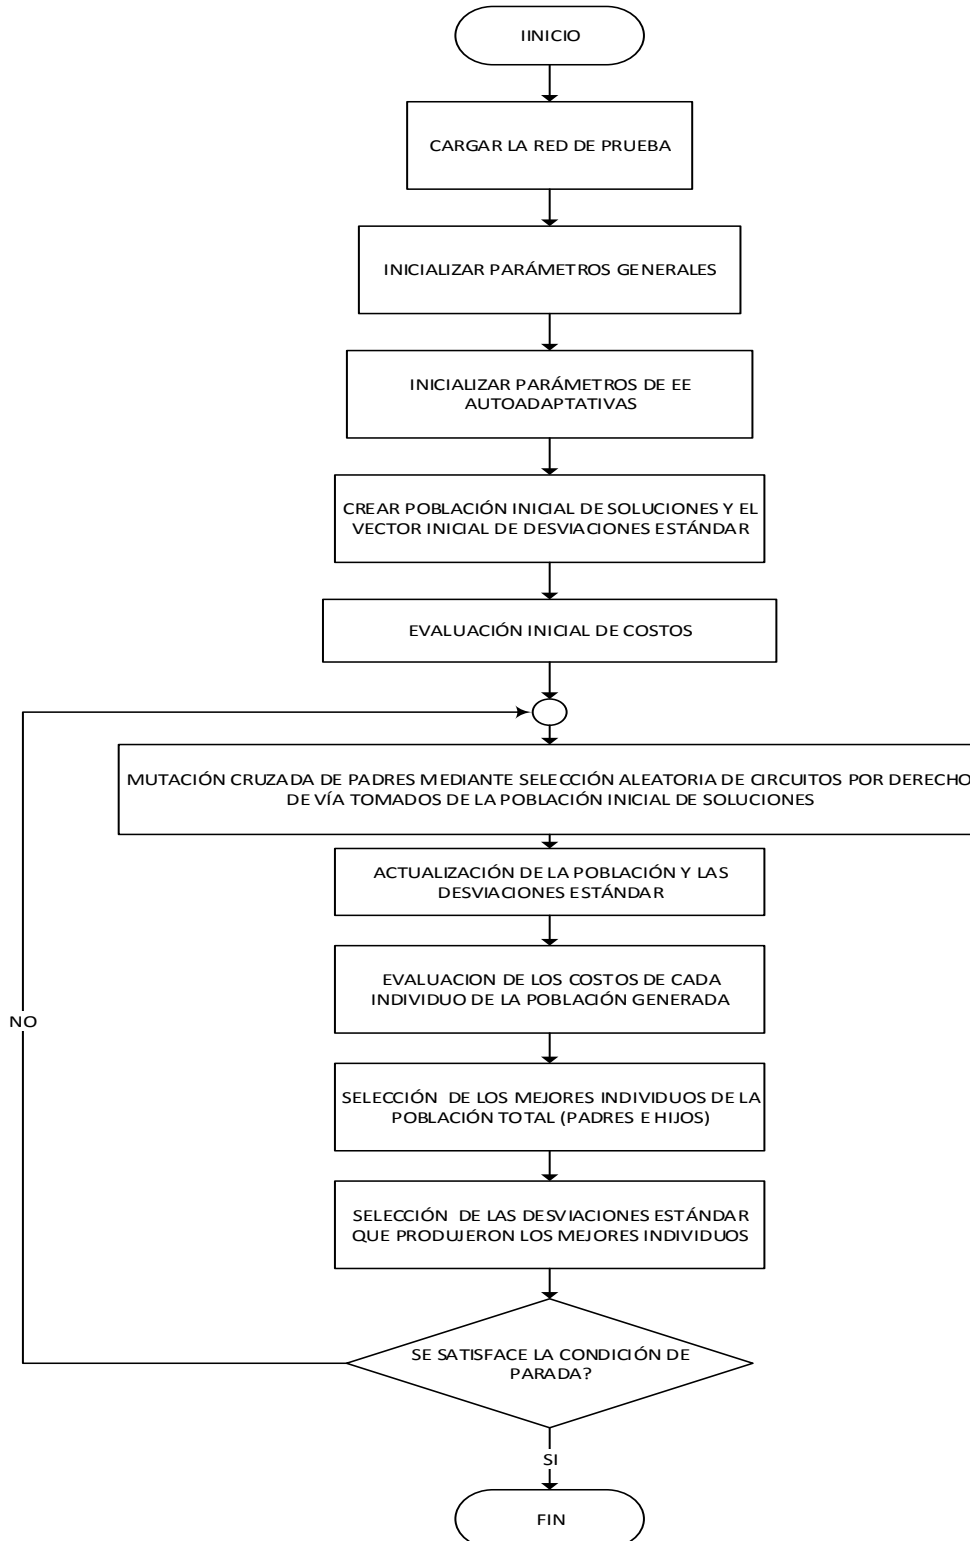


Figura 3.13 Diagrama de Flujo. Estrategia Evolutiva auto adaptativa. (EE)

3.4.4 Implementación del algoritmo de solución mediante Estrategias Evolutivas auto adaptativas modificadas (EEM)

De las pruebas efectuadas con los algoritmos de EE como están planteadas en el punto anterior, aún presentan limitaciones en cuanto a su capacidad de convergencia con el modelo de pruebas de Garver sin re despacho. Por este motivo un nivel de afinamiento adicional al algoritmo es propuesto en la Estrategia Evolutiva auto adaptativa modificada (EEM), la cual se basa en la EE con modificaciones conceptualmente explicadas y descritas de manera matemática en los párrafos anteriores.

Las modificaciones al algoritmo residen en los mecanismos de selección, los cuales usan dos alternativas:

- “Torneo de Selección” de los individuos más robustos mediante mecanismos aleatorios basados en la distribución uniforme. (Ver sección 3.3.6.2)
- Selección de los individuos más robustos basados en la “Sobre selección”. Como índices de selección se utilizan números aleatorios basados en las distribuciones Exponencial y de Weibull. (Ver sección 3.3.6.2)

La modificación al algoritmo se presenta en el siguiente pseudocódigo:

- I) **Ingresar los datos de la red.** Se cargan los datos del modelo de prueba. En el presente trabajo se utilizarán los modelos de Garver de 6 barras y el IEEE de 24 nodos con y sin re despacho.
- II) **Ajuste de parámetros generales.** Son parámetros importantes que tienen que ver con la convergencia del algoritmo y el método de solución heurístico o meta heurístico escogido. Estos son: número de individuos de la población de soluciones, número de iteraciones o generaciones, cantidad máxima de circuitos permitidos por cada derecho de vía en la red, cargar los datos del modelo de la red de pruebas a utilizar.
- III) **Inicializar los parámetros de la EE auto adaptativa.** El modelo de búsqueda de soluciones se basa en las fórmulas: $x'_i \leftarrow x'_i + \sigma'_i r_i$ $\sigma'_i \leftarrow \sigma'_i e^{(\tau' \rho_0 + \tau \rho_i)}$. La sintonización de los parámetros que han dado buenos

resultados para los procesos de convergencia en el problema tratado son los siguientes: $\tau = 150 (\sqrt{2\sqrt{n}})^{-1}$, $\tau' = 150(\sqrt{2n})^{-1}$. El resto de parámetros son calculados de acuerdo al algoritmo respectivo.

- IV) **Creación inicial de la población de soluciones.** La población de soluciones consistirá en una matriz $m \times n$, con m igual a la cantidad de individuos de la población de soluciones y n corresponde a la dimensión del problema, que para el caso del PET son cada una de las ramas de la red eléctrica sobre las cuales se puede incorporar un camino adicional. Los valores de cada elemento de la matriz indicada corresponden a la cantidad de caminos o circuitos por cada derecho de vía que conecta dos barras. Con los parámetros establecidos en II, se genera de forma aleatoria la población inicial de soluciones, usando para ello una distribución uniforme. Con un sencillo método de restricción se garantizará que la población inicial de soluciones no tenga individuos con caminos que superen el límite máximo de circuitos por derechos de vía.
- V) **Creación inicial del vector de desviaciones estándar.** Se crea una matriz de desviaciones estándar asociada a la población inicial. El rango de las desviaciones estándar se establece de forma aleatoria en los valores comprendidos entre $(-X_{max}, X_{max})$. Los cuales corresponden a la máxima cantidad de circuitos por derecho de vía. El signo menos en este rango permite que la búsqueda de nueva soluciones tenga una mejor flexibilidad en la búsqueda de soluciones, pues posibilita incrementar o disminuir circuitos por derecho de vía a lo largo del proceso meta heurístico.
- VI) **Evaluación inicial de costos.** El método iterativo propone una evaluación permanente de la función de costos de cada solución, por lo que incluso la población inicial requiere ser evaluada una vez que ha sido creada. Esto corresponde a la parte del problema principal de expansión. Una vez hecho esto se ordenan los individuos de la población por prelación, desde la solución más conveniente (la menos costosa) hasta la solución menos conveniente (la más costosa)

VII) **Evaluación del criterio de parada.** Hasta que el criterio de parada sea satisfecho hacer:

- a. Se efectúa la selección de padres mediante uno de los siguientes métodos:
 - Torneo de selección, del 20%,40% o 60% de los individuos más robustos de la generación anterior. La selección se realizará una a una por características del individuo (circuitos por derecho de vía).
 - Sobre selección. Se utilizara la selección aleatoria basada en la distribución de probabilidad Exponencial o de Weibull.
- b. Se efectúa de manera simultánea con la selección de características, el proceso de recombinación global para generar la descendencia o hijos de la generación presente.
- c. Actualiza la población y el vector de desviaciones estándar de acuerdo a las ecuaciones siguientes: $\sigma'_i \leftarrow \sigma'_i e^{(\tau' \rho_0 + \tau \rho_i)}$ para $i \in [1, n]$, $x'_k \leftarrow x'_k + \sigma'_i$. Se ha efectuado una modificación al algoritmo original pues se trabaja directamente con las desviaciones estándar y no con sus varianzas, pues permite al algoritmo “escapar” más fácilmente de los óptimos locales.
- d. Se restringe los individuos de la población de manera que la cantidad de circuitos por derecho de vía no supere el valor máximo permitido.
- e. Se evalúan los costos de todos los individuos de la población generada. En este proceso se ejecutan secuencialmente las siguientes acciones:
 - i. Se calculan los parámetros de línea equivalentes para cada rama debido a la incorporación de circuitos en cada derecho de vía.
 - ii. Para cada individuo (solución) de la población generada en cada iteración (generación) se calcula el flujo óptimo de potencia mediante la herramienta de MATPOWER® (runopf.m).

- iii. Se calculan los costos totales de cada solución (individuo de la población) como la sumatoria de los costos de adición de líneas nuevas más los costos de generación para la configuración óptima de despacho resultante del flujo óptimo de potencia AC. En este cálculo se penalizan (se colocan costos sumamente altos) a las soluciones que operacionalmente no sean factibles, es decir que no hayan satisfecho los criterios técnicos. Los costos de generación de potencia activa y reactiva están embebidos en los datos de los modelos de red, y es donde se puede controlar su impacto.
- f. Se actualizan las posiciones de los individuos de la población en función de su costo. Se incluye en esta comparación tanto los individuos de la generación anterior (padres) como los individuos de la población generada (hijos). Se seleccionan los mejores m individuos los cuales formarán parte de la próxima generación de padres. Ordenar los individuos escogidos desde el más robusto al menos robusto.
- g. Se seleccionan las desviaciones estándar que produjeron las mutaciones de los mejores individuos de la población. Estas serán utilizadas para las siguientes iteraciones

VIII) Fin.

En la Figura 3.14 se establece el diagrama de flujo de la Estrategia Evolutiva Modificada.

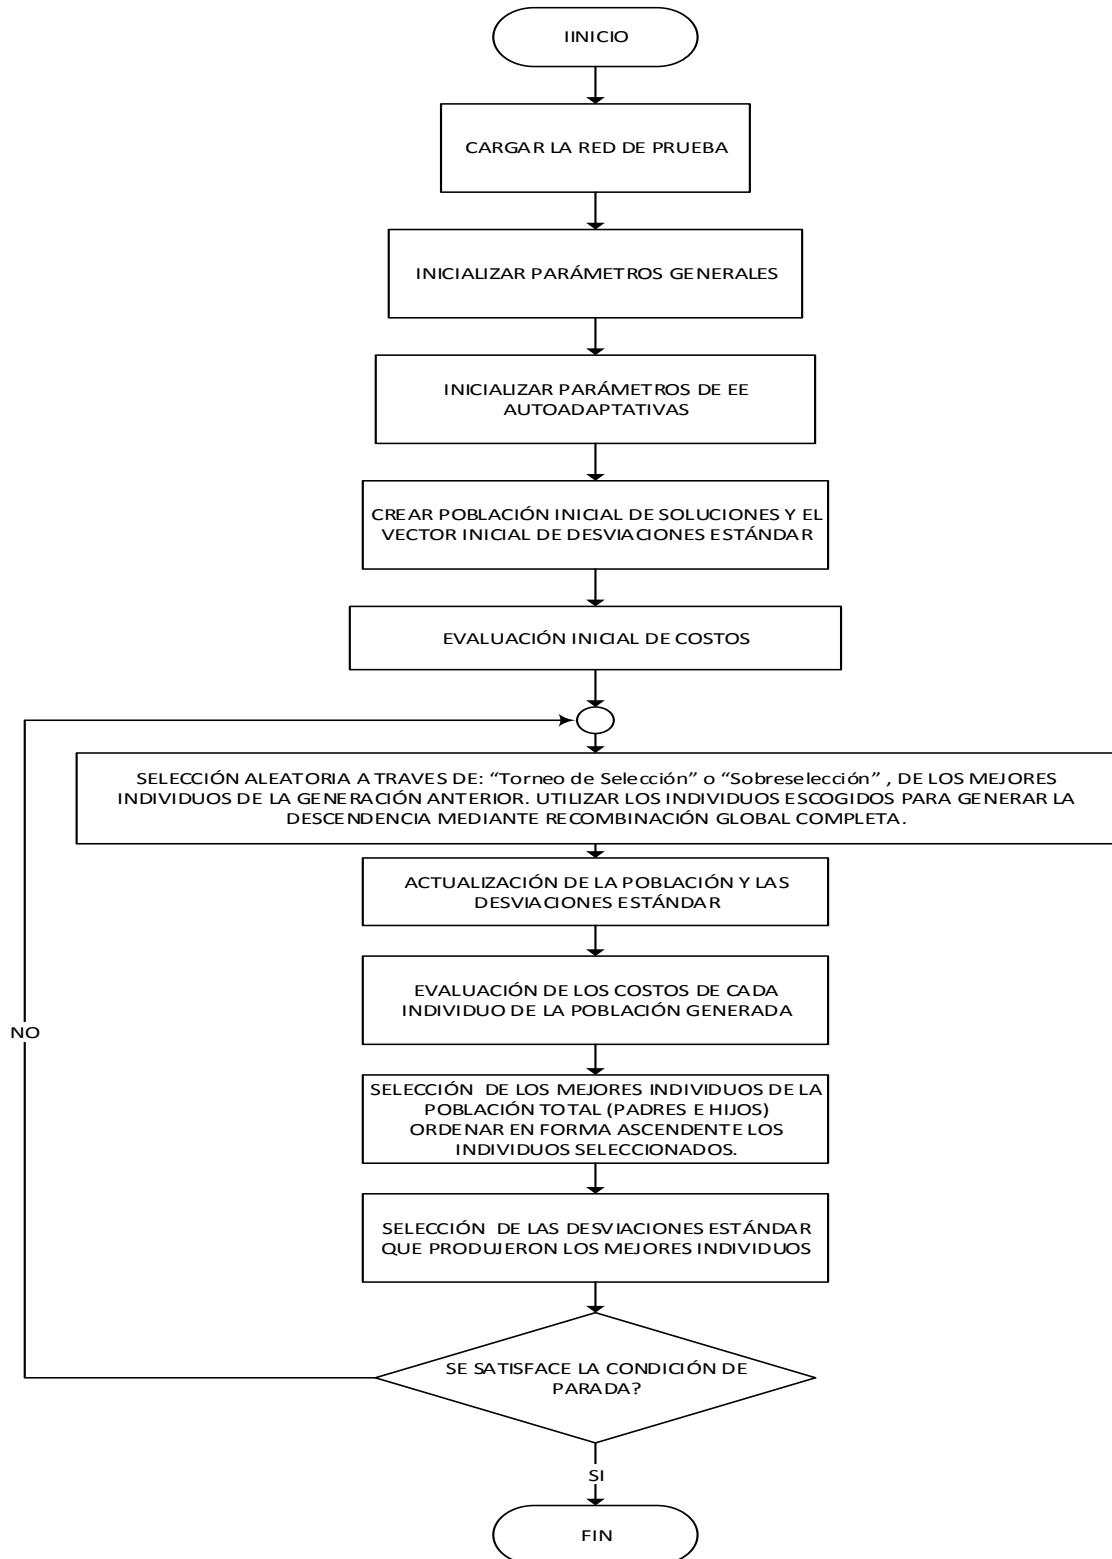


Figura 3.14 Diagrama de Flujo. Estrategia Evolutiva auto adaptativa modificada (EEM)

Capítulo 4

Pruebas y resultados

En este trabajo dos sistemas eléctricos fueron utilizados para solucionar el problema del planeamiento estático de expansión de los sistemas de transmisión: el sistema de Garver de 6 barras y el sistema IEEE de 24 barras. Estos sistemas son bien conocidos en la literatura, por lo que se establecen una base de comparación para los resultados obtenidos en este trabajo. Los datos usados para resolver el problema del PET usando el modelo AC pueden ser encontrados en [7], [62].

Para los sistemas de prueba se analizan dos situaciones [22]:

1. Problema con re despacho. Existe holgura en generación, así los generadores pueden ser ajustados de mejor forma posible, dentro de los límites especificados.
2. Problema sin re despacho. No existe holgura en los generadores, por lo que estos tienen una generación fija.

Se utilizan tres algoritmos de optimización: el primero corresponde al de Programación Evolutiva (PE) con y sin uso de mecanismos adaptativos, el segundo es el de Estrategias Evolutivas (EE) auto adaptativas y el tercero es el de Estrategias Evolutivas Modificadas (EEM). Los resultados para cada método de solución se presentan para los casos con y sin re despacho. No se analizan condiciones de contingencia.

Los algoritmos PE y EE fueron implementados en un ambiente MATLAB, funcionando en una plataforma de hardware Intel i7, Q740, 1.736GHz, 8GB de RAM. La herramienta de código abierto MATPOWER [34], es bien conocida para el análisis de sistemas de potencia, la cual fue utilizada con el propósito de evaluar la función objetivo utilizando el modelo de flujo de potencia óptimo AC (AC-OPF). La herramienta para resolver el flujo de potencia óptimo AC en MATPOWER es el paquete TSOPF [65], la cual implementa una técnica especial de punto interior.

4.1 Planeamiento Clásico

El algoritmo propuesto para solucionar el problema de planeamiento estático de expansión de sistemas de transmisión fue probado para los dos sistemas cuyas soluciones pueden ser encontradas en [4], [20].

La solución de planeamiento con re despacho de generación fue el punto de partida para estudiar el desempeño de los algoritmos de PE y EE. Debido a que no se tienen criterios previos de desempeño de estos sistemas, se espera que los resultados puedan servir como una referencia de partida.

Para el caso del planeamiento sin re despacho de generación, se aplicaron también las versiones de PE y EE, sabiendo que este tipo de planeamiento exige mayor esfuerzo para encontrar la solución óptima, y podrían considerarse con una buena manera de establecer la capacidad de convergencia de los algoritmos de búsqueda de este trabajo de investigación.

4.1.1 Sistema Garver de 6 barras

El sistema de Garver, mostrado en la Figura 5.1, es muy utilizado para presentar los resultados sobre la PET. Este sistema consiste de 6 barras 15 caminos candidatos y una demanda prevista de 760MW. El número máximo posible de líneas adicionadas por camino es igual a 5 y el número de topologías posibles es $(5 + 1)^{15} = 6^{15}$ equivalente a algo más de 470 mil millones de configuraciones que se podrían analizar.




Figura 4.1: Sistema Garver – Topología base

4.1.1.1. Garver con Re despacho (aplicando PE y EE)

Se analizan dos escenarios para el sistema de Garver con re despacho: el primero de ellos sin límite de reactivos, lo llamaremos Garver_AC_b1. En este modelo se permiten tener reactivos ilimitados o compensación shunt con un costo de \$0/Mvar. Se modelan los reactivos a través de los generadores artificiales. Utilizando los algoritmos PE no adaptativo, PE adaptativo y EE auto adaptativa el menor valor de inversión encontrado en el modelo explicado es $v = \text{US\$ } 110.000$ [20] e implica la adición de las siguientes líneas:

$$n_{3-5} = 1; n_{4-6} = 3$$

Es decir fue incorporada una línea entre las barras 3 y 5, y tres líneas entre las barras 4 y 6. Para este plan adicionalmente se establece que se requiere una compensación shunt de 96.87 Mvar añadidos a la barra 2.

El siguiente escenario analizado para el sistema de Garver con res despacho, es aquel en el cual no se permite tener compensación de reactivos, al cual lo llamaremos Garver_AC_b2. En este modelo no se permite la compensación de reactivos lo que se consigue al “apagar” los generadores de reactivos artificiales. Este es un esquema menos relajado al anterior, por lo que la solución esperada siempre será más costosa y se espera que la convergencia sea un poco más compleja durante el proceso de optimización. Utilizando los algoritmos PE no adaptativo, PE adaptativo y EE auto adaptativa, el menor valor de inversión encontrado en el modelo explicado es $v = \text{US\$ } 160.000$ [20] e implica la adición de las siguientes líneas:

$$n_{2-6} = 2; n_{3-5} = 2, n_{4-6} = 2$$

Se compara el desempeño de los algoritmos PE y EE aplicados al modelo de red Garver con compensación shunt y sin compensación shunt. El propósito es observar la razón de convergencia en cada uno de los algoritmos así como su robustez. Para las simulaciones se establece un límite máximo de 300 iteraciones, y alternativamente se prueban los resultados para 40, 60, 80, 100 y 120 individuos en cada generación. Para el caso de la Programación Evolutiva (PE) se probaron las variantes con y sin adaptación. Se utilizó una sola Estrategia Evolutiva (EE) auto adaptativa. Los resultados se muestran en las tablas desde la 4.1 hasta la 4.6.

Tabla 4.1: Desempeño de Programación Evolutiva sin adaptación (PE). Modelo de Garver AC sin restricción de reactivos. Max 300 iteraciones.

Individuos	40	60	80	100	120
Tasa de éxito (%)	100	100	100	100	100
# de iteraciones promedio	177	183	143	123	141
Desv. Est.# número de iteración promedio	82	49	51	42	43
# promedio evaluaciones de la función de costo FE	7080	10980	11440	12300	16920
v Mínimo	110000	110000	110000	110000	110000
v Máximo	110000	110000	110000	110000	110000
v Promedio	110000	110000	110000	110000	110000

Tabla 4.2: Desempeño de Programación Evolutiva con adaptación (PE). Modelo de Garver AC sin restricción de reactivos. Max 300 iteraciones

Individuos	40	60	80	100	120
Tasa de éxito (%)	90	100	100	100	100
# de iteraciones promedio	194	191	158	149	155
Desv. Est.# número de iteración promedio	58	48	52	44	28
Valor promedio FE	7760	11460	12640	14900	18600
v Mínimo	110000	110000	110000	110000	110000
v Máximo	130000	110000	110000	110000	110000
v Promedio	112000	110000	110000	110000	110000

Tabla 4.3: Desempeño de Estrategia Evolutiva auto adaptativa (EE). Modelo de Garver AC sin restricción de reactivos. Max 300 iteraciones.

Individuos	40	60	80	100	120
Tasa de éxito (%)	60	100	100	100	100
# de iteraciones promedio	42	34	31	27	44
Desv. Est.# número de iteración promedio	13	16	9	6	59
Valor promedio FE	1680	2040	2480	2700	5280
v Mínimo	110000	110000	110000	110000	110000
v Máximo	150000	110000	110000	110000	110000
v Promedio	123000	110000	110000	110000	110000

Tabla 4.4: Desempeño de Programación Evolutiva sin adaptación (PE). Modelo de Garver AC sin compensación de reactivos. Max 300 iteraciones.

Individuos	40	60	80	100	120
Tasa de éxito (%)	60	50	60	60	80
# de iteraciones promedio	237	219	240	220	220
Desv. Est.# número de iteración a v Mínimo	30	33	44	53	46
Valor promedio FE	9480	13140	19200	22000	26400
v Mínimo	160000	160000	160000	160000	160000
v Máximo	190000	190000	180000	180000	180000
v Promedio	168000	173000	166000	166000	163000

Tabla 4.5: Desempeño de Programación Evolutiva con adaptación (PE). Modelo de Garver AC sin compensación de reactivos. Max 300 iteraciones.

Partículas	40	60	80	100	120
Tasa de éxito (%)	40	70	70	100	100
# de iteraciones promedio	186	208	229	209	184
Desviación estándar iteraciones	63	34	50	38	27
Valor promedio FE	7440	12480	18320	20900	22080
v Mínimo	160000	160000	160000	160000	160000
v Máximo	180000	180000	180000	160000	160000
v Promedio	172000	164000	164000	160000	160000

Tabla 4.6: Desempeño de Estrategia Evolutiva auto adaptativa (EE). Modelo de Garver AC sin compensación de reactivos. Max 300 iteraciones

Individuos	40	60	80	100	120
Tasa de éxito (%)	40	80	90	80	90
# de iteraciones promedio	65	34	34	35	33
Desviación estándar iteraciones	85	15	7	12	10
Valor promedio FE	2600	2040	2720	3500	3960
v Mínimo	160000	160000	160000	160000	160000
v Máximo	220000	200000	170000	190000	170000
v Promedio	173000	168000	161000	164000	161000

Los resultados obtenidos y expresados en las tablas anteriores concuerdan con lo indicado en [7], [62] tanto para las condiciones de generación sin restricción de reactivos como para aquella con límite de reactivos, en cuanto a la cantidad de valor de mínima inversión obtenida. En estos ensayos no se registraron los tiempos de cálculo, pues el propósito fue observar el comportamiento y capacidad de convergencia de los algoritmos de partida PE y EE para el sistema de prueba de Garver. Son de interés dos parámetros: el primero corresponde al número de iteraciones promedio, el cual es un promedio estadístico del número de iteraciones requeridas por cada simulación hasta que la función objetivo llegue a su valor de estado estable el cual puede ser un mínimo local o un mínimo global. Este parámetro demuestra la robustez del algoritmo y su capacidad de desplazarse en el espacio de

búsqueda. El segundo parámetro corresponde a la desviación estándar calculada en base a los resultados de cada una de las 10 simulaciones obtenidas, el cual es un indicativo de la capacidad de convergencia del algoritmo utilizado.

Al utilizar algoritmos heurísticos de PE con y sin adaptación en el caso de Garver sin límite de reactivos (Tablas 5.1 y 5.2), que es la condición más relajada del modelo de pruebas, se observó que no existe mucha diferencia de desempeño entre los dos algoritmos de solución. Con una tasa de convergencia representada por el número de iteraciones promedio requeridas entre 150 y 200. Adicionalmente la desviación estándar de las simulaciones esta entre 30 y 80. Esto indica que el algoritmo como está planteado tiene un alto componente de búsqueda aleatoria, a pesar de varias pruebas con diferentes parámetros de sintonización. Por otra parte, con relación a la aplicación del algoritmo meta heurístico EE auto adaptativa, el desempeño es notablemente mejorado pues la tasa promedio de iteraciones se encuentra en el rango de 30 a 40. En forma paralela la desviación estándar de los resultados de las 10 simulaciones oscila entre rango de 5 a 15, para el conjunto de individuos 40,60,80 y 100, un caso particular se nota cuanto se utilizan 120 individuos donde la desviación estándar del número de iteraciones promedio de todas las simulaciones sube a 44. Se podría entender que incrementar la cantidad de individuos más allá de 100 en el algoritmo de EE auto adaptativas, tal como está planteado no resulta un aporte mayor y al contrario podría ser contraproducente pues el comportamiento del algoritmo tiende a convertirse en un proceso de búsqueda aleatoria.

Se han repetido las simulaciones anteriores para un caso menos relajado del modelo de prueba Garver, al no permitir compensación shunt mediante generación de reactivos. Como se explicó en párrafos anteriores en este caso se desactivaron los generadores artificiales para el OPF, pero se permitió el re despacho en las barras de generación. Los resultados de la aplicación de los algoritmos PE con y sin adaptación, así como la aplicación de la EE auto adaptativa se muestran en las Tablas 4.4, 4.5 y 4.6. Como era de esperarse el desempeño de a PE es aún más débil que el caso anterior, pues por una parte disminuye la tasa de éxito y se incrementó el número de iteraciones promedio requeridas por simulación. Sin embargo para el número máximo de iteraciones, la tasa de éxito conseguida para la PE con adaptación llega a ser del 100%. Un mejor rendimiento se observa en la EE

auto adaptativa donde el número de iteraciones promedio está en el rango de las 30 y desviaciones estándar de la cantidad de iteraciones requeridas por simulación está en el orden de la 15. A pesar de tener una mejor capacidad de convergencia frente a los algoritmos anteriores, la tasa de éxito para 120 individuos se sitúa en el 90%. Esto de cierta manera señala el camino de la investigación en las siguientes fases de este estudio. La EE deberá sufrir algunas mejoras con el propósito de tener un desempeño adecuado para el sistema de pruebas de Garver y ser aceptable para sistemas de mayor tamaño.




Figura 4.2: Solución del Sistema de Garver con re despacho

Del comportamiento de los diferentes algoritmos, se nota claramente que el más robusto es el que utiliza Estrategias Evolutivas auto adaptativas, que tiene una notable ventaja en cuanto a convergencia frente a la Programación Evolutiva. Es clara la ventaja para la solución del problema de TEP del algoritmo meta heurístico EE sobre el algoritmo heurístico PE en cualquiera de sus variantes. Por lo indicado, en las siguientes simulaciones se hará uso únicamente de las EE para la solución del problema de TEP y se aplicarán algunas variantes para poder tener una idea de la línea de mejora que estos algoritmos deberán seguir para la solución de este problema.

En las Figuras de la 4.3 a la 4.8 se han representado las características de convergencia de cada uno de los algoritmos PE y EE para el sistema de Garver con y sin compensación shunt, para los casos con la cantidad de individuos por población de mejor rendimiento global. Se han efectuado 10 ensayos y por cada uno de ellos se ha permitido se ejecuten hasta 300 iteraciones en el algoritmo probado. Los resultados evidencian lo indicado en los párrafos anteriores.

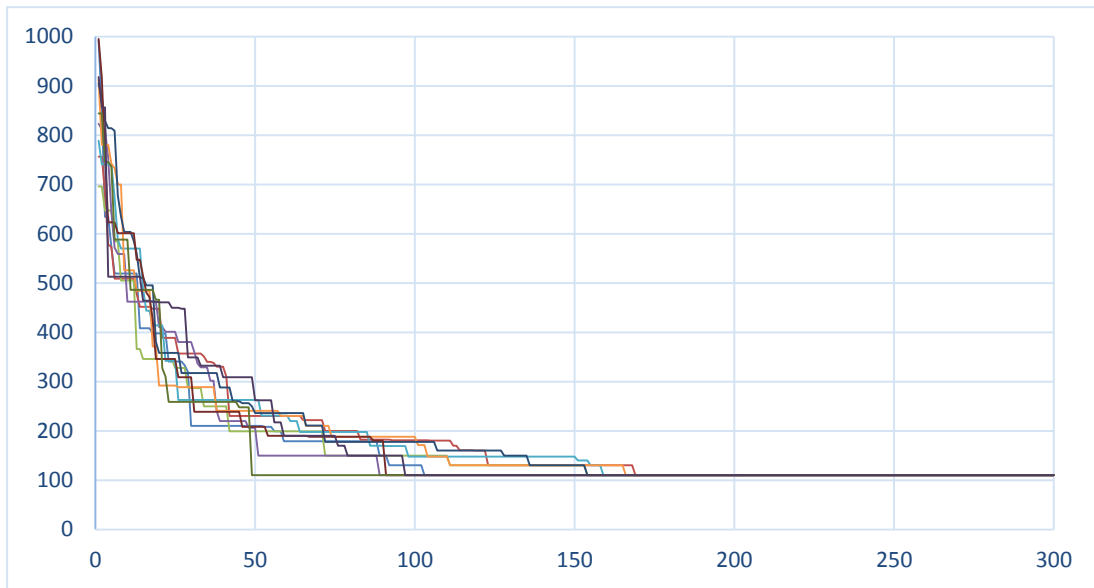


Figura 4.3 Representación de la convergencia de PE sin adaptación para 10 ensayos. Garver AC con compensación shunt \$0/Mvar. Población de 100 individuos.

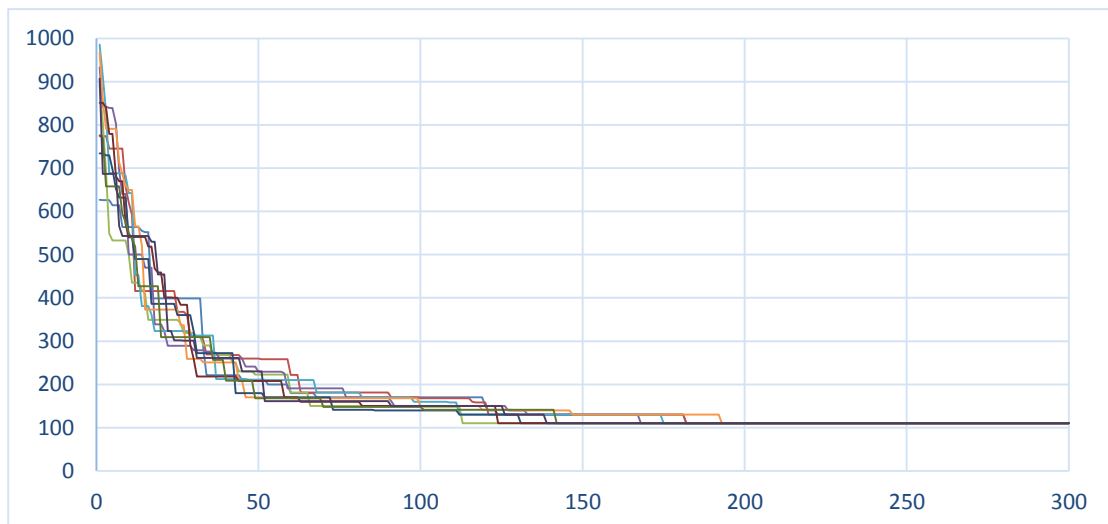


Figura 4.4 Representación de la convergencia de PE con adaptación para 10 ensayos. Garver AC con compensación shunt \$0/Mvar. Población 120 individuos.




Figura 4.5 Representación de la convergencia de EE auto adaptativa para 10 ensayos. Garver AC con compensación shunt \$0/Mvar. Población 100 individuos.

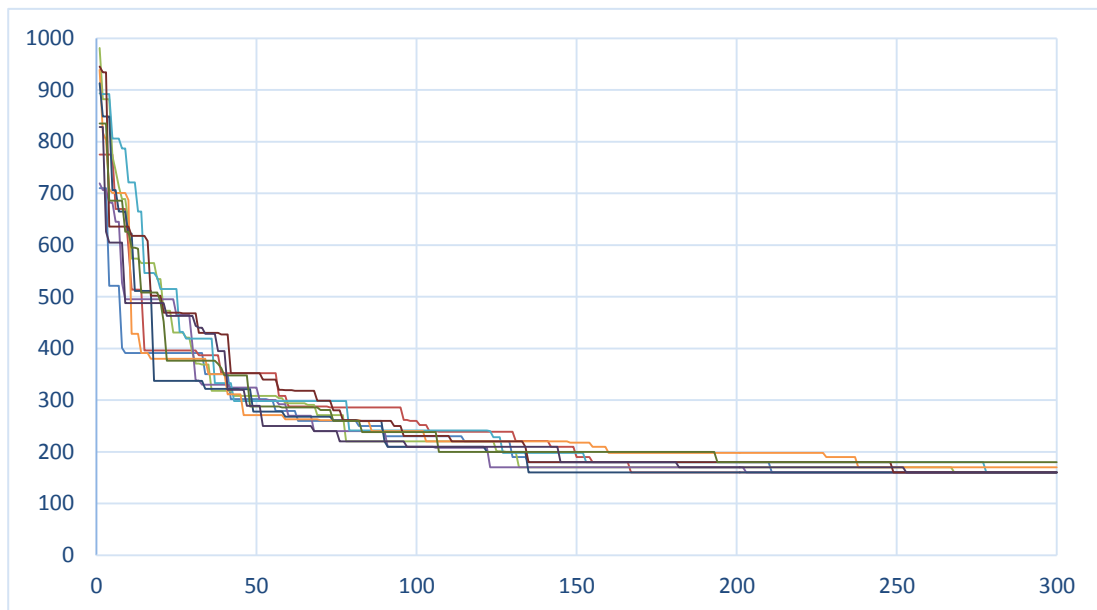


Figura 4.6 Representación de la convergencia de PE sin adaptación para 10 ensayos. Garver AC sin compensación shunt. Población 120 individuos.




Figura 4.7 Representación de la convergencia de PE con adaptación para 10 ensayos. Garver AC sin compensación shunt. Población 120 individuos.




Figura 4.8 Representación de la convergencia de EE auto adaptativa para 10 ensayos. Garver AC sin compensación shunt. Población 120 individuos.

A continuación, para el sistema de Garver sin re despacho, el cual es menos relajado que los modelos anteriores, se probará únicamente el rendimiento del

algoritmo de EE auto adaptativas para diferente cantidad de individuos de cada población, y determinar la selección de mejor rendimiento.

4.1.1.2. Garver sin Re despacho (aplicando EE)

El escenario de Garver sin re despacho implica que los generadores mantienen su nivel de generación establecido durante el proceso de solución del Flujo Optimo de Potencia. Se analizan algunos escenarios bajo esta condición. El primero de ellos, al que lo designaremos como Garver_AC-a1, corresponde a la generación de reactivos ilimitados con un costo de \$0/MVAR. Este modelo corresponde a la condición más relajada. En el segundo escenario de Garver sin re despacho no se permite generación de reactivos, lo designaremos como Garver_AC-a2 corresponde a la condición menos relajada. Finalmente se utilizará un modelo intermedio, en el cual se permiten reactivos en generación pero asignándoles un costo, que corresponde a una condición más realista, en este caso se ha asignado un valor de \$1000/MVAR, este último está designado como Garver_AC-a3. Para estos modelos de Garver sin re despacho se ha aplicado únicamente la Estrategia Evolutiva auto adaptativa (EE), debido a sus mejores prestaciones y no cabría sentido utilizar los algoritmos anteriores analizados de PE que tienen un menor desempeño que el indicado. Este algoritmo es el que servirá como referencia para comparación frente a otros algoritmos evolutivos utilizados para resolver el problema del PET utilizando el modelo AC. Se han ejecutado 10 simulaciones para poblaciones de 80, 100 y 120 individuos para cada uno de los modelos de Garver sin re despacho.

En el caso del modelo de Garver_AC-a1, el mínimo costo de inversión encontrado es de $v = \text{US\$ } 170 \times 1000$ [20] con una topología final encontrada que adiciona las siguientes líneas:

$$n_{2-6} = 3; n_{3-5} = 1; n_{4-6} = 2$$

Para el modelo de Garver_AC-a2, el mínimo costo de inversión encontrado es de $v = \text{US\$ } 261 \times 1000$ [20] con una topología final encontrada que adiciona las siguientes líneas:

$$n_{2-5} = 1; n_{2-6} = 5; n_{3-5} = 1; n_{4-6} = 2$$

Finalmente para el modelo de garver_AC-a3, el resultado es igual al caso anterior, el mínimo costo de inversión encontrado es de $v = \text{US\$ } 261 \times 1000$, con un costo de compensación shunt de $\text{US\$}63.96 \times 1000$. La topología final encontrada que adiciona las siguientes líneas:

$$n_{2-5} = 1; n_{2-6} = 4; n_{3-5} = 1; n_{4-6} = 3$$

En las tablas de la 4.7 a la 4.9 se describen las características de convergencia para el caso de Garver sin re despacho para los diferentes modelos explicados en los párrafos anteriores.

Tabla 4.7: Desempeño de Estrategia Evolutiva auto adaptativa (EE). Modelo de Garver AC sin re despacho, sin límite de reactivos US\$0/MVar. Max 100 iteraciones.

Garver_AC-a1.

Individuos	80	100	120
Tasa de éxito (%)	70	60	40
# de iteraciones promedio	44	46	51
Desviación estándar iteraciones	17	16	19
Valor promedio FE	3520	4600	6120
v Mínimo	170000	170000	170000
v Máximo	201000	208000	201000
v Promedio	179000	183000	187000

Tabla 4.8: Desempeño de Estrategia Evolutiva auto adaptativa (EE). Modelo de Garver AC sin re despacho, sin compensación shunt. Max 100 iteraciones.

Garver_AC-a2.

Individuos	80	100	120
Tasa de éxito (%)	30	50	30
# de iteraciones promedio	39	33	40
Desviación estándar iteraciones	11	8	15
Valor promedio FE	3120	3300	4800
v Mínimo	261000	261000	261000
v Máximo	290000	270000	270000
v Promedio	271000	266000	267000

Tabla 4.9: Desempeño de Estrategia Evolutiva auto adaptativa (EE). Modelo de Garver AC sin re despacho, sin límite de reactivos US\$1000/MVar. Max 100 iteraciones. Garver_AC-a3.

Individuos	80	100	120
Tasa de éxito (%)	40	60	50
# de iteraciones promedio	36	33	31
Desviación estándar iteraciones	14	9	7
Valor promedio FE	2880	3300	3720
v Mínimo	261000	261000	261000
v Máximo	280000	270000	270000
v Promedio	267000	265000	265000

Las características de convergencia de las tablas 4.7 a la 4.9 se pueden apreciar con claridad en las Figuras respectivas desde la 4.9 a la 4.17 representados a continuación:




Figura 4.9 Representación de la convergencia de EE auto adaptativa para 10 ensayos. Población 80 individuos. Garver AC sin re despacho, sin límite de reactivos. Garver_AC-a1




Figura 4.10 Representación de la convergencia de EE auto adaptativa para 10 ensayos. Población 100 individuos. Garver AC sin re despacho, sin límite de reactivos. Garver_AC-a1




Figura 4.11 Representación de la convergencia de EE auto adaptativa para 10 ensayos. 120 individuos. Garver AC sin re despacho, sin límite de reactivos. Garver_AC-a1




Figura 4.12 Representación de la convergencia de EE auto adaptativa para 10 ensayos. Población 80 individuos. Garver AC sin re despacho, sin compensación shunt. Garver_AC-a2

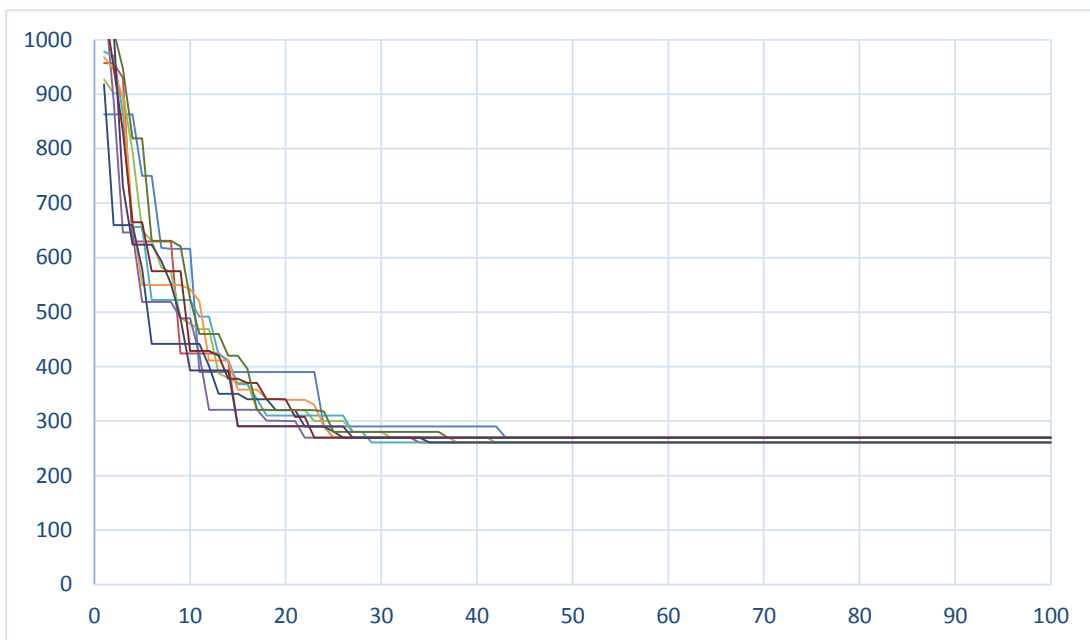


Figura 4.13 Representación de la convergencia de EE auto adaptativa para 10 ensayos. Población 100 individuos. Garver AC sin re despacho, sin compensación shunt. Garver_AC-a2




Figura 4.14 Representación de la convergencia de EE auto adaptativa para 10 ensayos. Población 120 individuos. Garver AC sin re despacho, sin compensación shunt. Garver_AC-a2




Figura 4.15 Representación de la convergencia de EE auto adaptativa para 10 ensayos. Población 80 individuos. Garver AC sin re despacho, compensación shunt US\$1000/MVar. Garver_AC-a3




Figura 4.16 Representación de la convergencia de EE auto adaptativa para 10 ensayos. 100 individuos. Garver AC sin re despacho, compensación shunt US\$1000/MVar. Garver_AC-a3




Figura 4.17 Representación de la convergencia de EE auto adaptativa para 10 ensayos. Población 120 individuos. Garver AC sin re despacho, compensación shunt US\$1000/MVar. Garver_AC-a3

El desempeño de la EE auto adaptativa para los diferentes modelos de la red de prueba de Garver sin re despacho evidencian algunos hechos, los cuales se describen a continuación. Para el modelo Garver_AC-a1, donde no se tiene límite de reactivos, se observa que la tasa de éxito para 10 simulaciones o corridas del algoritmo está entre 40% y 70% con una tendencia a que la tasa de éxito disminuya con el incremento de individuos. Esto es un indicador que con el incremento de la población la capacidad de convergencia del algoritmo de EE disminuye. Por otra parte, al utilizar el modelo de Garver sin re despacho, sin compensación shunt Garver_AC-a2, para 10 simulaciones efectuadas con 80,100 y 120 individuos, la tasa de éxito decae al rango entre el 30% y el 50%. Eso es comprensible debido a que es una condición del modelo menos relajado que la anterior. Finalmente, se han efectuado idénticas simulaciones para igual cantidad de individuos de la población con el modelo de Garver sin re despacho, con compensación shunt a USD\$1000/MVar, Garver_AC-a3, donde el desempeño del algoritmo EE auto adaptativo, es bastante similar al obtenido en el modelo Garver-AC-a2.

De los resultados conseguidos hasta el momento, se determinó la necesidad de implementar una mejora al algoritmo de búsqueda y optimización por Estrategia Evolutiva auto adaptativa, es así que se consiguió dar un paso hacia la Estrategia Evolutiva Modificada (EEM), de acuerdo a lo descrito en los párrafos 3.3.6 y 3.4.4 del presente documento. Implementando algunos criterios de selección y recombinación.

4.1.1.3. Garver sin Re despacho (aplicando EEM)

Se han aplicado 2 tipos de Estrategias Evolutivas Modificadas al escenario de Garver sin re despacho y sin restricción de reactivos, de acuerdo a lo codificado en este documento corresponde al Garver_AC-a1. El primer algoritmo corresponde a una selección aleatoria de los mejores individuos del 20%,40% y 60% de los mismos, los cuales aportan las características de los individuos de la generación de descendencia. En segunda instancia se utiliza el algoritmo de selección de los mejores padres mediante la generación de números aleatorios los cuales obedecen a una distribución exponencial, a través de un sesgo que privilegia la selección de los individuos más robustos. Los resultados de correr 10 simulaciones para cada una

de las opciones se muestran en las tablas de la 4.10 a la 4.13, las cuales se presentan a continuación:

Tabla 4.10: Desempeño de Estrategia Evolutiva Modificada (EEM). Selección aleatoria de características del 20% de los mejores individuos como mejores padres. Modelo de Garver AC sin re despacho, sin límite de reactivos US\$0/MVar. Max 50 iteraciones. Garver_AC-a1.

Individuos	80	100	120
Tasa de éxito (%)	20	30	50
# de iteraciones promedio	19	13	14
Desviación estándar iteraciones	14	6	11
Valor promedio FE	1520	3000	1680
v Mínimo	170000	170000	170000
v Máximo	212000	236000	211000
v Promedio	198000	195000	185000

Tabla 4.11: Desempeño de Estrategia Evolutiva Modificada (EEM). Selección aleatoria de características del 40% de los mejores individuos como padres. Modelo de Garver AC sin re despacho, sin límite de reactivos US\$0/MVar. Max 50 iteraciones. Garver_AC-a1.

Individuos	80	100	120
Tasa de éxito (%)	20	30	50
# de iteraciones promedio	16	14	22
Desviación estándar iteraciones	4	3	11
Valor promedio FE	1280	1400	2640
v Mínimo	170000	170000	170000
v Máximo	280000	201000	212000
v Promedio	192000	192000	188000

Tabla 4.12: Desempeño de Estrategia Evolutiva Modificada (EEM). Selección aleatoria de características del 60% de los mejores individuos como padres. Modelo de Garver AC sin re despacho, sin límite de reactivos US\$0/MVar. Max 50 iteraciones. Garver_AC-a1.

Individuos	80	100	120
Tasa de éxito (%)	30	90	30
# de iteraciones promedio	25	22	24
Desviación estándar iteraciones	9	4	6
Valor promedio FE	2000	2200	2880

v Mínimo	170000	170000	170000
v Máximo	211000	210000	206000
v Promedio	191000	174000	192000

Tabla 4.13: Desempeño de Estrategia Evolutiva Modificada (EEM). Selección aleatoria mediante la distribución de probabilidad exponencial de los individuos pertenecientes a la generación de padres. Modelo de Garver AC sin re despacho, sin límite de reactivos US\$/MVar. Max 50 iteraciones. Garver_AC-a1.

Individuos	80	100	120
Tasa de éxito (%)	50	20	40
# de iteraciones promedio	24	23	25
Desviación estándar iteraciones	10	11	10
Valor promedio FE	1920	2300	3000
v Mínimo	170000	170000	170000
v Máximo	208000	230000	221000
v Promedio	184000	200000	193000

De los resultados observados en las tablas de la 4.10 a la 4.13, llegamos a la conclusión de la incorporación de criterios de selección y recombinación, ayudan a mejorar la característica de convergencia de la Estrategia Evolutiva original, denominada ahora con estas mejoras Estrategia Evolutiva Modificada (EEM). Se observa que en el proceso de selección aleatoria uniforme del 20%, 40% y 60% de los padres más robustos, se observa un incremento de la tasa de convergencia, llegándose a estado estable, sea este un mínimo local o un mínimo global, con una cantidad de iteraciones notablemente menor a lo encontrado en la EE. Ahora en la EEM se tiene un promedio de iteraciones entre 15 y 25 frente a la cantidad de iteraciones promedio de 44 a 50 obtenidas aplicando la EE a este mismo modelo de Garver. Por otra parte observamos que no se ha producido una mejora significativa en la tasa de éxito, ya sea incrementando la cantidad de individuos de la población o el porcentaje de padres seleccionados aleatoriamente para la recombinación, es más, las tasas de éxito son notablemente inferiores a las obtenidas aplicando la EE. Un caso de excepción es el observado al aplicar la EEM con un porcentaje de selección aleatoria del 60% de los mejores padres y con una población de 100 individuos. Se podrían considerar estos resultados como parámetros de sintonía. Finalmente se observa que si bien la característica de convergencia del algoritmo ha aumentado notablemente, disminuye la capacidad del mismo para explorar nuevos

espacios de búsqueda conforme progresa la obtención de soluciones a lo largo de cada generación.

Las curvas que muestran la convergencia de las simulaciones realizadas para el método de “Torneo de Selección” en la EEM, presentados en las tablas de la 4.10 a la 4.12 están en las Figuras de la 4.18 a la 4.20. Aquí se pueden apreciar las mejoras del algoritmo EEM frente al EE simple.




Figura 4.18 Representación de la convergencia de EEM auto adaptativa para 10 ensayos. Población 120 individuos. Torneo de selección al 20%. Garver AC sin re despacho. Sin límite de reactivos. Garver_AC-a1.




Figura 4.19 Representación de la convergencia de EEM auto adaptativa para 10 ensayos. Población 120 individuos. Torneo de selección al 40%. Garver AC sin re despacho. Sin límite de reactivos. Garver_AC-a1.




Figura 4.20 Representación de la convergencia de EEM auto adaptativa para 10 ensayos. Población 100 individuos. Torneo de selección al 60%. Garver AC sin re despacho. Sin límite de reactivos. Garver_AC-a1.

Finalmente se ilustrará el desempeño de la “Sobre selección” en el algoritmo EEM, y se graficará el comportamiento de la convergencia para la tabla 5.13. Esto se describe en la Figura 4.21.




Figura 4.21 Representación de la convergencia de EEM auto adaptativa para 10 ensayos. Población 120 individuos. Sobre selección distribución exponencial. Garver AC sin re despacho. Sin límite de reactivos. Garver_AC-a1.

Para los siguientes escenarios de Garver se utilizará por tanto la Estrategia Evolutiva Modificada (EEM) aplicando Torneo de Selección usando criterios de selección aleatoria uniforme del 60% de los mejores padres para generar mediante una recombinación global la descendencia de la siguiente generación, sobre la cual se aplicarán los mecanismos de mutación ya conocidos en el algoritmo de la Estrategia Evolutiva original. Los resultados de las simulaciones se encuentran expresados en las tablas 4.14 y 4.15

Tabla 4.14: Desempeño de Estrategia Evolutiva Modificada (EEM). Selección aleatoria de características del 60% de los mejores individuos como padres. Modelo de Garver AC sin re despacho, sin compensación shunt. Max 50 iteraciones.

Garver_AC-a2.

Individuos	100
Tasa de éxito (%)	20
# de iteraciones promedio	22
Desviación estándar iteraciones	6
Valor promedio FE	2200
v Mínimo	261000
v Máximo	270000
v Promedio	267000

Tabla 4.15: Desempeño de Estrategia Evolutiva Modificada (EEM). Selección aleatoria de características del 60% de los mejores individuos como padres. Modelo de Garver AC sin re despacho, sin límite de reactivos US\$1000/MVar. Max 50

iteraciones. Garver_AC-a3.

Individuos	100
Tasa de éxito (%)	40
# de iteraciones promedio	24
Desviación estándar iteraciones	5
Valor promedio FE	2400

v Mínimo	261000
v Máximo	270000
v Promedio	266000

Los resultados del comportamiento del algoritmo EEM con Torneo de Selección al 60% de las tablas 5.14 y 5.15 se muestran respectivamente en las Figuras 5.22 y 5.23, a continuación:

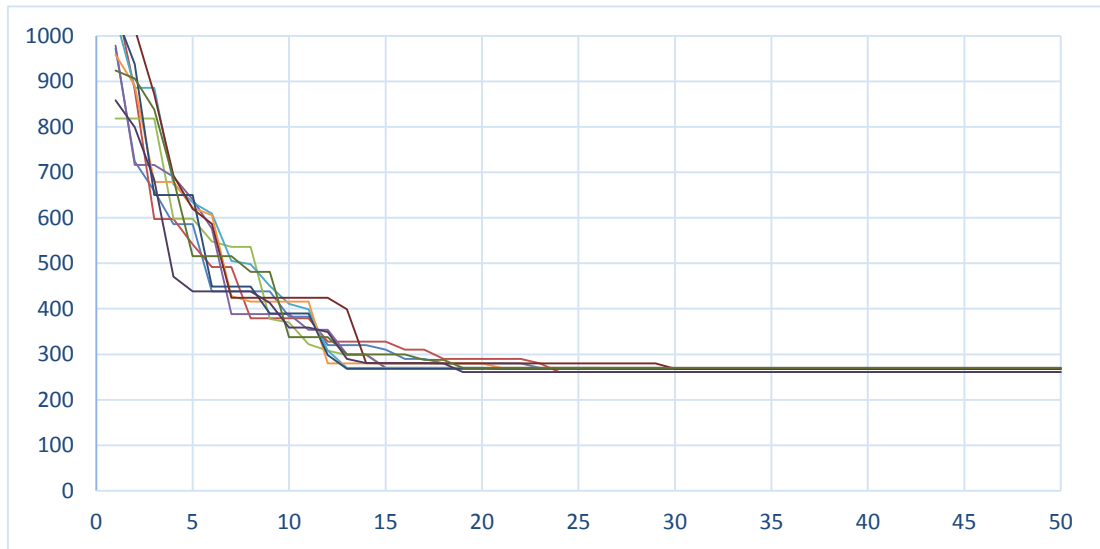


Figura 4.22 Representación de la convergencia de EEM auto adaptativa para 10 ensayos. Población 100 individuos. Torneo de selección al 60%. Garver AC sin re despacho. Sin compensación shunt. Garver_AC-a2.




Figura 4.23 Representación de la convergencia de EEM auto adaptativa para 10 ensayos. Población 100 individuos. Torneo de selección al 60%. Garver AC sin re despacho. Con compensación shunt US\$1000/MVar. Garver_AC-a3.




Figura 4.24: Solución del sistema de Garver sin re despacho

Definitivamente el uso de la EEM sobre el sistema de Garver para los escenarios sin re despacho, representa una mejora en el desempeño comparada con los resultados obtenidos para el mismo sistema e idénticos escenarios utilizando la EE tradicional. En el caso de la EE obtenemos tasas de convergencia con un número de iteraciones promedio de entre 30 y 40 (ver tablas 4.8 y 4.9) mientras que utilizando la EEM el número de iteraciones promedio se ha reducido a un rango de 20 a 25 (ver tablas 4.14 y 4.15). Es indica que el nuevo algoritmo acelera la convergencia hacia el óptimo global. Sin embargo, si por una parte se ha ganado capacidad de convergencia se ha perdido en tasa de éxito, pues con la EE se tenían valores entre el 50% al 60%, con la nueva EEM la tasa de éxito se ubicó en el rango del 20% al 40%. Esto es una característica de varios algoritmos evolutivos, donde la tasa de convergencia del algoritmo debe estar adecuadamente balanceada con la

capacidad de exploración del espacio de búsqueda, teniendo en mente siempre que es necesario evitar que el algoritmo en alguna de sus iteraciones quede estancado en óptimos locales.

4.1.2 Sistema IEEE de 24 barras

Este sistema tiene 24 barras y 41 caminos candidatos, una demanda prevista de 8.550 MW. El número máximo de líneas adicionales por camino es igual a 5. El número de topologías posibles es $(5 + 1)^{41} = 6^{41}$.

Este sistema es usado para comparar los resultados de los nuevos métodos de solución en trabajos de planeamiento de la expansión de los sistemas de transmisión. La topología base se representa en la Figura 4.25.

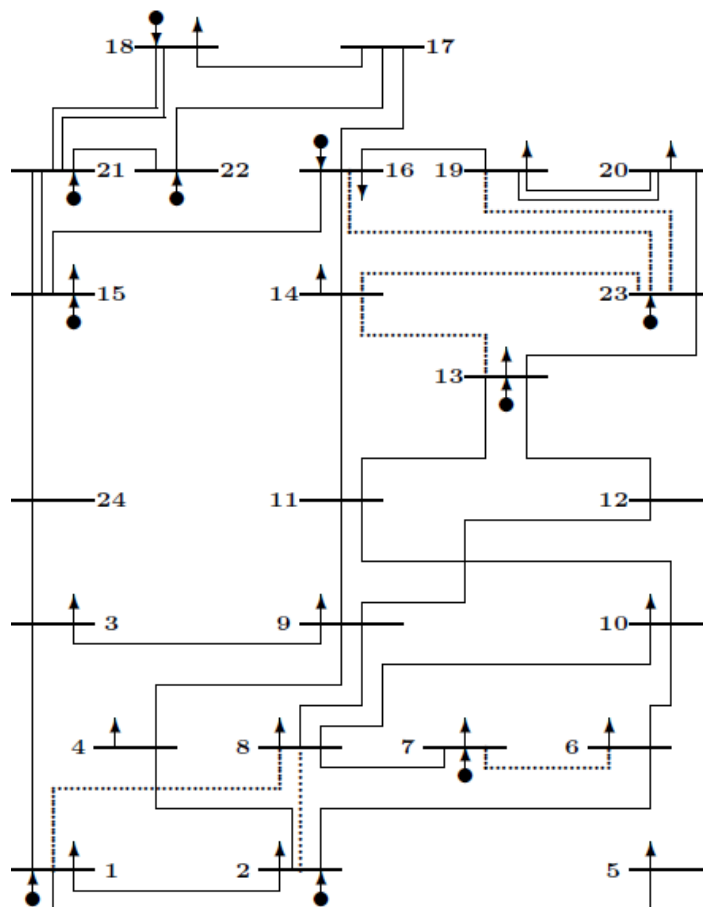


Figura 4.25: Sistema IEEE de 24 barras – topología base [4]

4.1.2.1. Sistema IEEE de 24 barras con re despacho (aplicando EEM)

Al aplicar el algoritmo EEM el cual aplica la mecanismo de “Torneo de Selección” de manera aleatoria del 60% de los mejores individuos seleccionados de manera aleatoria uniforme, se obtiene un valor de inversión igual a $v = \text{US\$ } 70.000$, mientras que las líneas adicionadas son:

$$n_{6-10} = 1; n_{14-16} = 1$$

El algoritmo de EEM utilizó poblaciones de 100 individuos. Se aplicó el algoritmo de EEM con selección aleatoria de entre el 60% de los mejores individuos como padres para aplicar la recombinación uniforme y la mutación de la descendencia para obtener las nuevas soluciones o hijos de la siguiente generación. Se efectuaron 10 ensayos o simulaciones de un máximo de 200 iteraciones. El desempeño del algoritmo para la red de prueba se muestra en la tabla 4.16.

Tabla 4.16: Desempeño de Estrategia Evolutiva modificada (EEM). Selección aleatoria de características del 60% de los mejores individuos como padres. Modelo IEEE 24 nodos, con re despacho, sin límite de reactivos

Individuos	100
Tasa de éxito (%)	60
# de iteraciones promedio	76
Desviación estándar iteraciones	16
Valor promedio FE	7600
v Mínimo	70000
v Máximo	105000
v Promedio	77000

En la Figura 4.26 podemos observar las características de desempeño del algoritmo EEM para el modelo IEEE de 24 nodos con re despacho y sin límite de reactivos.




Figura 4.26 Representación de la convergencia de EEM auto adaptativa para 10 ensayos. Población 100 individuos. Torneo de selección al 60%. IEEE 24 nodos AC con re despacho. Sin límite de reactivos.

4.1.2.2. Sistema IEEE de 24 barras sin re despacho (aplicando EEM)

El escenario del sistema de prueba IEEE 24 nodos sin re despacho, al igual que el de Garver sin re despacho, implica que los generadores mantienen su límite establecido de generación durante el proceso de Flujo Optimo de Potencia. Se analizan algunos variantes del escenario bajo esta condición: El primero de ellos al que lo designaremos como IEEE24_AC-a1, corresponde a la generación de reactivos ilimitados con un costo de \$0/MVAR. Este escenario corresponde a la condición más relajada. En el segundo IEEE 24 sin re despacho no se permite generación de reactivos, lo designaremos como IEEE24_AC-a2 y corresponde a la condición menos relajada. Finalmente se utilizará un escenario intermedio, en el cual se permiten reactivos en generación pero asignándoles un costo, que corresponde a una condición más realista, en este caso se ha asignado un valor de \$1000/MVAR, este último está designado como IEEE_AC-a3. Para todos estos escenarios IEEE24 sin re despacho se ha aplicado únicamente la Estrategia Evolutiva auto adaptativa modificada (EEM), considerando el proceso de “Torneo de Selección” al 60% de los

mejores individuos en cada generación. Se han ejecutado 10 simulaciones para poblaciones de 160 individuos. Con 300 iteraciones máximo por simulación.

En el caso del escenario IEEE24_AC-a1, el mínimo costo de inversión encontrado es de $v = \text{US\$ } 110 \times 1000$ con una topología final encontrada que adiciona las siguientes líneas:

$$n_{6-10} = 1; n_{7-8} = 2; n_{13-14} = 2$$

En este escenario, la compensación reactiva adicionada al sistema se localizó en los nodos 3, 4, 5, 8, 9, 10, 16 y 17, con los siguientes valores respectivos de potencia reactiva: 331.72, 77.07, 60.44, 95.43, 392.79, 226.83, 220.80, 154.09 MVAR.

Para el escenario IEEE24_AC-a2, el mínimo costo de inversión encontrado es de $v = \text{US\$ } 445 \times 1000$ con una topología final encontrada que adiciona las siguientes líneas:

$$n_{1-3} = 2; n_{2-4} = 1; n_{3-24} = 1; n_{6-10} = 2; n_{7-8} = 2;$$

$$n_{9-11} = 1; n_{11-13} = 1; n_{15-24} = 1$$

Finalmente para el escenario de garver_AC-a3, el resultado es muy similar al caso anterior, el mínimo costo de inversión encontrado es de $v = \text{US\$ } 455 \times 1000$. La topología final encontrada que adiciona las siguientes líneas:

$$n_{1-2} = 2; n_{1-3} = 4; n_{2-4} = 1; n_{6-10} = 2; n_{7-8} = 3;$$

$$n_{9-11} = 1; n_{11-13} = 1$$

En las tablas de la 4.17 a la 4.19 se describen las características de convergencia para el caso del sistema de pruebas IEEE 24 nodos sin re despacho para los diferentes escenarios explicados en los párrafos anteriores.

Tabla 4.17: Desempeño de Estrategia Evolutiva modificada (EEM). Selección aleatoria de características del 60% de los mejores individuos como padres. Modelo IEEE 24 nodos, sin re despacho, sin límite de reactivos. IEEE24_AC-a1

Población	100
Tasa de éxito (%)	90
# de iteraciones promedio	48
Desviación estándar iteraciones	26
Valor promedio FE	4800
v Mínimo	110000
v Máximo	114000
v Promedio	110400

Tabla 4.18: Desempeño de Estrategia Evolutiva modificada (EEM). Selección aleatoria de características del 60% de los mejores individuos como padres. Modelo IEEE 24 nodos, sin re despacho, sin compensación shunt. IEEE24_AC-a2

Población	100
Tasa de éxito (%)	10
# de iteraciones promedio	132
Desviación estándar iteraciones	50
Valor promedio FE	13200
v Mínimo	445000
v Máximo	461000
v Promedio	457000

Tabla 4.19: Desempeño de Estrategia Evolutiva modificada (EEM). Selección aleatoria de características del 60% de los mejores individuos como padres. Modelo IEEE 24 nodos, sin re despacho, con compensación shunt \$100/Mvar. IEEE24_AC-a3

Población	100
Tasa de éxito (%)	20
# de iteraciones promedio	180
Desviación estándar iteraciones	80
Valor promedio FE	18000
v Mínimo	455000
v Máximo	483000
v Promedio	464000

En la Figura 4.27 se puede hacer se muestran los resultados de la tabla 4.17 mientras que en la Figura 4.28 se muestran el resultado correspondiente a la tabla 4.18.




Figura 4.27 Representación de la convergencia de EEM auto adaptativa para 10 ensayos. Población 100 individuos. Torneo de selección al 60%. IEEE 24 nodos AC sin re despacho. Sin límite de reactivos. IEEE24_AC_a1




Figura 4.28 Representación de la convergencia de EEM auto adaptativa para 10 ensayos. Población 100 individuos. Torneo de selección al 60%. IEEE 24 nodos AC sin re despacho. Sin compensación shunt. IEEE24_AC_a2



De los resultados anteriores, podemos observar que para el escenario del sistema IEEE24, sin límite de reactivos, la solución del problema de planeamiento presenta un valor de \$110.000, que coincide con los resultados encontrados en la referencia [62]. La cantidad de iteraciones promedio requeridas para el proceso de búsqueda es menor a 50.

Por otra parte para el escenario del sistema IEEE de 24 nodos, sin despacho y sin compensación shunt, el mejor valor de inversión es de \$445.000, que también es consistente con lo encontrado en la referencia [62]. El promedio de iteraciones requeridas para convergencia del método de búsqueda es de 132 frente a las 52 iteraciones promedio requeridas cuando se utiliza local PSO [62]. En este caso el algoritmo EEM, para las condiciones de un escenario más exigente presenta un menor desempeño en comparación con la meta heurística local PSO, que se ha utilizado como referencia para este análisis.

Capítulo 5

Conclusiones y trabajos posteriores.

5.1 Conclusiones

En este trabajo se ha efectuado una exploración de tres tipos de algoritmos evolutivos para abordar la solución del problema del planeamiento de la expansión de los sistemas eléctricos de transmisión utilizando el modelo AC (PET). Un primer algoritmo utilizado, de naturaleza heurística fue la Programación Evolutiva (PE) con y sin adaptación el cual fue puesto a prueba al aplicarlo sobre el sistema de Garver con re despacho. Su rendimiento fue comparado luego frente al algoritmo meta heurístico de Estrategia Evolutiva (EE) aplicado al mismo sistema e idénticos escenarios. Fue evidente la ventaja del algoritmo meta heurístico EE que involucraba ya criterios de selección utilizando a la varianza como un elemento de mutación de los soluciones candidatas. Para este último, los criterios de selección de los padres de generaciones de soluciones futuras se basaron en un método aleatorio de selección de distribución uniforme. Ambos algoritmos tanto el de PE como el de EE mantenían un rendimiento aceptable al aplicarlo a sistemas pequeños como el de Garver de 6 barras y con re despacho, con una clara ventaja de desempeño del algoritmo de EE. Sin embargo para el mismo sistema de Garver y sin re despacho, con el propósito de simular las condiciones de incluir completamente generación no despachable, se modelaron escenarios en donde no era permitido el re despacho, la EE disminuyó notablemente su desempeño por lo que se hizo necesario avanzar hacia el tercer tipo de algoritmo evolutivo al que se lo denominó Estrategia Evolutiva Modificada (EEM). Este último al implementar criterios de selección y mutación, tuvo mejor desempeño en la exploración del espacio de búsqueda y evidenció ventajas en la convergencia al aplicarlo sobre el sistema de Garver en escenarios sin re

despacho. Fue seleccionado para aplicarlo al sistema de pruebas IEEE de 24 barras, en donde en el escenario con re despacho tuvo un desempeño bastante bueno y para los escenarios sin re despacho mostró un comportamiento aceptable.

Se notó sin embargo que la capacidad del algoritmo de escapar de soluciones óptimas locales disminuía notablemente conforme avanzaba el proceso de búsqueda, lo que hizo que la tasa de éxito sea baja. Considerando que para el problema del planeamiento de la expansión de sistemas de transmisión, el criterio de velocidad no es tan importante como la tasa de éxito para encontrar una solución óptima o una media de soluciones de buena calidad, podemos concluir que si bien la EEM mantiene una velocidad bastante buena, el algoritmo no es suficientemente robusto pues su tasa de éxito no es alta. Pero por otra parte si cumple con el criterio alternativo de tener una media de valores de la función de evaluación que se aproxima cercanamente a la solución óptima global.

5.2 Propuestas para trabajos futuros

- Se deben mejorar las estrategias de selección y mutación de manera que se adapten a la naturaleza del problema del PET. Se debe pretender incrementar la tasa de éxito con un balance adecuado entre ésta y la velocidad de convergencia.
- Incorporar métodos convenientes para la creación de soluciones iniciales, basados en el conocimiento del problema. Con ello se podría disminuir el esfuerzo computacional en el proceso iterativo y aprovechar ese recurso destinándolo en afinar las estrategias de exploración del espacio de búsqueda.
- Incorporar el procesamiento paralelo en el algoritmo EEM y la medición del tiempo de cálculo de la solución óptima para cada iteración.
- Incorporar criterios de seguridad estática en la aplicación de la EEM para la solución del problema del PET.

Considerar el problema del PET incorporando incertidumbre tanto en la generación como en la demanda.

Referencias Bibliográficas

- [1] R. Gallego, “Planejamento a Longo Prazo de Sistemas de transmissão usando Técnicas de Otimização Combinatorial”, Tese de Doutorado, UNICAMP, SP Brasil, 1997.
- [2] I. G. Sanchez, R. Romero, J.R.S. Mantovani, M.J. Rider, “Transmission expansion planning using the DC model and non-linear programming technique”, IEE Proc. – Gen., Transm. Distrib., vol. 152, no. 6, pp. 763-769, November 2005.
- [3] R. Romero, M. Rider, I. Silva, “A metaheuristic to solve the transmission expansion problem”, IEEE Transactions on Power Systems, vol. 22, pp. 2289-2291, 2007.
- [4] I. J. Silva, “Planejamento da Expansão de Sistemas de Transmissão Considerando Segurança e Planos de Programação da Geração”, Tese de Doutorado, UNICAMP, Brasil, 2005.
- [5] J. I. R. Rodriguez, D. M. Falcao, G. N. Taranto, “Short-term transmission expansion planning by a combined genetic algorithm and hill-climbing technique” The 15th International Conference on Intelligent System Applications to Power Systems, ISAP, pp. 1-8, Curitiba, 2009.
- [6] M. J. Rider, “Planejamento da Expansão de Sistemas de Transmissão Usando os Modelos CC-CA e Técnicas de Programação Não-Linear”, Tese de Doutorado, UNICAMP SP, Brasil, 2006.
- [7] M. J. Rider, A. V. Garcia, R. Romero, “Power system transmission network expansion planning using AC model” Proc. IET Gen., Transm., Distrib., vol. 1, no. 5, pp. 731-742. 2007.

- [8] L. A. Gallego, M. Rider, R. Romero, A. Garcia, "A specialized genetic algorithm to solve the short term transmission network expansion planning", PowerTech 2009, IEEE Bucharest, pp. 1-7, 2009.
- [9] S. P. Torres, C. A. Castro, M. J. Rider, "Transmission expansion planning by using DC and AC models and particle swarm optimization", in "Swarm Intelligence in Electric and Electronic Engineering", IGI Global, 2013 (to appear).
- [10] R. Romero, E. Asada, E. Carrero, C. Rocha, "Constructive heuristic algorithm in branch and bound structure applied to transmission network expansion planning", IET Gen., Transm. Distrib., vol. 1, no. 2, pp. 318-323, 2007.
- [11] G. Latorre, R. Cruz, J. Areiza, A. Villegas, "Classification of publications and models on transmission expansion planning", IEEE Trans. Power Syst., vol. 18, no. 2, pp. 938-946, May 2003.
- [12] Y. del Valle, G. K. Venayagamoorthy, S. Mohagheghi, J.-C. Hernandez, R. G. Harley, "Particle Swarm Optimization: basic concepts, variants and applications in power systems", IEEE Trans. Evolutionary Computation, vol. 12, no. 2, pp. 171-195, April 2008.
- [13] S. P. Torres, C. A. Castro, R. Pringles, W. Guaman, "Comparison of particle swarm based meta-heuristics for the electric transmission network expansion planning problem", IEEE PES General Meeting, Detroit, USA, pp. 1-7, July 2011.
- [14] A. Escobar, R. A. Gallego, R. Romero, "Multi-stage and coordinated planning of the expansion of transmission systems", IEEE Trans. Power Syst., vol. 19, no. 2, pp. 735-744, May 2004.
- [15] S. A. de Oliveira, "Metaheurísticas Aplicadas ao Planejamento da Expansão da Transmissão de Energia Elétrica em Ambiente de Processamento Distribuído" Tese de Doutorado, UNICAMP, Brasil, 2004.
- [16] E. Asada, E. Carreno, R. Romero, A. Garcia, "A branch-and-bound algorithm for the multi-stage transmission expansion planning", Power Engineering Society General Meeting, 2005. IEEE, pp. 17-22, June 2005.

- [17] I. J. Silva, M. J. Rider, R. Romero, "Genetic Algorithm of Chu and Beasley for Static and Multistage Transmission Expansion Planning", IEE Proc. - Gener. Transm. Distrib., October 2006.
- [18] R. Romero, A. Monticelli, "Planejamento a longo prazo da expansão de sistemas de transmissão de energia elétrica", Campinas, apostila UNICAMP, 2000.
- [19] L. L. Garver, "Transmission network estimation using linear programming", IEEE Trans. Power App. Syst., vol. PAS-89, no. 7, pp. 1688-1697, Sep. 1970.
- [20] R. Romero, A. Monticelli, A. García, S. Haffner, "Test systems and mathematical models for transmission network expansion planning", IEE Proc. - Gener. Transm. Distrib., vol. 149, no. 1, pp. 27-36, January 2002.
- [21] R. Romero, A. Monticelli, "A hierarchical decomposition approach for transmission network expansion planning", IEEE Trans. Power Syst., vol. 9, no. 1, pp. 373-380, Feb. 1994.
- [22] S. Haffner, "O planejamento da expansão dos sistemas elétricos no contexto de um ambiente competitivo", Tese de Doutorado, UNICAMP, SP Brasil, 2000.
- [23] S. Haffner, A. Monticelli, A. Garcia, J.R.S. Mantovani, R. Romero, "Branch and bound algorithm for transmission system expansion planning using a transportation model", IEE Proc. - Gen., Transm. Distrib., vol. 147, no. 3, pp. 149-156, May 2000.
- [24] S. Haffner, A. Monticelli, A. Garcia, R. Romero, "Specialised branch-and-bound algorithm for transmission network expansion planning", IEE Proc. - Gen., Transm. Distrib., vol. 148, no. 5, pp. 482-488, 2001.
- [25] M. J. Rider, A. Garcia, R. Romero, "Transmission system expansion planning by a branch and bound algorithm", IET Gen., Transm. Distrib., vol. 2, no. 1, pp. 90-99, 2008.
- [26] R. A. Gallego, A. Monticelli, R. Romero, "Transmission expansion planning by extended genetic algorithm", Proc. IEE - Gen. Trans. Dist., vol 145, no. 3, pp. 329-335, May 1998.

- [27] E. L. da Silva, H. Gil, J. Areiza, "Transmission network expansion planning under an improved genetic algorithm", *IEEE Trans. Power Syst.*, vol. 15, no. 4, pp. 1168-1175, Nov. 2000.
- [28] R. Romero, R. A. Gallego, A. Monticelli, "Transmission system expansion planning by simulated annealing", *IEEE Trans. Power Syst.*, vol. 11, no. 1, pp. 364-369, Feb. 1996.
- [29] R. A. Gallego, R. Romero, A. Monticelli, "Tabu search algorithm for network synthesis", *IEEE Trans. Power Syst.*, vol. 15, pp. 490-495, May 2000.
- [30] E. L. Da Silva, J. M. A. Ortiz, G. C. de Oliveira, S. Binato, "Transmission network expansion planning under a tabu search approach", *IEEE Trans. Power Syst.*, vol. 16, no. 1, pp. 62-68, 2001.
- [31] S. Binato, G. C. Oliveira, J. L. Araujo, "A Greedy Randomized Adaptative Search Procedure for Transmission Network Expansion Planning", *IEEE Trans. Power Syst.*, vol. 16, no. 2, pp. 247-253, May 2001.
- [32] R. Pringles, V. Miranda, F. Garcés, "Expansión óptima del sistema de transmisión utilizando EPSO", VII Latin American Congress on Electricity Generation & Transmission, October 24-27, 2007.
- [33] S. P. Torres, C. A. Castro, "Parallel particle swarm optimization applied to the static transmission expansion planning problem", *Transmission and Distribution: Latin America Conference and Exposition (T&D-LA)*, pp.1-6, Sept. 2012.
- [34] R. D. Zimmerman, C. E. Murillo-Sánchez, R. J. Thomas, "MATPOWER: Steady-State Operations, Planning, and Analysis Tools for Power Systems Research and Education", *IEEE Trans. Power Syst.*, vol. 26, no. 1, 2011.
- [35] E. Carreno, E. Asada, R. Romero A. Garcia, "A branch and bound algorithm using the hybrid linear model in the transmission network expansion planning", *Power Tech 2005, IEEE Russia*, pp. 1-6, June 2005.
- [36] S. Binato, M. V. F. Pereira, S. Granville, "A new Benders decomposition approach to solve power transmission network design problems", *IEEE Trans. Power Syst.*, vol. 16, pp. 235-240, May 2001.

- [37] L. Bahiense, G. C. Oliveira, M. Pereira, S. Garnville, "A mixed integer disjunctive model for transmission network expansion", *IEEE Trans. Power Syst.*, vol. 16, no. 3, pp. 560-565, Aug. 2001.
- [38] A. Monticelli, A. Santos Jr., M. V. F. Pereira, "Interactive transmission network planning using a least-effort criterion", *IEEE Trans. Power App. Syst.*, vol. 101, no. 10, pp. 3919-3925, 1982.
- [39] M. V. F. Pereira, L. M. V. G. Pinto, "Application of Sensitivity Analysis of Load Supplying Capability to Interactive Transmission Expansion Planning", *IEEE Trans. Power App. Syst.*, vol. PAS-104, no. 2, Feb. 1985.
- [40] R. Villasana, L. L. Garver, S. J. Salon, "Transmission network planning using linear programming", *IEEE Trans. Power App. Syst.*, vol. PAS-104, pp. 349-356, Feb. 1985.
- [41] M. V. F. Pereira, L. M. V. G. Pinto, S. H. F. Cunha, G. C. Oliveira, "A decomposition approach to automated generation/transmission expansion planning", *IEEE Trans. Power App. Syst.*, vol. PAS-104, no. 11, pp. 3074-3081, November 1985.
- [42] G. C. Oliveira, A. P. Costa, S. Binato, "Large Scale Transmission Network Planning Using Optimization and Heuristic Techniques", *IEEE Trans. Power Syst.*, vol. 10, no. 4, pp. 1828-1834, November 1995.
- [43] R. A. Gallego, A. B. Alves, A. Monticelli, R. Romero, "Parallel simulated annealing applied to long term transmission network expansion planning", *IEEE Trans. Power Syst.*, vol. 12, pp. 181-188, Feb. 1997.
- [44] M. Cortes-Carmona, R. Palma-Behnke, O. Moya, "Transmission network expansion planning by a hybrid simulated annealing algorithm", *Intelligent System Applications to Power Systems, ISAP 2009*, pp. 1-7, Nov. 2009.
- [45] I. J. Silva, M. J. Rider, R. Romero, A. V. Garcia, C. A. Murari, "Transmission network expansion planning with security constraints", *IEE Proc. - Gen., Transm. Distrib.*, vol. 152, no. 6, pp 828-836, Nov. 2005.

- [46] H. Mori, Y. Sone, "A parallel tabu search based approach to transmission network expansion planning", Power Tech Proceedings, IEEE Porto, vol. 2, Portugal, Sep. 2001
- [47] A. M. Leite da Silva, L. A. da Fonseca Manso, L. C. de Resende, L. S. Rezende, "Tabu search applied to transmission expansion planning considering losses and interruption costs", Probabilistic Methods Applied to Power Systems, PMAPS 2008, pp 1-7, May, 2008.
- [48] L. S. Rezende, A. M. Leite da Silva, L. A. F. Manso, "Aplicação de colônia de formigas ao planejamento cronológico da expansão da transmissão considerando restrições de confiabilidade", XVII Congresso Brasileiro de Automática, CBA-2008, Juiz de Fora, MG, Set. 2008.
- [49] P. Limsakul, S. Pothiya, N. Leeprechanon, "Application of ant colony optimization to transmission network expansion planning with security constraint", Advances in Power System Control, Operation and Management, APSCOM 2009, pp. 1-6, Nov. 2009.
- [50] J. Yi-Xiong, G. Hao-Zhong, Y. Jian-yong, Z. Li, "New discrete method for particle swarm optimization and its application in transmission network expansion planning", Electric Power Systems Research, pp. 227-233, 2006.
- [51] Verma, B. K. Panigrahi, P. R. Bijwe, "Transmission Network Expansion Planning with Adaptive Particle Swarm Optimization", Nature & Biologically Inspired Computing, NaBIC 2009, pp. 1099-1104, Dec. 2009.
- [52] I. M. Mendonça, I. C. Silva Junior, T. G. Moreira, A. L. M. Marcato, B. H. Dias, E. J. Oliveira "Planejamento estático da expansão de sistemas de transmissão de energia elétrica via otimização por enxame de partículas", XLIII Simpósio Brasileiro de Pesquisa Operacional, XLIII SBPO, Ubatuba, SP, Agosto 2011.
- [53] J. Kennedy, R. C. Eberhart. "Particle swarm optimization", Proc. of the IEEE International Conference on Neural Networks, vol. IV, pp. 1942–1948, 1995.
- [54] J. Sun, B. Feng, W. Xu, "Particle swarm optimization with particles having quantum behavior", Proc. 2004 IEEE Congress on Evolutionary Computation, pp. 325-331, 2004.

- [55] Parsopoulos, M. Vrahatis, "Particle swarm optimization and intelligence: Advances and applications", ISBN: 978-1615206667, IGI Global, 2010.
- [56] M. Clerc, J. Kennedy, "The particle swarm-explosion, stability and convergence in a multidimensional complex space", IEEE Trans. Evolutionary Computation, vol. 6, no. 2, pp. 58-73, 2002.
- [57] J. Sun, B. Feng, W. Xu, "A global search strategy of quantum-behaved particle swarm optimization", Proc. IEEE Conference on Cybernetics and Intelligent Systems, Singapore, pp. 111-116, 2004.
- [58] J. Sun, C. H. Lai, X. J. Wu "Particle swarm optimization: Classical and quantum perspectives", Chapman & Hall/CRC Numerical Analysis and Scientific Computing Series, December 2011.
- [59] J. Sun, W. Xu, J. Liu, "Parameter selection of quantum-behaved particle swarm optimization", Proc. International Conference on Natural Computation, Changsha, China, pp. 543-552, 2005.
- [60] M. Xi, J. Sun, W. Xu, "An improved quantum-behaved particle swarm optimization algorithm with weighted mean best position", Applied Mathematics and Computation, vol. 205, no.2 pp. 751-759, 2008.
- [61] J. Sun, W. Xu, W. Fang, "Quantum-behaved particle swarm optimization algorithm with controlled diversity", Proc. International Conference on Computational Science, pp. 847-854, 2006.
- [62] S. P. Torres, C. A. Castro, "Expansion planning for smart transmission grids using AC model and shunt compensation", IET Generation, pp.1-10, 2013.
- [63] A. M. Leite da Silva, L. S. Rezende, L. A. F. Manso, G. J. Anders, "Transmission Expansion Planning: A Discussion on Reliability and "N-1" Security Criteria", Probabilistic Methods Applied to Power Systems, PMAAPS 2010, pp. 244-251, June 2010.
- [64] S. P. Torres, C. A. Castro, "Transmission expansion planning considering contingencies and using the AC network model", XII SEPOPE, RJ, Brasil, Maio 2012.

- [65] <http://www.mosek.com>, último acesso em 18/08/2013.
- [66] J. Sun, X. Wua, V. Palade, W. Fang, C.-H. Lai, W. Xu, “Convergence analysis and improvements of quantum-behaved particle swarm optimization”, *Information Sciences*, vol. 193, pp. 81-103, June 2012.
- [67] J. Wang Y. Zhou, “Quantum-behaved particle swarm optimization with generalized local search operator for global optimization”, *Third International Conference on Intelligent Computing, ICIC 2007, Qingdao, China, August, 2007*.
- [68] N. Leeprechanon, P. Limsakul, S. Potia, “Optimal Transmission Planning Using Ant Colony Optimization”, *Journal of Sustainable Energy & Environment* 1, pp. 71-76, 2010.
- [69] R. A. Gallego, A. Escobar, R. A. Romero, A. Monticelli, “Planeamiento de la Expansión de Sistemas de Transmisión de Energía Eléctrica”, *Grupo de Planeamiento en Sistemas Eléctricos (GP), Universidad Tecnológica de Pereira*.
- [70] Wilmer E. Barreto, Santiago P. Torres, Carlos A. Castro, “Study of Particle Swarm Optimization Variations Applied to Transmission Expansion Planning”, *IEEE PES PowerTech 2013, Grenoble, France, 16-20 June, 2013*.
- [71] R. Bent, G.L. Toole, A. Berscheid, “Transmission network expansion planning with complex power flow models”, *IEEE Trans. Power Systems* 27, pp. 904-912, 2012.
- [72] W.E. Barreto, “Estudio da variantes da Particle Swarm Optimization aplicadas ao planejamento da expansão de sistemas de transmissão”. Tese de Mestre em Engenharia Elétrica, UNICAMP, Brasil, 2013.
- [73] Dan Simon, “Evolutionary Optimization Algorithms. Biologically inspired and population-based approaches to Computer Intelligence”, John Wiley & Sons, USA, 2013.
- [74] T. Back, D. Fogel, Z. Michalewicz, “Evolutionary Computation 1: Basic Algorithms and Operators”, Institute of Physics Publishing, Bristol & Philadelphia, 2000.

[75] T.Back, D.Fogel, Z.Michalewicz, "Evolutionary Computation 2: Advanced Algorithms and Operators", Institute of Physics Publishing, Bristol & Philadelphia, 2000.