



**UNIVERSIDAD DE CUENCA
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA ELÉCTRICA**

**“PLANEAMIENTO DE LA EXPANSIÓN DE SISTEMAS DE TRANSMISIÓN
USANDO EL MODELO AC Y ALGORITMOS DE ESTIMACIÓN DE
DISTRIBUCIÓN”.**

**TRABAJO DE TITULACIÓN PREVIO A
LA OBTENCIÓN DEL TÍTULO DE
INGENIERO ELÉCTRICO**

Autor: Edgar Gonzalo Morquecho Salto

C.I. 0106742000

Director: Dr.- Ing. Santiago Patricio Torres Contreras

C.I. 0102448958

CUENCA - ECUADOR

Noviembre 2017



RESUMEN

El problema del planeamiento de la expansión del sistema de transmisión (PET) consiste en determinar la red de transmisión a construir para satisfacer los requerimientos de la demanda futura para un escenario de largo plazo, minimizando el costo de inversión y cumpliendo las restricciones de la red. Esta tesis presenta una metodología y un modelo matemático para resolver el problema del planeamiento de la expansión del sistema de transmisión estático de largo plazo. El modelo matemático utilizado para representar a la red es el modelo AC con ecuaciones de flujo de carga no lineales, este modelo representa un problema de programación no lineal, entero mixto (PNLEM), combinatorial y no convexo. La función objetivo a minimizar permite incluir tanto el costo por inversión como el costo asociado por pérdidas de potencia activa. Los algoritmos de estimación de distribuciones (EDAs) como técnica de optimización para resolver el PET. En este trabajo se utilizan los algoritmos son técnicas meta-heurísticas que basan su búsqueda en generar un modelo probabilístico de las soluciones prometedoras para generar la siguiente población. Los algoritmos propuestos se prueban sobre los sistemas de Garver de seis nodos y el sistema IEEE de veinte y cuatro nodos.

Palabras clave: Planeamiento de la expansión de la Transmisión, Modelo AC, Algoritmos de estimación de distribuciones, EDAs, Optimización, Meta-heurística.



ABSTRACT

The Transmission Network Expansion Planning (TNEP) problem consists of determine the transmission network to be built to meet the future demand requirements for a long-term scenario, minimizing the cost of investment and meeting the technical criteria of the network. This research work thesis presents a methodology and a mathematical model to solve the long-term static Transmission Network Expansion Planning. The AC model with non-linear load flow equations is used to represent the transmission network, which represent a non-linear, mixed-integer problem (MINLP), combinatorial and non-convex problem to solve the TNEP. The objective function to be minimized allows to include both the cost per investment and the cost associated per active power losses. The Estimation of Distribution Algorithms (EDAs) are used as optimization technique to solve the TNEP. These algorithms are meta-heuristic techniques that base its search on generate a probabilistic model of the promising solutions to generate the next population. The proposed algorithms are tested on Garver 6-node systems and on the IEEE 24-node system.

Keywords: Transmission Network Expansion Planning, AC model, Estimation of Distribution Algorithms, EDAs, Optimization, Meta-heuristics.



Tabla de contenido

CAPÍTULO 1	20
INTRODUCCIÓN	20
1.1 Alcance	23
1.2 Objetivos	24
1.3 Objetivos parciales	24
1.4 Contenido	24
CAPÍTULO 2	26
PLANEAMIENTO DE LA EXPANSIÓN DEL SISTEMA DE TRANSMISIÓN DE ENERGÍA ELÉCTRICA.....	26
Introducción	26
2.1 Planeamiento de la expansión del sistema eléctrico de potencia	27
2.1.1 Horizonte de tiempo.....	28
2.1.2 Pronóstico de la demanda	28
2.1.3 Planeamiento estático y planeamiento dinámico	30
2.2 Planeamiento de la expansión del sistema de generación (PEG).....	31
2.3 Planeamiento de la expansión del sistema de transmisión (PET)	32
2.3.1 Modelación matemática.....	33
2.4 Métodos de solución.....	35
2.4.1 Métodos de optimización matemáticos.....	35
2.4.2 Algoritmos Meta-heurísticos	36
CAPÍTULO 3	37
MODELACIÓN MATEMÁTICA DEL PROBLEMA DE PLANEAMIENTO DE LA EXPANSIÓN DEL SISTEMA DE TRANSMISIÓN	37
Introducción	37
3.1 Formulación genérica	38
3.2 Modelo de transporte.....	38
3.3 Modelo híbrido no lineal	41
3.4 Modelo híbrido lineal	42



3.5	Modelo DC	44
3.6	Modelo AC	46
3.6.1	Función objetivo.....	46
3.6.2	Costos por compensación shunt.....	50
3.6.3	Descripción del método de producción de potencia activa y reactiva	51
3.7	Modelo AC con costo de pérdidas	52
3.7.1	Función objetivo.....	53
CAPÍTULO 4		60
ALGORITMOS DE ESTIMACIÓN DE DISTRIBUCIÓN PARA LA RESOLUCIÓN DEL PET		60
Introducción		60
4.1	Algoritmos de estimación de distribución	61
4.2	Modelos probabilísticos	62
4.2.1	Distribución de probabilidad	62
4.3	Modelos probabilísticos en el dominio discreto	63
4.4	Modelo probabilístico en el dominio continuo	64
4.5	Clasificación de los EDAs	65
4.5.1	Algoritmo Genético Compacto (AGc) en el dominio binario.....	66
4.6	EDAs de primer orden en el dominio continuo	71
4.6.1	Algoritmo genético compacto en el dominio continuo (AGcr)	71
4.6.2	Algoritmo de Aprendizaje Incremental Basado en Poblaciones para dominio continuo (PBILc).....	74
4.6.3	Enfoque 1 del PBILc_1	74
4.6.4	Enfoque 2 del PBILc_2	78
4.6.5	Incorporación de mutación al PBILc	81
4.7	Implementación del algoritmo de solución del PET para el dominio binario	81
4.7.1	Codificación de un individuo en el dominio binario	81
4.7.2	Implementación del PET usando el AGc	82



4.8 Implementación del algoritmo de solución del PET para el dominio continuo	89
4.8.1 Codificación de un individuo en el dominio continuo	89
4.8.2 Implementación del PET usando el AGcr	89
4.8.3 Implementación del PET usando PBILc_1 y PBILc_2	94
CAPÍTULO 5	101
PRUEBAS Y RESULTADOS	101
Introducción	101
5.1 Resultados	102
5.2 Sistema Garver de 6 barras	103
5.2.1 Sistema Garver con Redespacho (utilizando los algoritmos AGc, AGcr, PBILc_1 y PBILc_2).....	103
5.2.2 Sistema Garver sin Redespacho	113
5.3 Sistema IEEE de 24 barras	127
5.3.1 Sistema IEEE de 24 barras con redespacho aplicando el algoritmo PBILc_1 y PBILc_2.....	129
5.3.2 Sistema IEEE de 24 barras sin redespacho	131
5.4 Escenarios de prueba con costo de pérdidas	138
5.4.1 Sistema Garver con redespacho incluyendo costo de pérdidas	139
5.4.2 Sistema Garver sin redespacho incluyendo el costo de pérdidas....	150
5.4.3 Sistema IEEE con redespacho con costo de pérdidas aplicando el algoritmo PBILc_1 y PBILc_2	154
CAPÍTULO 6	160
6.1 Conclusiones	160
6.2 Recomendaciones y trabajos futuros	161
Anexos	160
Anexo A Datos del Sistema Garver de 6 nodos.....	160
Anexo B Datos del Sistema IEEE de 24 nodos.....	162



Lista de figuras

Figura 2.1: Parámetros a considerar en el PET	27
Figura 2.2: Planeamiento estático.	30
Figura 2.3: Planeamiento dinámico.	31
Figura 3.1: Función costos para la compensación de reactivos.	51
Figura 4.1: Grafica de la campana de Gauss.	65
Figura 4.2: Actualización del vector de probabilidades en el AGc (dominio binario).	69
Figura 4.3: Ilustración de la distribución normal al iniciar y al finalizar la optimización con el PBILc_1.	76
Figura 4.4: Diagrama de flujo Algoritmo Genético Compacto.....	88
Figura 4.5: Diagrama de flujo Algoritmo Genético Compacto dominio continuo...	93
Figura 4.6: Diagrama de flujo Algoritmo PBILc_1 y PBILc_2.	99
Figura 5.1: Sistema Garver- Topología base.....	103
Figura 5.2: Presentación de la convergencia del AGc (dominio binario) para 10 ensayos. Escenario Garver_AC_A1. Población 80 individuos.	109
Figura 5.3: Convergencia del AGcr (dominio continuo) para 3 de 10 ensayos. Escenario Garver_AC_A1. Población 80 individuos.....	109
Figura 5.4: Convergencia del Algoritmo PBILc_1 para 10 ensayos. Escenario Garver_AC_A1. Población 80 individuos.	110
Figura 5.5: Convergencia del Algoritmo PBILc_2 para 10 ensayos. Escenario Garver_AC_A1. Población 80 individuos.	110
Figura 5.6: Convergencia del AGc para 10 ensayos. Escenario Garver_AC_A2. Población 80 individuos.....	111



Figura 5.7: Convergencia del AGcr para 10 ensayos. Escenario Garver_AC_A2. Población 80 individuos.....	111
Figura 5.8: Convergencia del Algoritmo PBILc_1 para 3 de 10 ensayos. Escenario Garver_AC_A2. Población 100 individuos.....	112
Figura 5.9: Convergencia del Algoritmo PBILc_2 para 10 ensayos. Escenario Garver_AC_A2. Población 100 individuos.....	112
Figura 5.10: Convergencia del AGc (dominio binario) para 10 ensayos. Escenario Garver_AC_B1. Población 100 individuos.....	116
Figura 5.11: Convergencia del AGc (dominio binario) para 10 ensayos. Escenario Garver_AC_B2. Población 100 individuos.....	116
Figura 5.12: Convergencia del AGc (dominio binario) para 10 ensayos. Escenario Garver_AC_B3. Población 100 individuos.....	117
Figura 5.13: Convergencia del AGcr para 10 ensayos. Escenario Garver_AC_B1. Población 100 individuos.....	119
Figura 5.14: Convergencia AGcr para 10 ensayos. Escenario Garver_AC_B2. Población 120 individuos.....	120
Figura 5.15: Convergencia del AGcr para 10 ensayos. Escenario Garver_AC_B3. Población 100 individuos.....	120
Figura 5.16: Convergencia del Algoritmo PBILc_1 para 10 ensayos. Escenario Garver_AC_B1. Población 100 individuos.....	124
Figura 5.17: Convergencia del Algoritmo PBILc_2 para 10 ensayos. Escenario Garver_AC_B1. Población 100 individuos.....	125
Figura 5.18: Convergencia del Algoritmo PBILc_1 para 10 ensayos. Escenario Garver_AC_B2. Población 100 individuos.....	125
Figura 5.19: Convergencia del Algoritmo PBILc_2 para 10 ensayos. Escenario Garver_AC_B2. Población 100 individuos.....	126
Figura 5.20: Convergencia del Algoritmo PBILc_1 para 10 ensayos. Escenario Garver_AC_B3. Población 100 individuos.....	126



Figura 5.21: Convergencia del Algoritmo PBILc_2 para 10 ensayos. Escenario Garver_AC_B3. Población 100 individuos.....	127
Figura 5.22: Sistema IEEE - Topología Base.....	128
Figura 5.23: Convergencia del Algoritmo PBILc_1 para 10 ensayos. Modelo IEEE con redespacho para 3 de 10 ensayos. Población 120 individuos.	130
Figura 5.24: Convergencia del Algoritmo PBILc_2 para 10 ensayos. Modelo IEEE con redespacho para 3 de 10 ensayos. Población 120 individuos.	131
Figura 5.25: Convergencia del Algoritmo PBILc_1 para 3 de 10 ensayos con 120 individuos. Escenario IEEE_AC_A1.	135
Figura 5.26: Convergencia del Algoritmo PBILc_1 para 3 de 10 ensayos con 100 individuos. Escenario IEEE _AC_A2.	136
Figura 5.27: Convergencia del Algoritmo PBILc_1, para 100 individuos. Escenario IEEE_AC_A3 para 3 de 10 ensayos.	136
Figura 5.28: Convergencia del Algoritmo PBILc_2 para 3 de 10 ensayos con 120 individuos. Escenario IEEE_AC_A1.	137
Figura 5.29: Convergencia del Algoritmo PBILc_2 para 3 de 10 ensayos con 100 individuos. Escenario IEEE _AC_A2.	137
Figura 5.30: Convergencia del Algoritmo PBILc_2, para 100 individuos. Escenario IEEE_AC_A3 para 3 de 10 ensayos.	138
Figura 5.31: Influencia del costo de las pérdidas en el proceso de optimización. Escenario Garver_AC_A1_P1 con el AGcr, con costo de la energía $\lambda = 0.175$..	141
Figura 5.32: Influencia del costo de las pérdidas en el proceso de optimización. Escenario Garver_AC_A1_P1 con el AGcr, con costo de energía de $\lambda = 0.35$...	143
Figura 5.33: Convergencia del AGcr para 80 individuos. Escenario Garver_AC_A1_P1 para 3 de 10 ensayos, con costo de la energía de $\lambda = 0.175$	144
Figura 5.34: Convergencia del AGcr para 80 individuos. Escenario Garver_AC_A1_P1 con costo de la energía de $\lambda = 0.35$	144



Figura 5.35: Influencia del costo de las pérdidas en el proceso de optimización. Escenario Garver_AC_A1_P1 con el algoritmo PBILc_1 para un costo unitario de la energía de $\lambda = 0.35$ 146

Figura 5.36: Convergencia del Algoritmo PBILc_1 para 100 individuos. Escenario Garver_AC_A1_P1 con costo unitario de la energía de $\lambda = 0.175$ 148

Figura 5.37: Convergencia del Algoritmo PBILc_1 para 100 individuos. Escenario Garver_AC_A1_P1 con costo unitario de la energía de $\lambda = 0.35$ 148

Figura 5.38: Convergencia del Algoritmo PBILc_2 para 100 individuos. Escenario Garver_AC_A1_P1 con costo unitario de la energía de $\lambda = 0.175$ 149

Figura 5.39: Convergencia del Algoritmo PBILc_2 para 100 individuos. Escenario Garver_AC_A1_P1 con costo unitario de la energía de $\lambda = 0.35$ 149

Figura 5.40: Influencia del costo de las pérdidas en el proceso de optimización. Escenario Garver_AC_A2_P1 con el algoritmo PBILc_2 para un costo unitario de la energía de $\lambda = 0.35$ 152

Figura 5.41: Convergencia del Algoritmo PBILc_1 para 100 individuos. Escenario Garver_AC_B1_P1 con costo unitario de la energía de $\lambda = 0.35$ 153

Figura 5.42: Convergencia del Algoritmo PBILc_2 para 100 individuos. Escenario Garver_AC_B1_P1 con costo unitario de la energía de $\lambda = 0.35$ 154

Figura 5.43: Influencia del costo por pérdidas en el proceso de optimización. Escenario IEEE_AC_A1_P1 con el algoritmo PBILc_2 con costo de energía $\lambda = 0.05$ 157

Figura 5.44: Convergencia del Algoritmo PBILc_2 para 100 individuos. Escenario IEEE_AC_A1_P1 con costo unitario de la energía de $\lambda = 0.05$ 158

Figura 5.45: Convergencia del Algoritmo PBILc_1 para 80 individuos. Escenario IEEE_AC_A1_P1 con costo unitario de la energía de $\lambda = 0.05$ 158



Lista de tablas

Tabla 4.1: Sistema binario (Gray)	82
Tabla 4.2: Individuo representado en sistema entero y binario.....	82
Tabla 5.1: Desempeño del AGc (Dominio binario). Modelo de Garver AC sin restricción de reactivos. Max. 200 iteraciones. (Garver_AC_A1).	105
Tabla 5.2: Desempeño del AGcr (Dominio continuo). Modelo de Garver AC sin restricción de reactivos. Max. 200 iteraciones. (Garver_AC_A1).	105
Tabla 5.3: Desempeño de algoritmo PBILc_1. Modelo de Garver AC sin restricción de reactivos. Max. 150 iteraciones. (Garver_AC_A1).	105
Tabla 5.4: Desempeño de algoritmo PBILc_2. Modelo de Garver AC sin restricción de reactivos. Max. 150 iteraciones. (Garver_AC_A1).	106
Tabla 5.5: Desempeño de AGc (Dominio binario). Modelo de Garver AC sin compensación de reactivos. Max. 200 iteraciones (Garver_AC_A2).	106
Tabla 5.6: Desempeño del AGcr (Dominio continuo). Modelo de Garver AC sin compensación de reactivos. Max. 200 iteraciones (Garver_AC_A2).	106
Tabla 5.7: Desempeño de Algoritmo PBILc_1. Modelo de Garver AC sin compensación de reactivos. Max. 150 iteraciones (Garver_AC_A2).	107
Tabla 5.8 Desempeño de Algoritmo PBILc_2. Modelo de Garver AC sin compensación de reactivos. Max. 150 iteraciones (Garver_AC_A2).	107
Tabla 5.9: Desempeño del AGc (Dominio binario). Modelo de Garver AC sin redespacho sin restricción de reactivos. Max. 200 iteraciones. (Garver_AC_B1).	114
Tabla 5.10: Desempeño del AGc (Dominio binario). Modelo de Garver AC sin redespacho sin generación de reactivos. Max. 200 iteraciones. (Garver_AC_B2).	114
Tabla 5.11: Desempeño del AGc (Dominio binario). Modelo de Garver AC sin redespacho con costo de reactivos. Max. 200 iteraciones. (Garver_AC_B3).	115



Tabla 5.12: Desempeño del AGcr. Modelo de Garver AC sin redespacho sin restricción de reactivos. Max. 200 iteraciones. (Garver_AC_B1).	118
Tabla 5.13: Desempeño del AGcr. Modelo de Garver AC sin redespacho sin generación de reactivos. Max. 200 iteraciones. (Garver_AC_B2).	118
Tabla 5.14: Desempeño del AGcr. Modelo de Garver AC sin redespacho con generación de reactivos (costo 1,000 US\$/Mvar). Max. 200 iteraciones. (Garver_AC_B3).	118
Tabla 5.15: Desempeño de Algoritmo PBILc_1. Modelo de Garver AC sin restricción de reactivos. Max. 150 iteraciones (Garver_AC_B1).	121
Tabla 5.16: Desempeño de Algoritmo PBILc_1. Modelo de Garver AC sin compensación shunt. Max. 150 iteraciones (Garver_AC_B2).	122
Tabla 5.17: Desempeño de Algoritmo PBILc_1. Modelo de Garver AC con costo por compensación 1,000 US\$/Mvar. Max. 150 iteraciones (Garver_AC_B3).	122
Tabla 5.18: Desempeño de Algoritmo PBILc_2. Modelo de Garver AC sin restricción de reactivos. Max. 150 iteraciones (Garver_AC_B1).	122
Tabla 5.19: Desempeño de Algoritmo PBILc_2. Modelo de Garver AC sin compensación shunt. Max. 150 iteraciones (Garver_AC_B2).	123
Tabla 5.20: Desempeño de Algoritmo PBILc_2. Modelo de Garver AC con costo por compensación 1,000 US\$/Mvar. Max. 150 iteraciones (Garver_AC_B3).	123
Tabla 5.21: Desempeño de Algoritmo PBILc_1. Modelo IEEE con redespacho. Max. 200 iteraciones.	129
Tabla 5.22: Desempeño de Algoritmo PBILc_2. Modelo IEEE con redespacho. Max. 200 iteraciones.	130
Tabla 5.23: Desempeño de Algoritmo PBILc_1. Modelo IEEE sin redespacho, sin restricción de reactivos (IEEE_AC_A1). Max. 200 iteraciones.	132
Tabla 5.24: Desempeño de Algoritmo PBILc_2. Modelo IEEE sin redespacho, sin restricción de reactivos (IEEE_AC_A1). Max. 200 iteraciones.	132



Tabla 5.25: Desempeño de Algoritmo PBILc_1. Modelo IEEE sin redespacho, sin compensación shunt (IEEE_AC_A2). Max. 200 iteraciones.....	133
Tabla 5.26: Desempeño de Algoritmo PBILc_2. Modelo IEEE sin redespacho, sin compensación shunt (IEEE_AC_A2). Max. 200 iteraciones.....	134
Tabla 5.27: Desempeño de Algoritmo PBILc_1. Escenario IEEE_AC_A3. Max. 200 iteraciones.....	135
Tabla 5.28: Desempeño de Algoritmo PBILc_2. Escenario IEEE_AC_A3. Max. 200 iteraciones.....	135
Tabla 5.29: Parámetros para el cálculo de las pérdidas de potencia activa.	139
Tabla 5.30: Solución del problema de planeamiento para el escenario Garver_AC_A1_P1.....	140
Tabla 5.31: Desempeño de Algoritmo AGcr. Escenario Garver_AC_A1_P1. Max. 200 iteraciones.	143
Tabla 5.32: Solución del problema de planeamiento para el escenario Garver_AC_A1_P1 con el algoritmo PBILc_1y PBILc_2.....	145
Tabla 5.33: Desempeño de los algoritmos PBILc_1y PBILc_2. Escenario Garver_AC_A1_P1. Max. 150 iteraciones.....	147
Tabla 5.34: Parámetros para el cálculo de las pérdidas de potencia activa con el escenario Garver_AC_B1_P1.	150
Tabla 5.35: Solución del problema de planeamiento para el escenario Garver_AC_B1_P1 con el algoritmo PBILc_1 y PBILc_2.....	151
Tabla 5.36: Desempeño de Algoritmo PBILc. Escenario Garver_AC_B1_P1. Max. 150 iteraciones.	152
Tabla 5.37: Parámetros para el cálculo de las pérdidas de potencia activa con el escenario IEEE_AC_A1_P1.....	155
Tabla 5.38: Solución del problema de planeamiento para el escenario IEEE_AC_A1_P1 con el algoritmo PBILc.....	155



Tabla 5.39: Desempeño de Algoritmo PBILc_1 y PBILc_2. Escenario IEEE_AC_A1_P1. Max. 200 iteraciones. **157**



Lista de Algoritmos

Algoritmo 4.1: Esquema básico de un Algoritmo de Estimación de Distribución.	62
Algoritmo 4.2: Algoritmo Genético Compacto para la optimización de n bits en el dominio binario.	68
Algoritmo 4.3: Versión generalizada del AGc con elitismo.	70
Algoritmo 4.4: Algoritmo Genético Compacto para el dominio continuo.....	73
Algoritmo 4.5: Algoritmo PBILc_1 para el dominio continuo.....	77
Algoritmo 4.6: Algoritmo PBILc_2 para el dominio continuo.....	80
Algoritmo 4.7: Mutación aplicada al algoritmo PBILc.	81
Algoritmo 4.8: Creación de la Población de Soluciones Iniciales.	84



Yo, **Edgar Gonzalo Morquecho Salto** en calidad de autor y titular de los derechos morales y patrimoniales del trabajo de titulación "**Planeamiento de la expansión del sistema de transmisión usando el modelo AC y algoritmos de estimación de distribuciones**", de conformidad con el Art. 114 del CÓDIGO ORGÁNICO DE LA ECONOMÍA SOCIAL DE LOS CONOCIMIENTOS, CREATIVIDAD E INNOVACIÓN reconozco a favor de la Universidad de Cuenca una licencia gratuita, intransferible y no exclusiva para el uso no comercial de la obra, con fines estrictamente académicos.

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

Cuenca, Noviembre del 2017

A handwritten signature in blue ink, consisting of stylized letters and a horizontal line extending to the right.

Edgar Gonzalo Morquecho Salto

C.I: 0106742000



Yo, **Edgar Gonzalo Morquecho Salto**, autor del trabajo de titulación “**Planeamiento de la expansión del sistema de transmisión usando el modelo AC y algoritmos de estimación de distribuciones**”, certifico que todas las ideas, opiniones y contenidos expuestos en la presente investigación son de exclusiva responsabilidad de su autor.

Cuenca, Noviembre del 2017

A handwritten signature in blue ink, appearing to read 'Edgar Morquecho Salto', written over a horizontal line.

Edgar Gonzalo Morquecho Salto

C.I.: 0106742000



Dedicatoria

Dedico esta tesis a mi Dios quien supo guiarme por el buen camino, darme fuerzas para seguir adelante y no desmayar en los problemas que se presentaban.

A mis padres Digna y Rolando, quienes son el pilar fundamental en mi vida, por su incondicional apoyo, consejos, comprensión, amor y ayuda en el tiempo en el que escribía esta tesis.



Agradecimiento

Primeramente, agradezco a Dios por permitirme estar con vida y por tener a los seres más queridos junto a mí. En segundo lugar a los que forman parte esencial en mi familia a mis padres Digna y Rolando, a mis hermanas y a mi hermano, ya que me han apoyado siempre. Y finalmente al Dr. Santiago Torres por su dirección, paciencia, y valiosos consejos que me permitieron terminar esta tesis.



CAPÍTULO 1

INTRODUCCIÓN

Un sistema eléctrico de potencia (SEP) está constituido básicamente de fuentes de generación, el sistema de transmisión, el sistema de distribución, y consumidores. El objetivo del SEP es transportar la energía eléctrica producida en los centros de generación hacia los centros de consumo con niveles adecuados de seguridad, confiabilidad, calidad, de la manera más económica posible y respetando restricciones ambientales.

A medida que aumenta la demanda en el transcurso del tiempo, el SEP requiere el planeamiento de nuevas inversiones con el objetivo de expandir tal sistema. Es por esta razón que el planeamiento de la expansión del sistema eléctrico resulta ser una actividad muy importante con el fin atender los requerimientos del incremento de la demanda, para proveer de energía económicamente aceptable, confiable, y manteniendo los criterios técnicos y ambientales del sistema.

El planeamiento del sistema eléctrico de potencia se lleva a cabo en intervalos de tiempo (horizonte de tiempo), considerados de corto, mediano y largo plazo. En el corto plazo (1 -5 años), se realiza el planeamiento para la construcción, supervisión y financiamiento de obras, las cuales fueron seleccionadas para ser realizadas. En el mediano plazo (5 -10 años), se realiza un plan de obras para el sistema en estudio, es decir, se planea qué instalaciones o equipos son necesarios, cuándo es el mejor momento para su puesta en marcha y dónde sería más efectiva su ubicación. En el largo plazo (10 -15 años), conocido como planeamiento de la expansión del sistema de potencia, se busca satisfacer la demanda futura con la incorporación de nuevas instalaciones al sistema eléctrico [1].



Normalmente, el planeamiento de la expansión del sistema eléctrico se lleva a cabo en los niveles de generación, transmisión, y distribución. Este trabajo está orientado al problema del planeamiento de la expansión de largo plazo de los sistemas de transmisión. El planeamiento a largo plazo de la expansión de sistemas de transmisión (*PET*) tiene como objetivo determinar y seleccionar la red de transmisión que se debe construir para atender los requerimientos de demanda proyectada para un escenario futuro, minimizando los costos de inversión y abasteciendo de energía eléctrica a todos los usuarios con niveles operativos y ambientales adecuados [2], [3].

El PET puede ser estático y dinámico. El planeamiento estático proporciona el plan de expansión óptimo en un único y determinado horizonte de planeamiento (para un año específico), es decir, determina *qué, dónde y cuántos* circuitos de transmisión deben ser instalados en el sistema eléctrico; mientras que el planeamiento dinámico toma en consideración los periodos parciales dentro el horizonte de tiempo para determinar el plan de expansión óptimo. Es decir, además de determinar *qué, dónde y cuántos* indica *cuándo* debe ser instalada la infraestructura al sistema eléctrico.

Los parámetros a considerar para el estudio del PET son: *i)* Pronóstico de la Demanda: El pronóstico de la demanda es clave en la determinación de las decisiones de inversión, por lo que es necesario elegir un método adecuado de tal manera de minimizar el error de proyección, *ii)* Plan de Generación: El plan de generación indica la construcción y puesta en servicio de nuevas unidades en un horizonte de estudio, *iii)* Tratamiento del tiempo: Estático o dinámico, *iv)* Horizonte de tiempo: Corto, mediano o largo Plazo y *v)* Topología inicial de la red eléctrica.

Desde el punto de vista matemático, la solución al problema del PET requiere considerar dos componentes principales: *i)* Modelación matemática y *ii)* Algoritmo de solución.



El PET, en su forma más compleja, representa un problema combinatorio cuyo modelo matemático corresponde a un problema de programación no lineal entero mixto (PNLEM). Entre los modelos matemáticos para resolver el problema del planeamiento tendremos: modelo DC [4], [5], [6], [7], [8], modelo de transportes [9], [10], modelo híbrido [9], [11], y el modelo de flujo de carga AC [2], [12], [13], [14].

Normalmente, para resolver el problema del PET se emplea el modelo de flujo de carga de corriente continua (DC), que es una versión simplificada del modelo de flujo de carga de corriente alterna (AC). El modelo DC tiene la ventaja de ser un modelo matemático de fácil implementación. Sin embargo, presenta algunas desventajas: *i)* permite realizar el planeamiento de la expansión considerando solamente la potencia activa, y *ii)* si se requiere realizar el planeamiento de potencia reactiva, esto se resuelve en pasos posteriores [11], [15]. El uso del modelo de la red de transmisión de corriente alterna AC es el modelo matemático ideal para representar el problema del PET; el uso de este modelo permite determinar las pérdidas exactas de potencia activa y reactiva durante el proceso de optimización; además, en el mismo proceso se puede ubicar de forma óptima los equipos de compensación de potencia reactiva [2], [12]; sin embargo, la solución de este modelo representa un problema de gran complejidad matemática debido a que su formulación es un problema de PNLEM [2], [12], [13], [14].

Para resolver los modelos matemáticos del PET se utiliza principalmente métodos de programación matemática y métodos meta-heurísticos. Los métodos de programación matemática pueden garantizar soluciones óptimas de acuerdo al modelo que se use actualmente, incluso para sistemas de gran escala en tiempos computacionales razonables [16], [17], [18], [19]. Los métodos meta-heurísticos son otra alternativa para resolver problemas del planeamiento de la expansión del sistema de transmisión. Entre los algoritmos meta-heurísticos para resolver el



problema del PET tendremos: algoritmos genéticos [20], [21], búsqueda tabú [10], algoritmos evolutivos [2], algoritmo de sistema de colonia de hormigas [22], enjambre de partículas [4], [5], [12]. Existen otros métodos meta-heurísticos como los Algoritmos de Estimación de Distribuciones denominados EDAs que aún no han sido aplicados como métodos de solución del PET. Los EDAs son algoritmos derivados de los Algoritmos Evolutivos (EAs). La diferencia entre estos dos algoritmos reside en la forma de mejorar el conjunto de soluciones en cada generación. En los EAs las nuevas poblaciones se generan tomando en consideración las características de los individuos (operadores de cruce, mutación, probabilidad de cruce, probabilidad de mutación, número de individuos, etc.); mientras que los EDAs se basan en encontrar una solución a un problema por medio de la búsqueda estocástica de las poblaciones de soluciones candidatas. Los EDAs consisten en encontrar mejores soluciones en cada iteración (nueva población) mediante las características estocásticas de la población anterior. Es decir, para generar una nueva población se requiere primero estimar la distribución de probabilidad de una cierta cantidad de individuos (los que ofrezcan mejores soluciones) dentro del espacio de búsqueda de la población anterior, y después realizar el muestreo de la distribución de probabilidad para generar un nuevo conjunto de posibles soluciones. El Algoritmo Genético Compacto (AGc) y el Algoritmo de Aprendizaje Incremental Basado en Poblaciones (PBIL) son EDAs que optimizan una función basados en estadísticas de primer orden.

1.1 Alcance

En este trabajo se propone aplicar el Algoritmo Genérico Compacto y el Algoritmo de Aprendizaje Incremental Basado en Poblaciones para la solución del problema de planeamiento de la expansión de sistemas de transmisión estático de largo plazo, usando el modelo AC e incorporando el costo por pérdidas en la función objetivo. El horizonte de planificación considerado es de 10 años. Para este trabajo se asume conocido el crecimiento de la demanda, el plan de generación y los costos de adiciones de líneas.



La implementación de la técnica meta-heurística se realizó en el entorno MATLAB; para resolver el flujo óptimo de potencia se utilizará el paquete de software MATPOWER.

El desempeño de los algoritmos se analizará en los sistemas de pruebas de Garver de 6 nodos y el sistema de la IEEE de 24 nodos.

1.2 Objetivos

El objetivo principal del trabajo consiste en desarrollar un algoritmo computacional para resolver el problema del PET estático de largo plazo, utilizando las técnicas de optimización del Algoritmo Genético Compacto y dos variantes del Algoritmo de Aprendizaje Incremental Basado en Poblaciones, usando el modelo AC de la red de transmisión.

1.3 Objetivos parciales

- Realizar un programa computacional, en entorno MATLAB, para resolver el problema del planeamiento de la expansión del sistema de transmisión estático de largo plazo, utilizando el modelo matemático del flujo de carga AC y técnicas de optimización meta-heurísticas basadas en el algoritmo genérico compacto y el algoritmo de aprendizaje incremental basado en poblaciones.
- Incluir el costo de pérdidas de energía en la función objetivo de expansión.
- Verificar el desempeño de los algoritmos usando el sistema de prueba de Garver de 6 nodos y el sistema de la IEEE de 24 nodos.
- Comparar los resultados obtenidos con otros publicados sobre este tema.

1.4 Contenido

El Capítulo 1 de este trabajo presenta una descripción general del tema de investigación, la metodología utilizada, el alcance, y los objetivos que se pretenden alcanzar. Una descripción teórica del planeamiento de la expansión del SEP, y particularmente del sistema de transmisión junto con su estado del arte se



presentan en el Capítulo 2. En el Capítulo 3 se describen los modelos matemáticos existentes y el modelo propuesto en este trabajo para resolver el PET. Los algoritmos meta-heurísticos basados en EDAs se presentan en el Capítulo 4. El Capítulo 5 presenta los resultados del trabajo de investigación. Las conclusiones y recomendaciones se presentan el capítulo 6.



CAPÍTULO 2

PLANEAMIENTO DE LA EXPANSIÓN DEL SISTEMA DE TRANSMISIÓN DE ENERGÍA ELÉCTRICA.

Introducción

Con el incremento de la demanda eléctrica a lo largo de los años el sistema eléctrico de potencia requiere ser modificado de tal manera de proporcionar un suministro de energía eléctrica adecuado, fiable y a un costo razonable. Desde el punto de vista económico, con inversiones excesivas la infraestructura resulta subutilizada lo que resulta en un daño a la economía del país. Por otro lado, en un sistema sin la adecuada infraestructura podría existir déficit de energía, líneas sobrecargadas, etc., resultando en un sistema eléctrico ineficiente que igualmente redundaría en un perjuicio económico para el país.

Para prever esas situaciones, el PET resulta en una actividad esencial para que la demanda de energía eléctrica pueda ser satisfecha. Esta actividad debe ser desarrollada en cada una de las etapas del sistema eléctrico: *i)* Generación, *ii)* Transmisión y *iii)* Distribución.

En el planeamiento de la expansión del sistema de transmisión, tema central de esta tesis, el objetivo es encontrar las rutas óptimas de tal manera de suministrar completamente la demanda, cumpliendo restricciones técnicas (sin sobrecargar las líneas de transporte, tensiones adecuadas en los nodos, etc.) y económicas (costo mínimo), conociendo la generación y demanda para un horizonte de tiempo predefinido.

En este capítulo se describen los conceptos teóricos de planeamiento de sistemas eléctricos en general, y en particular el planeamiento de la expansión del sistema de transmisión. Además, se describen diferentes técnicas de optimización empleadas para resolver el problema del planeamiento de la expansión del sistema de transmisión. Este capítulo no describe conceptos del planeamiento de la expansión del sistema de distribución debido a que esta actividad tiene consideraciones especiales diferentes a las de los otros dos sistemas aunque en concepto es similar al planeamiento de la expansión del sistema de transmisión.

2.1 Planeamiento de la expansión del sistema eléctrico de potencia

El planeamiento de la expansión del sistema eléctrico de potencia tiene como objetivo obtener el máximo beneficio técnico-económico de las nuevas instalaciones eléctricas proyectadas para un periodo de tiempo establecido, de tal forma de satisfacer la demanda futura al mínimo costo [23], [24].

Para realizar el planeamiento de la expansión de un SEP se debe considerar algunos parámetros tales como: *i)* Horizonte de tiempo *ii)* Tratamiento del problema dentro del horizonte de tiempo *iii)* Pronóstico de la demanda y *iv)* Sector a planificar, mostrados en la Figura 2.1.

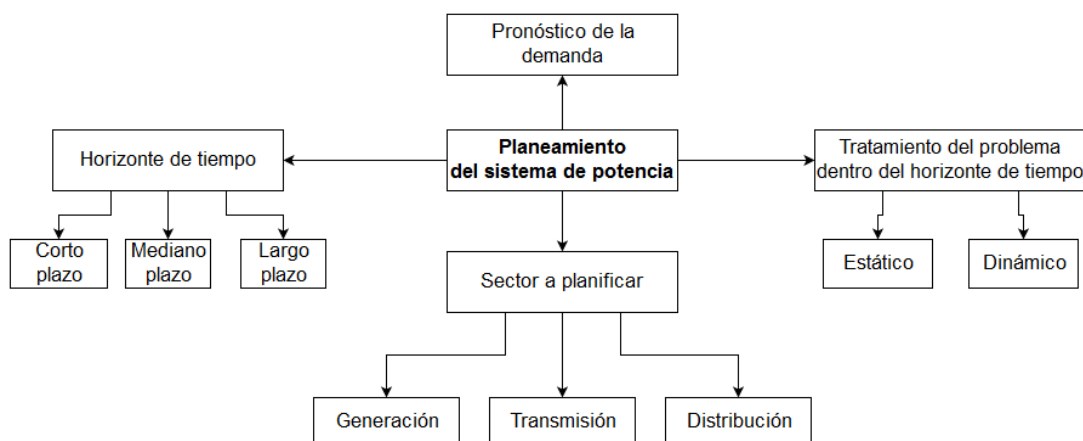


Figura 2.1: Parámetros a considerar en el PET



2.1.1 Horizonte de tiempo

El planeamiento del sistema eléctrico de potencia se lleva a cabo para ciertos intervalos de tiempo (horizonte de tiempo), considerados de corto, mediano y largo plazo. En el corto plazo (1 -5 años), se realiza el planeamiento para la construcción, supervisión y financiamiento de obras, las cuales fueron seleccionadas para ser realizadas. En el mediano plazo (5 -10 años), se realiza un plan de obras para el sistema en estudio, es decir, se planea qué instalaciones o equipos son necesarios, cuándo es el mejor momento para su puesta en marcha y dónde sería más efectiva su ubicación. En el largo plazo (10 -15 años), conocido como planeamiento de la expansión del sistema de potencia, se busca satisfacer la demanda futura con la incorporación de nuevas instalaciones al sistema eléctrico [1]. Estos lapsos de tiempo, aunque cubren los periodos de tiempo usados en varios países, son referenciales ya que cada país define lo que significa corto, mediano y largo plazo en cuanto al planeamiento del sistema eléctrico se refiere [23], [25], [26].

2.1.2 Pronóstico de la demanda

Para realizar el planeamiento de la expansión del sistema eléctrico es fundamental pronosticar la demanda futura para el periodo de estudio del planeamiento. Este aspecto resulta fundamental ya que, ante diferentes escenarios de crecimiento de la demanda, los planes obtenidos necesariamente deberían ser también diferentes.

De manera semejante que, en el planeamiento del sistema eléctrico de potencia, el pronóstico de la demanda se realiza en diferentes periodos de tiempo considerados de corto, mediano y largo plazo. El corto plazo consiste en pronosticar la demanda para proporcionar de energía eléctrica al sistema sobre un intervalo de horas, días y semanas. El mediano plazo consiste en la predicción de la demanda mensual hasta un año, con lo cual se tiene una adecuada coordinación de los recursos de las centrales generadoras para abastecer la



demanda futura, realizar programas de mantenimiento, planear el consumo de combustibles. El largo plazo consiste en la predicción de la demanda que abarca un horizonte de un año hasta diez años. La predicción de la demanda a largo plazo es usada para la planeación de la expansión de la generación y la transmisión.

Entre los métodos más utilizados para pronosticar la demanda a largo plazo tenemos: análisis de tendencias, modelos econométricos y análisis de uso final [23], [27].

El método de tendencias utiliza la información del pasado para establecer una función de ajuste de tal manera de extrapolar la curva de crecimiento de la demanda, asumiendo que los acontecimientos continuaran en la misma dirección y con la misma velocidad creciente de la demanda. Este método es fiable solamente si las variables que determinan la demanda futura se comportan de manera similar al comportamiento en el pasado.

Los modelos econométricos son métodos estadísticos que asocian el comportamiento de la demanda con variables económicas (población, ingreso per cápita, costo de la electricidad, etc.).

El análisis de uso final es utilizado principalmente para cargas residenciales. Está basado en calcular la energía eléctrica consumida por un número de aparatos eléctricos. El cálculo de la energía resulta de multiplicar el consumo individual por el número de usuarios, y de esta forma determinar se puede determinar el comportamiento futuro de la demanda.

A pesar de la disponibilidad de procedimientos matemáticos sofisticados, las proyecciones de demanda son en términos generales especulativos, incrementándose a medida que aumenta el periodo de pronóstico, ya que existen factores, que están sometidos a elevados grados de incertidumbre, tales como: *i)*

Indicadores económicos (ingreso per cápita, producto interno bruto PIB) *ii)* Crecimiento poblacional *iii)* Desarrollo tecnológico *iv)* Tipo de clientes, etc.

2.1.3 Planeamiento estático y planeamiento dinámico

El planeamiento de un sistema eléctrico de potencia se puede clasificar de acuerdo con el desarrollo temporal del plan. Este puede ser estático y dinámico.

Planeamiento estático

Se tiene un problema de planeamiento estático, cuando en un horizonte de tiempo se considera solamente las fechas inicial y final. Los resultados determinan la configuración óptima de la red al final del horizonte de tiempo, sin tomar en cuenta cuándo serán instalados los nuevos circuitos, es decir determina qué, dónde y cuántos equipos deben estar adicionados al sistema eléctrico al final del periodo de planificación. Si bien desde el punto de vista del esfuerzo computacional es más simple de resolver que el planeamiento dinámico, los resultados solo determinan las inversiones a realizar para un año específico.

Por ejemplo, como se muestra en la Figura 2.2, considerando un horizonte de tiempo de largo plazo (10 años) 2016-2026, si se conoce la demanda futura al final del periodo, entonces se realiza el estudio del planeamiento del sistema eléctrico para el año 2026.




Figura 2.2: Planeamiento estático.

Planeamiento dinámico

El planeamiento dinámico toma en consideración varias etapas (años) dentro del horizonte de tiempo para realizar el planeamiento, de modo que la solución se encuentra para todas las etapas al mismo tiempo. En este caso se determinan no solo los circuitos que es necesario instalar sino cuando han de ser instalados; es decir, además de determinar qué, dónde y cuántos, indica cuándo (en cuál etapa) deben ser instalados los equipos al sistema eléctrico.

Considerando la Figura 2.3, donde se tiene un horizonte de tiempo de 2016-2026, el estudio del planeamiento dinámico determinará las nuevas instalaciones que deberán ser instaladas para todas las 10 etapas (años) dentro del horizonte de tiempo cumpliendo las restricciones técnicas del sistema.

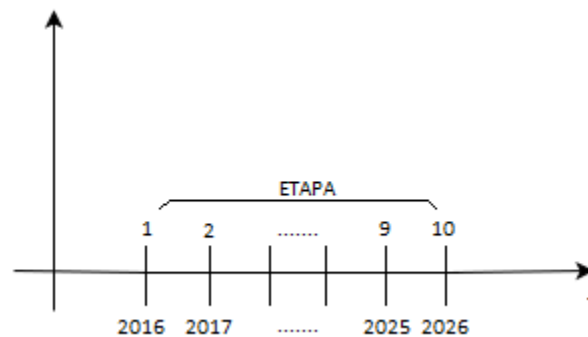


Figura 2.3: Planeamiento dinámico.

2.2 Planeamiento de la expansión del sistema de generación (PEG)

El PEG proporciona información desde el corto plazo con el despacho económico de las unidades, hasta el largo plazo con las nuevas centrales de generación que se requiere construir en términos del tipo, la capacidad, cuándo estará disponible y dónde serán instaladas; de tal forma de satisfacer la demanda futura de manera confiable, eficiente y al menor costo.

El planeamiento de la generación debe satisfacer la demanda eléctrica pronosticada y poseer una reserva de energía de manera de garantizar niveles mínimos de confiabilidad.



El PEG puede ser del tipo estático (la solución es proporcionada para un año específico) o del tipo dinámico (la solución es proporcionada para cada etapa dentro del periodo de estudio). El objetivo del PEG es minimizar una función objetivo de costos sujeta a ciertas restricciones.

Algunas de las restricciones a considerar en el PEG son: *i)* Límite presupuestario *ii)* Capacidad máxima y mínima de generación *iii)* Flujo máximo a través de los circuitos *iv)* Costo total de la inversión *v)* Margen de reserva de potencia.

Para el planeamiento de la expansión del sistema de generación se deben tomar en cuenta variables tales como: pronóstico de la demanda, costo de combustibles, crecimiento de país, disponibilidad de recursos energéticos, interconexiones eléctricas internacionales, tiempo de vida de la planta, etc. En [23] se estudia en detalle el problema del PEG.

2.3 Planeamiento de la expansión del sistema de transmisión (PET)

El PET, estático, a largo plazo tiene como objetivo determinar y seleccionar la red de transmisión que se debe construir para atender los requerimientos de demanda proyectada, minimizando la inversión y abasteciendo de energía eléctrica a todos los usuarios con niveles operativos adecuados, tomando en cuenta el funcionamiento del sistema en condición normal y ante la ocurrencia de contingencias [2], [23].

El PET permite determinar las rutas óptimas de las líneas de transmisión entre las fuentes de generación y las cargas, cumpliendo las siguientes restricciones del sistema: *i)* La capacidad máxima de transferencia de potencia de las líneas de transmisión, *ii)* equilibrio o balance entre la generación y la carga, *iii)* capacidad máxima de ampliación del sistema de transmisión y *iv)* capacidad máxima de generación



El problema del PET es un problema de optimización muy complejo debido al gran número de variables dependientes, variables independientes y restricciones. La solución del problema del planeamiento de la expansión consiste principalmente en determinar la modelación matemática y el algoritmo de solución.

2.3.1 Modelación matemática

La modelación matemática es una descripción mediante relaciones matemáticas (funciones y ecuaciones) de un problema de la vida real. Un modelo cuanto más exacto, sus soluciones se vuelven más complejas, pero permite obtener soluciones lo suficientemente precisas como para proveer conclusiones válidas.

El modelamiento del problema del PET utilizando las ecuaciones de flujo de carga AC no lineales implica el manejo de variables que lo hacen típico de la programación no lineal entera mixta (PNLEM), presentando además un fenómeno de explosión combinatoria de las soluciones, debido a la gran cantidad de posibles configuraciones factibles. Esto implica que el esfuerzo computacional para resolverlo crece de manera exponencial con el tamaño del problema [10].

Varios tipos de modelos matemáticos han sido propuestos en la literatura especializada para representar la red de transmisión en los estudios de la planificación de la expansión del sistema de transmisión. Desde modelos simplificados como por ejemplo el modelo de transporte [9], modelo DC [1], [4], [5], [7] y modelo híbrido que es una combinación de los dos primeros [1], [6], [10], [22], hasta modelos completos como el modelo AC [2], [12], [13], [14].

El modelo de transportes considera solamente la primera ley de Kirchhoff. Las ventajas del modelo es la facilidad para trabajar con modelos lineales y adicionalmente su formulación permite trabajar con sistemas no conexos (barras desconectadas del sistema principal) y conexos prácticamente de la misma manera. Por otro lado, el modelo DC permite una representación más aproximada



del sistema de potencia, ya que considera las dos leyes de Kirchhoff. Sin embargo, esta representación más exacta introduce una no linealidad en el problema [1]. El modelo DC es ampliamente utilizado para modelar el problema del PET. El modelo DC es un modelo matemático simple y de fácil implementación, aunque presenta ciertas desventajas tales como: *i)* permite realizar el planeamiento de la expansión considerando solamente la potencia activa y si se requiere realizar el planeamiento de potencia reactiva se realizan otros pasos posteriores [11], [15] y *ii)* sus soluciones muchas de las veces no son las de mínimo costo debido a que para ser implementado de forma práctica, el plan obtenido debe cumplir con el modelo AC.

Los modelos más estudiados para resolver el problema del PET han sido los modelos simplificados (especialmente el modelo DC), debido principalmente a que al modelo AC se lo consideraba intratable desde el punto de vista computacional. Normalmente, las soluciones producidas por el modelo DC proporcionan soluciones infactibles para el modelo AC [14], [28], [29]. Mientras que, el problema del PET utilizando el modelo AC (empleando ecuaciones de flujo de carga no lineales) es un muy complejo, combinatorial, no convexo, no lineal y de programación entera mixta (PNLEM). Ya que el estudio del PET usando el modelo AC se encuentra en sus etapas iniciales, existen muy pocos trabajos aplicando esta metodología. En [30], se presentó el algoritmo heurístico constructivo (CHA), cuyo enfoque fue probado para sistemas con generación despachable, donde los costos de compensación shunt no se tienen en cuenta. En [31], se propuso un nuevo enfoque simplificado del modelo AC basado en un problema lineal entero mixto. En la referencia [28], se propuso un modelo de optimización por caja negra que, de alguna manera, permite tomar en cuenta la compensación shunt. Este enfoque está direccionado para sistemas con generación no despachable. En [14], se propuso una formulación cónica para resolver el problema del PET por medio del modelo AC. Ese modelo proporciona soluciones con mejor precisión que los establecidos en [31]. Por otra parte, en [12]



se propuso una formulación para resolver el problema del PET, donde utiliza el modelo AC y optimización basada de Enjambre de Partículas (PSO). Ese trabajo (en el cual se basa esta tesis) toma en consideración la compensación shunt, además permite gestionar tanto la generación despachable como la no despachable. En [13] se propuso un nuevo enfoque para resolver el problema TEP utilizando el modelo AC y la herramienta de optimización Evolución Diferencial (DE) tomando en cuenta el criterio de contingencias (N-1).

En el Capítulo 3 se presentan las formulaciones de los diferentes modelos matemáticos utilizados en el PET.

2.4 Métodos de solución

Debido a que los modelos matemáticos del PET usando el modelo AC con ecuaciones de flujo de carga no lineales son problemas de PNLEM, durante los últimos años se han propuesto diversos métodos de optimización para resolver estos modelos que pueden ser clasificados en dos grupos: *i)* Métodos de optimización matemáticos y *ii)* Algoritmos Meta-Heurísticos [10].

2.4.1 Métodos de optimización matemáticos

Para resolver los modelos matemáticos del PET se utiliza principalmente métodos de programación matemática y métodos meta-heurísticos. Los métodos de programación matemática pueden garantizar soluciones óptimas de acuerdo al modelo que se use actualmente, incluso para sistemas de gran escala en tiempos computacionales razonables [16], [17], [18], [19]

En la actualidad existe una gran cantidad de trabajos de investigación de los algoritmos de programación matemática [23] aplicados al problema del PET: *i)* Programación Lineal [32], *ii)* Programación Lineal Entera Mixta [33], [34], *iii)* Programación Dinámica [35], *iv)* Programación no Lineal [36], *v)* Cortes de Benders [37], [38], *vi)* Métodos de *Branch and Bound* [39], [40], *vii)* Optimización Robusta [19]. Además, en los últimos años se han desarrollado las técnicas de



optimización convexa que, aunque han sido relativamente poco aplicadas en la resolución del problema PET, se espera que puedan ofrecer mejores soluciones al problema realizando relajaciones convexas al modelo AC [14],[41], [42].

2.4.2 Algoritmos Meta-heurísticos

Los algoritmos meta-heurísticos son otra alternativa interesante para resolver problemas del planeamiento de la expansión del sistema de transmisión. Son algoritmos aproximados que consisten en procedimientos iterativos que guían una heurística de acuerdo a un proceso determinado por el tipo de algoritmo. El proceso heurístico es aplicado hasta que el algoritmo no sea capaz de encontrar una solución mejor que considere los criterios de evaluación establecidos. Los criterios pueden ser: costos, número de iteraciones, etc.

En la literatura especializada existen varios trabajos de investigación que han abordado el problema de planeamiento de la expansión de los sistemas de transmisión usando técnicas de optimización meta-heurística. Los avances en esta área se potencian en gran medida por las mejoras en la capacidad de los sistemas de cómputo y por la implementación de nuevos o mejorados algoritmos de optimización.

Entre los algoritmos meta-heurísticos aplicados al problema del PET se tienen: *i)* Algoritmo Genético [43], [44], *ii)* Búsquedas Tabú [45], [46], *iii)* Algoritmos Evolutivos [33], [45], *iv)* Algoritmo de Sistema de Colonia de Hormigas [47], *v)* Enjambre de Partículas [4], [5], [7], [12], [17], *vi)* Evolución Diferencial [2], etc.



CAPÍTULO 3

MODELACIÓN MATEMÁTICA DEL PROBLEMA DE PLANEAMIENTO DE LA EXPANSIÓN DEL SISTEMA DE TRANSMISIÓN

Introducción

Para la formulación del problema del PET existen diferentes modelos matemáticos los cuales se pueden clasificar de acuerdo a su grado de complejidad. Desde modelos simplificados, como por ejemplo el modelo de transporte, el modelo híbrido lineal, el modelo híbrido no lineal y el modelo DC, hasta modelos completos como el modelo AC.

En la literatura, para resolver el problema del planeamiento de la expansión de la transmisión se han utilizado tradicionalmente los modelos matemáticos simplificados (modelo DC, modelo de transporte), pero estudios han demostrado que el uso de este modelo puede proporcionar costos de inversión muy alejados de la realidad [28], por lo que es necesario investigar sobre el uso del modelo AC, que puede resultar en un modelo más preciso para representar el problema del PET. Aunque el uso del modelo AC usando las ecuaciones de flujo AC no lineales para resolver el problema del PET es muy complejo, y representa un problema entero mixto, no lineal, combinatorial, no convexo, en los últimos años se ha investigado la factibilidad de su uso [2], [12], [28], [30].

En este capítulo se presenta algunos de los modelos matemáticos más importantes utilizados para resolver el problema estático del PET. Se detallará la explicación del modelo AC en el cual se basa en ese trabajo para resolver el problema del PET. Adicionalmente, se presentará la formulación del modelo AC incorporando pérdidas.



3.1 Formulación genérica

El problema de planeamiento estático del sistema de transmisión de energía eléctrica se formula como un problema de optimización que en general tiene la forma:

$$\min v = C(x) + d(y) \quad (3.1)$$

s. a.

$$A(x) \geq b \quad (3.2)$$

$$E(x) + F(y) \geq h \quad (3.3)$$

Dónde:

x : Representa las variables de decisión o variables de inversión.

$C(x)$: Representa el costo asociado a las decisiones de inversión.

$d(y)$: Representa el costo asociado a las decisiones de operación.

$A(x) \geq b$: Representa las restricciones asociadas a las decisiones de inversión.

y : Representa las variables de operación del sistema (decisiones respecto al nivel de generación en barras, corte de carga, flujos en las líneas y transformadores, etc.).

$E(x) + F(y) \geq h$: Representa las restricciones asociadas a las decisiones de operación.

3.2 Modelo de transporte

El modelo de transporte fue la primera propuesta sistemática de modelamiento matemático (utilizó Programación Lineal) usado con éxito en el



problema de planeamiento de sistemas de transmisión [1], el cual fue formulado por Garver [32].

Este modelo de transporte es un modelo simplificado que satisface solamente la primera ley de Kirchhoff, despreciando la segunda ley de Kirchhoff. El modelo matemático del problema de planeamiento de la expansión de la transmisión usando el modelo de transporte está dado por las siguientes ecuaciones:

$$\min v = \sum_{(i,j)} c_{ij} n_{ij} \quad (3.4)$$

s. a.

$$Sf + g = d \quad (3.5)$$

$$|f_{ij}| \leq (n_{ij} + n_{ij}^0) \bar{f}_{ij} \quad (3.6)$$

$$0 \leq g \leq \bar{g} \quad (3.7)$$

$$0 \leq n_{ij} \leq \bar{n}_{ij} \quad (3.8)$$

$$n_{ij} \text{ entero} \quad (3.9)$$

$$f_{ij} \text{ irrestricto} \quad (3.10)$$

Dónde:

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

c_{ij} : Costo de la adición de un circuito al sistema entre las barras $i - j$.

n_{ij} : Número de circuitos adicionados entre las barras $i - j$.

\bar{n}_{ij} : Número máximo de circuitos adicionados entre las barras $i - j$.

S : Matriz de incidencia de ramas del sistema eléctrico.

f : Vector de flujos cuyos elementos f_{ij} representan el flujo total en el camino $i - j$.



g : Vector de generación cuyos elementos g_i representan el nivel de generación en la barra de generación i .

d : Vector de demanda.

n_{ij}^0 : Número de circuitos del sistema base entre las barras $i - j$.

\bar{f}_{ij} : Flujo máximo para un circuito entre las barras $i - j$.

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

La función objetivo (3.4) representa el costo de inversión en nuevos circuitos, la ecuación (3.5) representa la primera ley de Kirchhoff; la restricción (3.6) representa la capacidad de transmisión de los circuitos. Las restricciones (3.7) y (3.8) establecen respectivamente, los límites de generación en cada nodo y el número máximo de circuitos que se pueden instalar en cada rama. La restricción (3.9) establece que el número de circuitos debe ser un número entero.

El modelo de transporte representa un modelo de programación lineal entera mixta (PLEM), y aunque presenta menor dificultad para ser resuelto, este se puede volver muy complejo para sistemas de gran tamaño.

Una ventaja significativa de utilizar este modelo es que permite resolver tanto sistemas conexos como no conexos, debido a que en la formulación matemática no se toma en consideración las reactancias de los circuitos, pero la gran desventaja de este método es que las soluciones encontradas pueden resultar muy alejadas de la solución óptima.

Existen diversos estudios sobre este modelo matemático como los presentados en [1], [9], [11].



3.3 Modelo híbrido no lineal

El modelo híbrido no lineal fue propuesto en [36], donde plantea encontrar una configuración que produzca la menor inversión en el plan de la expansión del sistema de transmisión bajo algunas consideraciones. El sistema eléctrico correspondiente a los caminos en donde ya existen circuitos en la configuración base deben satisfacer las dos leyes de Kirchhoff, y los caminos nuevos en donde no existen circuitos en la configuración base debe satisfacer solo la primera ley de Kirchhoff, por lo que este modelo es un modelo intermedio entre el modelo de transportes y el modelo de flujo de carga DC.

El modelo matemático presentado está modificado con respecto a [36], pero matemáticamente son equivalentes:

$$\min v = \sum_{(i,j)} c_{ij} n_{ij} \quad (3.11)$$

s. a.

$$Sf + g = d \quad (3.12)$$

$$f_{ij} - (\gamma_{ij}^0 + \gamma_{ij}^{eq})(\theta_i - \theta_j) = 0 \quad \forall (ij) \in \Omega_1 \quad (3.13)$$

$$|f_{ij}| \leq (n_{ij} + n_{ij}^0) \bar{f}_{ij} \quad (3.14)$$

$$0 \leq g \leq \bar{g} \quad (3.15)$$

$$0 \leq n_{ij} \leq \bar{n}_{ij} \quad (3.16)$$

$$\gamma_{ij} \text{ discreto} \quad (3.17)$$

$$n_{ij} \text{ entero} \quad (3.18)$$

$$f_{ij} \text{ irrestricto} \quad (3.19)$$

$$\theta_i \text{ irrestricto } \forall (ij) \in \Omega_3 \quad (3.20)$$

Dónde:

γ_{ij}^0 : Susceptancia equivalente a los circuitos existentes en el camino $i - j$ de la configuración base.



γ_{ij}^{eq} : Susceptancia equivalente de los circuitos adicionados en el camino $i - j$.

θ_i : Magnitud del ángulo de la tensión de las barras existentes.

Ω_1 : Representa el conjunto de circuitos existentes en la configuración base.

Ω_2 : Representa el conjunto de circuitos correspondientes a los nuevos caminos.

Ω_3 : Representa el conjunto de nodos que hacen parte de la configuración base.

La ecuación (3.12) representa la primera ley de Kirchhoff, y (3.13) representa la ecuación correspondiente a la segunda ley de Kirchhoff. El conjunto de ecuaciones correspondientes a la segunda ley de Kirchhoff solo se presenta para los caminos existentes en la configuración base ya que solo la topología inicial debe satisfacer la segunda ley de Kirchhoff y la restricción (3.20) expresa que los ángulos de fase son cantidades ilimitadas, es decir, que pueden tener valores positivos o negativos. En el nodo de referencia el ángulo de fase es fijo ($\theta_{ref} = 0$).

Debido a que las ecuaciones correspondientes a la segunda ley de Kirchhoff (3.13) son no lineales, el modelo híbrido no lineal representa un modelo de programación no lineal entera mixta (PNLEM) cuya solución se vuelve más compleja con respecto al modelo de transportes.

3.4 Modelo híbrido lineal

Debido a que el modelo no lineal representa un problema de PNLEM [1], existe una alternativa a este modelo (Modelo híbrido lineal) que puede ser más fácil de resolver convirtiéndolo en un problema de PLEM. El modelo está basado en que el sistema base debe satisfacer las dos leyes de Kirchhoff, y las nuevas



alternativas del sistema (sistema base más adición de líneas) debe satisfacer solo la primera ley de Kirchhoff. El modelo híbrido lineal es un modelo relajado del modelo híbrido no lineal.

La formulación matemática del modelo híbrido lineal asume la siguiente forma:

$$\min v = \sum_{(i,j)} c_{ij} n_{ij} \quad (3.21)$$

s. a.

$$Sf' + S_0f_0 + g = d \quad (3.22)$$

$$f_{ij}^0 - \gamma_{ij}^0(\theta_i - \theta_j) = 0 \quad \forall (ij) \in \Omega_1 \quad (3.23)$$

$$|f_{ij}^0| \leq (n_{ij}^0) \bar{f}_{ij} \quad \forall (ij) \in \Omega_1 \quad (3.24)$$

$$|f'_{ij}| \leq (n_{ij}) \bar{f}_{ij} \quad \forall (ij) \in \Omega_1 \quad (3.25)$$

$$0 \leq g \leq \bar{g} \quad (3.26)$$

$$0 \leq n_{ij} \leq \bar{n}_{ij} \quad (3.27)$$

n_{ij} entero

f_{ij} irrestricto

θ_i irrestricto $\forall (ij) \in \Omega_3$

Dónde:

S_0 : Matriz de incidencia de ramas en la configuración base.

f_0 : Vector de flujos en la configuración base.

S : Matriz de incidencia de ramas del sistema completo.

f' : Vector de flujos en los circuitos adicionados.

θ_j : Ángulos de fase de las barras en la configuración base.



γ_{ij} : Susceptancia de la línea conectada entre los nodos $i - j$.

d_i : Demanda en el nodo i

3.5 Modelo DC

El modelo DC es una generalización del modelo de flujo de carga DC. Este modelo presenta soluciones con valores más realistas con respecto a los modelos anteriores, ya que en el modelo DC el sistema eléctrico debe satisfacer las dos leyes de Kirchhoff, es decir, todas las barras del sistema deben satisfacer la primera ley de Kirchhoff y todos los lazos existentes deben satisfacer la segunda ley de Kirchhoff.

El modelo matemático DC del problema de planeamiento de la expansión del sistema de transmisión, desarrollado en [1], está dado por las siguientes ecuaciones:

$$\min v = \sum_{(i,j)} c_{ij} n_{ij} + \alpha \sum_{k \in \Gamma} r_k \quad (3.28)$$

s. a.

$$Sf + g + r = d \quad (3.29)$$

$$f_{ij} - (\gamma_{ij}^0 + \gamma_{ij}^{eq})(\theta_i - \theta_j) = 0 \quad (3.30)$$

$$f_{ij} \leq (\gamma_{ij}^0 + \gamma_{ij}^{eq}) \bar{\theta}_{ij} \quad (3.31)$$

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

$$0 \leq r \leq \bar{d}$$

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

$$n_{ij} \text{ entero}$$

$$f_{ij} \text{ irrestricto}$$

$$\gamma_{ij}^{eq} \text{ entero}$$

$$\theta_i \text{ irrestricto}$$



Dónde:

γ_{ij}^0 : Susceptancia equivalente de los circuitos existentes entre las barras $i - j$.

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

$c_{i,j}$: Costo de la adición de un circuito al sistema entre las barras $i - j$.

$f_{i,j}$: Flujo de potencia activa entre las barras $i - j$.

$n_{i,j}^0$: Número de circuitos adicionados entre las barras $i - j$.

g, d y r : Son vectores con las generaciones, las demandas y los cortes de carga nodales, respectivamente.

α : Factor de penalización para asegurar planes de expansión factibles (sin corte de carga).

\bar{n}_{ij} : Número de circuitos del sistema base entre las barras $i - j$.

La ecuación (3.29) representa la conservación de potencia en cada nodo (primera ley de Kirchhoff) de la red DC equivalente, la ecuación (3.30) modela la segunda ley de Kirchhoff, Γ representa el conjunto de todas las barras k en donde existe demanda; r_k representa la generación ficticia en la barra k y es utilizado para permitir encontrar una solución en los casos en que no exista suficiente capacidad de transmisión, agregando un generador ficticio en cada nodo de carga, pero al insertar un generador ficticio la variable α es un parámetro de penalización suficientemente grande de tal forma de obtener topologías de inversión poco atractivas.



El problema es de tipo PNLEM; entera por la presencia de variables de tipo entera como el número de circuitos adicionados, y no lineal debido a la presencia de la segunda ley de Kirchhoff.

3.6 Modelo AC

En la literatura tradicionalmente para resolver el problema del planeamiento de la expansión de la transmisión se utilizan modelos matemáticos simplificados (modelo DC, modelo de transporte), pero estudios han demostrado que el uso de este modelo puede proporcionar costos de inversión muy alejados de la realidad [28], por lo que es necesario investigar sobre el uso del modelo AC, que puede resultar en un modelo más preciso para representar el problema del PET. En [30], se presenta un algoritmo heurístico constructivo (CHA) que presenta una desventaja notable, la calidad de las soluciones disminuye para sistemas grandes. Posteriormente, en [28] propone un modelo de optimización tipo caja negra donde solo maneja generación no despachable. Este método, debido a que está basado en la composición de varios algoritmos heurísticos, no presenta demasiada calidad en las soluciones finales. En [12], se plantea la generalización del sistema de corte de carga para resolver el problema del PET usando el modelo AC y teniendo en cuenta la compensación en derivación. Las pruebas se realizaron para varios escenarios de expansión con la generación tanto despachable como no despachable. El algoritmo de solución utilizado es el algoritmo de optimización por enjambre de partículas (PSO). Este desarrollo presentó buenos resultados en sistemas pequeños de prueba (Sistema Garver de 6 nodos y Sistema de 24 nodos de la IEEE), y se necesita de investigación adicional para sistemas de alto nivel de complejidad como es el sistema brasilero de 87 nodos.

3.6.1 Función objetivo

La función objetivo usando el modelo matemático AC se formula en [2], [12], de la siguiente forma:



$$\min v = \sum_{(k,l) \in \Omega} c_{kl} n_{kl} + w \quad (3.32)$$

s. a.

$$0 \leq n \leq \bar{n}; n \text{ entero} \quad (3.33)$$

Dónde:

v : Inversión debido a adiciones de circuitos en el sistema más costo de desconexión de carga más costo de la compensación shunt.

c_{kl} : Costo de la adición de un circuito al sistema entre las barras $k - l$.

n_{kl} : Número de circuitos adicionados entre las barras $k - l$.

w : Costo de producción de carga activa y reactiva.

n : Vector con el número total de circuitos existentes y adicionados.

\bar{n} : Vector del número máximo de circuitos permitidos entre las barras $k - l$.

Ω : Conjunto de todos los caminos en el sistema eléctrico.

En la función objetivo de la ecuación (3.32) se puede diferenciar dos términos correspondientes a:

1. El problema principal de planeamiento $\rightarrow \sum_{(k,l) \in \Omega} c_{kl} n_{kl}$
2. El problema operacional $\rightarrow w$

El problema principal de planeamiento representa el costo total de la adición de las líneas de transmisión. El problema operacional ecuación (3.34) calcula los costos por producción de carga activa y reactiva (carga no servida o no atendida) para cada topología del sistema mediante la formulación del flujo de potencia óptimo AC junto con restricciones operacionales del sistema. La producción de carga activa y reactiva se modela mediante generadores artificiales que deben ser



adicionados en todas las barras de carga (barras PQ) cuando la generación y su sistema de transporte no son capaces de atender la demanda.

$$\min w = \sum_{k \in A} \alpha_1 r_{Pk} + \alpha_2 r_{Qk} \quad (3.34)$$

s. a.

$$P(V, \theta) - P_G + P_D - r_P = 0 \quad (3.35)$$

$$Q(V, \theta) - Q_G + Q_D - r_Q = 0 \quad (3.36)$$

$$\underline{P}_G \leq P_G \leq \bar{P}_G \quad (3.37)$$

$$\underline{Q}_G \leq Q_G \leq \bar{Q}_G \quad (3.38)$$

$$\underline{r}_P \leq r_P \leq \bar{r}_P \quad (3.39)$$

$$\underline{r}_Q \leq r_Q \leq \bar{r}_Q \quad (3.40)$$

$$\underline{V} \leq V \leq \bar{V} \quad (3.41)$$

$$s^{from} \leq \bar{S} \quad (3.42)$$

$$s^{to} \leq \bar{S} \quad (3.43)$$

Dónde:

r_P : Producción de potencia activa.

α_2 : Costo de la compensación shunt.

r_Q : Producción de potencia reactiva.

V : Vector de magnitud de voltajes.

α_1 : Costo de la producción de potencia activa.

θ : Vector de ángulos de voltajes.

P_G : Vector de potencia activa generada.

Q_G : Vector de potencia reactiva generada.

P_D : Vector de potencia activa demandada.

Q_D : Vector de potencia reactiva demandada.

\overline{P}_G : Vector de máxima potencia activa generada.

\overline{Q}_G : Vector de potencia reactiva generada.

La ecuación (3.35) y (3.36) representan las ecuaciones de flujo de potencia AC, donde los elementos del vector $P(V, \theta)$ y $Q(V, \theta)$ son calculados por las ecuaciones (3.44) y (3.45) y corresponden a la potencia activa y reactiva en las líneas de transmisión.

$$P_k(V, \theta) = V_k \sum_{l \in M} V_l [G_{kl} \cos \theta_{kl} + B_{kl} \sin \theta_{kl}] \quad (3.44)$$

$$Q_k(V, \theta) = V_k \sum_{l \in M} V_l [G_{kl} \sin \theta_{kl} - B_{kl} \cos \theta_{kl}] \quad (3.45)$$

Los elementos de la matriz de admitancia G_{kl} y B_{kl} se pueden calcular por medio de las ecuaciones (3.46) y (3.47) respectivamente.

$$G = \begin{cases} G_{kl}(n) = -(n_{kl} g_{kl} + n_{kl}^0 g_{kl}^0) \\ G_{kk}(n) = \sum_{l \in \Omega_k} (n_{kl} g_{kl} + n_{kl}^0 g_{kl}^0) \end{cases} \quad (3.46)$$

$$B = \begin{cases} B_{kl}(n) = -(n_{kl} b_{kl} + n_{kl}^0 b_{kl}^0) \\ B_{kk}(n) = b_k^{shunt} + \sum_{l \in \Omega_k} [(n_{kl} (b_{kl} + b_{kl}^{shunt}) + n_{kl}^0 (b_{kl}^0 + (b_{kl}^{shunt})^0))] \end{cases} \quad (3.47)$$

Dónde:

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

$g_{kl}, b_{kl}, b_{kl}^{sh}$: Corresponde a la conductancia, susceptancia y susceptancia shunt de la línea de transmisión.

b_k^{sh} : Corresponde a la susceptancia shunt en la barra k .

Los valores de S^{from} y S^{to} son calculados por las ecuaciones (3.48) y (3.49).

$$S_{kl}^{from} = \sqrt{(P_{kl}^{from})^2 + (Q_{kl}^{from})^2} \quad (3.48)$$

$$S_{kl}^{to} = \sqrt{(P_{kl}^{to})^2 + (Q_{kl}^{to})^2} \quad (3.49)$$

Dónde:

M : Conjunto de todos los buses.

k, l : Líneas entre barras.

θ_{kl} : Diferencia del ángulo de fase entre la barra k y la barra l .

G_{kl} y B_{kl} : Elementos de la matriz de admitancias.

3.6.2 Costos por compensación shunt

En el problema operacional mostrada en la ecuación (3.34) el término $(\alpha_2 r_{Qk})$ permite modelar la compensación shunt, basada en la producción de carga reactiva, 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 se modela mediante una función lineal de costos variables por intervalos como se muestra en la Figura 3.1.

La Figura 3.1 proporciona el costo de la producción de potencia reactiva tanto inductiva como capacitiva. Es importante tener en cuenta que el costo de la compensación debe ser siempre positivo, de tal manera que cuando se tiene

compensación capacitiva (inyección de potencia positiva), el coeficiente de costo α_2 se modela como positivo. Por otro lado, cuando la compensación reactiva es inductiva (inyección de potencia negativo), el coeficiente de costo α_2 se modela como negativo.

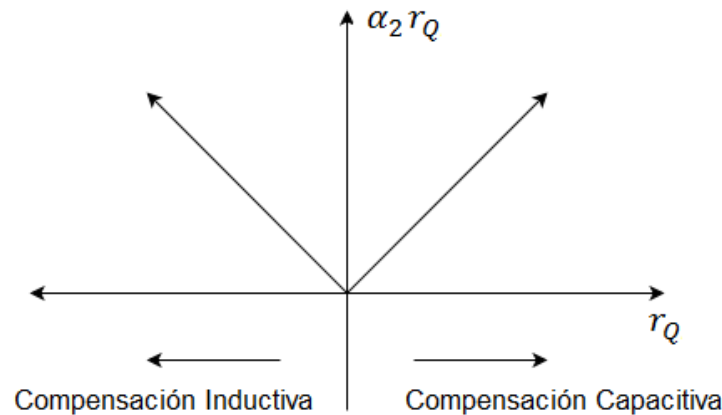


Figura 3.1: Función costos para la compensación de reactivos.

3.6.3 Descripción del método de producción de potencia activa y reactiva

En una cierta iteración i del algoritmo de optimización, las posibles soluciones (topologías generadas) son evaluadas a través del flujo de potencia óptimo AC. Si una topología de transmisión particular es factible, el flujo de potencia óptimo AC convergerá incluso en caso de violación de la restricción. Una violación de la restricción se mitiga inicialmente por el flujo de potencia óptimo AC a través de la generación por redespacho que es la forma más económica. Si esto no es posible, el flujo de potencia óptimo AC utilizará generadores ficticios que es la forma más cara [2], [12]. En este caso, pueden ocurrir las siguientes situaciones:

- Cuando no hay producción de potencia activa ($\alpha_1 r_p$). El generador ficticio no genera potencia activa (r_p), por lo tanto, toda la demanda activa es atendida por la topología de transmisión actual del sistema. En este caso todas las restricciones se cumplen.



- Cuando hay producción de potencia activa ($\alpha_1 r_p > 0$). La generación no puede atender la demanda total activa requerida en el sistema, por lo que los generadores ficticios deben ser adicionados. El generador ficticio genera potencia activa (r_p) El costo de la potencia activa suministrada por el generador ficticio debe ser adicionado al costo total del planeamiento, esto se realiza con la variable α_1 . La variable α_1 es un factor de penalización a la potencia no atendida por la topología actual del sistema de transmisión.
- Cuando no hay producción de potencia reactiva ($\alpha_2 r_{Qk}$). El generador ficticio no genera potencia reactiva (r_Q), por lo tanto toda la demanda reactiva es atendida por la topología de transmisión actual del sistema. En este caso todas las restricciones se cumplen.
- Cuando hay producción de potencia reactiva ($\alpha_2 r_{Qk} > 0$). Ocurre cuando la topología actual de transmisión no cumple con los requisitos de potencia reactiva del sistema, por lo que necesita generación de potencia reactiva, esta potencia reactiva se consigue con la adición de generadores artificiales que suministren potencia reactiva. El costo de la generación de la compensación α_2 de potencia reactiva producto con la potencia reactiva generada (r_Q) deben ser añadidos al costo total del PET.

3.7 Modelo AC con costo de pérdidas

El modelo AC anteriormente descrito no permite calcular el problema de planeamiento incluyendo pérdidas, ya que las mismas se consideran nulas. Sin embargo, es posible incluir las pérdidas de potencia activa, añadiendo el costo por pérdidas al costo total de planeamiento.



3.7.1 Función objetivo

La función objetivo usando el modelo matemático AC incluyendo pérdidas se formula de la siguiente forma:

$$\min v = \sum_{(k,l) \in \Omega} c_{kl} n_{kl}^{Anual} + w^{Anual} + C_{perd}^{Anual} \quad (3.50)$$

s. a.

$$0 \leq n \leq \bar{n}; n \text{ entero} \quad (3.51)$$

Dónde:

v : Inversión debido a adiciones de circuitos en el sistema más costo de desconexión de carga más costo de la compensación shunt más costo asociado a pérdidas (costos anualizados).

c_{kl}^{Anual} : Costo anualizado de la adición de un circuito al sistema entre las barras $k - l$.

n_{kl} : Número de circuitos adicionados entre las barras $k - l$.

w^{Anual} : Costo anualizado de la producción de potencia activa y reactiva.

n : Vector con el número total de circuitos existentes y adicionados.

\bar{n} : Vector del número máximo de circuitos permitidos entre las barras $k - l$.

Ω : Conjunto de todos los caminos en el sistema eléctrico.

En la función objetivo de la ecuación (3.50) se puede diferenciar tres términos correspondientes a:

1. Costo asociado a pérdidas $\rightarrow C_{perd}^{Anual}$



2. El problema principal de planeamiento (costo de inversión de nuevos circuitos de transmisión) $\rightarrow \sum_{(k,l) \in \Omega} c_{kl} n_{kl}^{Anual}$
3. El problema operacional (costo de energía no suministrada, costo de compensación de potencia reactiva) $\rightarrow w^{Anual}$

Para incluir el costo de pérdidas en la F.O. se considera que el problema del PET presenta un horizonte temporal con una determinada demanda máxima prevista. Las pérdidas totales de potencia activa para cada topología del sistema se calculan para ese nivel de demanda máxima. Ya que la función objetivo está en función de costos, se requiere colocar las pérdidas en función del costo, para lo cual el costo anual total de las pérdidas viene dado por la ecuación (3.52):

$$C_{perd}^{Anual} = 8760 * \lambda * f_{perd} * P_{total} \quad (3.52)$$

Dónde:

P_{total} : Pérdidas totales de potencia activa de una topología.

8760: Número de horas en un año.

λ : Costo unitario de la energía.

f_{perd} : Factor de pérdidas en la red anuales.

Para calcular el valor de P_{total} se parte de las potencias calculadas en cada barra. Las potencias calculadas en las barras se obtienen a partir de las ecuaciones de potencia compleja (ecuaciones (3.53) y (3.54)), y corrientes de barra (ecuaciones (3.52) y (3.53)).



$$S = VI^* \quad (3.53)$$

$$S_k = P_k + jQ_k \quad (3.54)$$

$$I = YV \quad (3.55)$$

$$I_k = \sum_{k \in M} (G_{kl} + jB_{kl} \text{sen} \theta_{kl})(\text{cos} \theta_{kl} + j \text{sen} \theta_{kl}) V_k \quad (3.56)$$

De donde se deducen las ecuaciones (3.57) y (3.58) correspondientes a la potencia activa y reactiva en cada barra.

$$P_k(V, \theta) = V_k \sum_{k \in M} V_l [G_{kl} \text{cos} \theta_{kl} + B_{kl} \text{sen} \theta_{kl}] \quad (3.57)$$

$$Q_k(V, \theta) = V_k \sum_{k \in M} V_l [G_{kl} \text{sen} \theta_{kl} - B_{kl} \text{cos} \theta_{kl}] \quad (3.58)$$

Las pérdidas de potencia activa por cada derecho de transmisión (ejemplo entre las barras $k - l$) están dadas por la suma de los flujos de potencia de P_{kl} y P_{lk} , esto es:

$$P_{\text{perd}(kl)} = P_{kl}(V, \theta) + P_{lk}(V, \theta) \quad (3.59)$$

Las pérdidas totales de potencia activa para cada topología se calculan por la ecuación (3.60), que es la sumatoria de las pérdidas de potencia activa en cada derecho de transmisión.

$$P_{\text{total}} = \sum_{(k,l) \in \Omega} P_{\text{perd}(kl)} \quad (3.60)$$

Ya que el periodo de amortización en las inversiones de infraestructuras de transporte suele ser muy larga (30 años), los parámetros λ y f_{perd} suelen sufrir considerables cambios por lo que se pueden obtener valores estimados, añadiendo mayor incertidumbre al problema del PET.



El problema principal de planeamiento representa el costo total anualizado de la adición de las líneas de transmisión. Si la amortización financiera de la inversión se realiza mediante términos de amortización constante, el coste anualizado de inversión se puede expresar por la ecuación (3.61) [26].

$$c_{kl}n_{kl}^{Anual} = CFR * (c_{kl}n_{kl}) \quad (3.61)$$

Siendo CFR el factor de recuperación por capital, el cual se obtiene por medio de la ecuación (3.62).

$$CFR = \frac{r(1+r)^n}{((1+r)^n - 1)} \quad (3.62)$$

Dónde:

r : Tasa de descuento (interés)

n : Número de años de amortización de la inversión

El problema operacional representado por las ecuaciones (3.63 – 3.72) proporciona el costo anualizado por producción de potencia activa y reactiva para cada plan de expansión.

$$\min w^{Anual} = \sum_{k \in \Lambda} CFR * (\alpha_1 r_{Pk} + \alpha_2 r_{Qk}) \quad (3.63)$$

s. a.

$$P(V, \theta) - P_G + P_D - r_P = 0 \quad (3.64)$$

$$Q(V, \theta) - Q_G + Q_D - r_Q = 0 \quad (3.65)$$

$$\underline{P}_G \leq P_G \leq \bar{P}_G \quad (3.66)$$

$$\underline{Q}_G \leq Q_G \leq \bar{Q}_G \quad (3.67)$$



$$\underline{r}_P \leq r_P \leq \bar{r}_P \quad (3.68)$$

$$\underline{r}_Q \leq r_Q \leq \bar{r}_Q \quad (3.69)$$

$$\underline{V} \leq V \leq \bar{V} \quad (3.70)$$

$$S^{from} \leq \bar{S} \quad (3.71)$$

$$S^{to} \leq \bar{S} \quad (3.72)$$

Dónde:

r_P : Producción de potencia activa.

α_2 : Costo de la compensación shunt.

r_Q : Producción de potencia reactiva.

V : Vector de magnitud de voltajes.

α_1 : Costo de producción de potencia activa.

θ : Vector de ángulos de voltajes.

P_G : Vector de potencia activa generada.

Q_G : Vector de potencia reactiva generada.

P_D : Vector de potencia activa demandada.

Q_D : Vector de potencia reactiva demandada.

\bar{P}_G : Vector de máxima potencia activa generada.

\bar{Q}_G : Vector de potencia reactiva generada.

El problema operacional corresponde a la formulación del flujo óptimo de potencia AC, con algunas limitaciones operacionales (similar al modelo AC sin

pérdidas). La producción de potencia activa y reactiva se modela mediante generadores artificiales que deben ser adicionados en todas las barras de carga (barras PQ) cuando la generación y su sistema de transporte no son capaces de atender la demanda. La producción de potencia activa y reactiva incluyendo costo por pérdidas es similar al modelo AC sin incluir costo por pérdidas (sección 3.6.3).

La ecuación (3.64) y (3.65) representa las ecuaciones de flujo de potencia AC, donde los elementos del vector $P(V, \theta)$ y $Q(V, \theta)$ son calculados por las ecuaciones (3.73) y (3.74); que corresponden a la potencia activa y reactiva en las líneas de transmisión.

$$P_k(V, \theta) = V_k \sum_{l \in M} V_l [G_{kl} \cos \theta_{kl} + B_{kl} \sin \theta_{kl}] \quad (3.73)$$

$$Q_k(V, \theta) = V_k \sum_{l \in M} V_l [G_{kl} \sin \theta_{kl} - B_{kl} \cos \theta_{kl}] \quad (3.74)$$

Los elementos de la matriz de admitancia G_{kl} y B_{kl} se pueden calcular por medio de las ecuaciones (3.75) y (3.76) respectivamente.

$$G = \begin{cases} G_{kl}(n) = -(n_{kl} g_{kl} + n_{kl}^0 g_{kl}^0) \\ G_{kk}(n) = \sum_{l \in \Omega_k} (n_{kl} g_{kl} + n_{kl}^0 g_{kl}^0) \end{cases} \quad (3.75)$$

$$B = \begin{cases} B_{kl}(n) = -(n_{kl} b_{kl} + n_{kl}^0 b_{kl}^0) \\ B_{kk}(n) = b_k^{shunt} + \sum_{l \in \Omega_k} [(n_{kl} (b_{kl} + b_{kl}^{shunt}) + n_{kl}^0 (b_{kl}^0 + (b_{kl}^{shunt})^0))] \end{cases} \quad (3.76)$$

Dónde:

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



g_{kl} , b_{kl} , b_{kl}^{sh} : Corresponde a la conductancia, susceptancia y susceptancia shunt de la línea de transmisión.

b_k^{sh} : Corresponde a la susceptancia shunt en la barra k .

Los valores de S^{from} y S^{to} son calculados por las ecuaciones (3.77) y (3.78).

$$S_{kl}^{from} = \sqrt{(P_{kl}^{from})^2 + (Q_{kl}^{from})^2} \quad (3.77)$$

$$S_{kl}^{to} = \sqrt{(P_{kl}^{to})^2 + (Q_{kl}^{to})^2} \quad (3.78)$$

Dónde:

M : Conjunto de todos los buses.

k, l : Líneas entre barras.

θ_{kl} : Diferencia del ángulo de fase entre la barra k y la barra l .

G_{kl} y B_{kl} : Elementos de la matriz de admitancias.



CAPÍTULO 4

ALGORITMOS DE ESTIMACIÓN DE DISTRIBUCIÓN PARA LA RESOLUCIÓN DEL PET

Introducción

Los algoritmos genéticos son técnicas de búsqueda basados en la selección y recombinación de soluciones prometedoras. Estos algoritmos han logrado un cierto éxito en la resolución de algunos problemas de optimización complejos en los últimos años. Sin embargo, el rendimiento de los algoritmos genéticos depende de un buen número de parámetros tales como: los operadores de cruce y mutación, las probabilidades de cruce y mutación, el tamaño de la población, la tasa de reproducción generacional, el número de generaciones, etc. Para diferentes problemas, la elección de los valores adecuados es de vital importancia, por lo que la tarea de seleccionar la mejor opción de valores para todos estos parámetros se ha sugerido para constituir en sí misma un problema de optimización adicional [48]. Por otro lado, el algoritmo genético presenta un bajo rendimiento en algunos problemas debido a su convergencia prematura.

Las razones anteriores han motivado la creación de un nuevo método de búsqueda conocido como Algoritmo de Estimación de Distribuciones denotado como EDAs (por sus siglas en inglés *Estimation of Distribution Algorithms*) que es una extensión del algoritmo genético, con el fin de predecir de manera más fácil los movimientos de las poblaciones en el espacio de búsqueda, así como también evitar la necesidad de tantos parámetros [49], [50].

Este capítulo está dividido en dos secciones. La primera presenta la técnica de optimización meta-heurística basada en el algoritmo de estimación de distribuciones (EDAs) y sus algoritmos básicos (aplicados en el dominio continuo y



en el dominio binario): Algoritmo Genético Compacto (AGc) y el Algoritmo de Aprendizaje Incremental Basado en Poblaciones (PBIL). La segunda sección corresponde a la implementación de los algoritmos en el entorno MATLAB para resolver el modelo matemático AC del problema de PET formulado en el capítulo anterior.

4.1 Algoritmos de estimación de distribución

Los EDAs tienen su base teórica en la teoría de la probabilidad. Estos algoritmos, están basados en poblaciones que evolucionan a medida que avanza el proceso de búsqueda, donde la creación de un nuevo conjunto de soluciones de forma probabilística es el punto clave para el proceso de búsqueda. Es decir, los EDAs utilizan un modelo probabilístico de las soluciones prometedoras (mejores soluciones) para estimar una distribución sobre el espacio de búsqueda. La nueva población es generada a partir de la distribución de probabilidad estimada del modelo probabilístico.

En los EDAs la población está representada por un *vector de probabilidad*. A medida que avanza el proceso de optimización (nueva iteración), el vector de probabilidad es utilizado para la generación de la nueva población y posteriormente es desplazado (actualizado) por el algoritmo correspondiente hacia las áreas más prometedoras del espacio de búsqueda.

La estructura básica de los EDAs (ver Algoritmo 4.1), inicia con una población inicial de soluciones candidatas x_i con N individuos generados aleatoriamente. Después de la generación de una población inicial y posterior evaluación de todos sus miembros, se procede a seleccionar $M < N$ individuos con mejores soluciones, para construir un modelo probabilístico n -dimensional (actualización del vector de probabilidad) en base a estos individuos. Del modelo probabilístico se realiza un muestreo a partir de una distribución de probabilidad (ya sea discreto o continuo) para generar la nueva población x_i . Este proceso se repite hasta que se alcanza algún criterio de parada.

Establecer N (tamaño de población)

Generar un población de soluciones iniciales x_i con $i \in [1, N]$

Con cada *individuo* x_i con n elementos $x_i(1), \dots, x_i(n)$, $i \in [1, N]$

Mientras no (criterio de parada)

- Seleccionar M individuos de x_i (mejores soluciones), donde $M < N$
- Construir el modelo probabilístico $p(x)$ basado en los M individuos
- Generar una nueva población mediante el muestreo de $p(x)$

Siguiente generación

Algoritmo 4.1: Esquema básico de un Algoritmo de Estimación de Distribución.

Cada EDA tiene su propio enfoque único para los tres pasos principales del Algoritmo 4.1 tanto para espacios de búsqueda discretos como continuos. Los diferentes enfoques se basan en responder algunas interrogantes: *i)* ¿cómo son los M individuos seleccionados de la población total de las soluciones candidatas N ?, *ii)* ¿qué modelo probabilístico se construye a partir de los M individuos seleccionados?, *iii)* ¿cómo se utilizan el modelo probabilístico para crear una nueva población para la próxima generación?. Las respuestas a estas preguntas dan lugar a diferentes tipos de EDAs.

Los modelos probabilísticos de n -dimensiones se utilizan para identificar y representar las interdependencias entre las n variables. Para modelar las interdependencias entre las n variables se utiliza los modelos probabilísticos.

4.2 Modelos probabilísticos

4.2.1 Distribución de probabilidad

A la distribución de probabilidad se la puede definir como una función que asigna a cada suceso definido sobre una variable aleatoria la probabilidad de que dicho suceso ocurra. La distribución de probabilidad está definida sobre el



conjunto de todos los sucesos, cada uno de los sucesos es el rango de valores de la variable aleatoria. Las distribuciones de probabilidad se dividen generalmente en dos clases: *i)* Distribución de probabilidad en el dominio discreto y *ii)* Distribución de probabilidad en el dominio continuo

4.3 Modelos probabilísticos en el dominio discreto

La distribución de una variable discreta es aquella cuya función de probabilidad sólo toma valores positivos en un conjunto de valores finitos o infinito numerable. A dicha función se le llama función de masa de probabilidad y es denotada como $p(X = x)$. Es decir, si X_i representa una variable aleatoria. Un posible valor de X_i es denotado como x_i , de tal forma que $p(X_i = x_i)$ representa la probabilidad que la variable X_i tome el valor de x_i .

Para los EDAS en el dominio discreto (dominio binario $[0,1]$), las poblaciones se generan a partir de distribuciones de probabilidad discretas del modelo probabilístico (vector de probabilidad), por ejemplo para un problema en el que la probabilidad de tener un bit 0 en la posición i -ésima de una solución candidata $x(i)$, es de 0,75, y la probabilidad de tener un bit 1 es de 0,25. Se puede generar una solución candidata para el bit $x(i)$ con la ecuación (4.1) [49]:

$$r \leftarrow U[0,1]$$
$$x(i) \leftarrow \begin{cases} 0 & \text{si } r < 0.75 \\ 1 & \text{si } r > 0.75 \end{cases} \quad (4.1)$$

Dónde:

r es un número aleatorio generado a partir de una distribución uniforme entre 0 y 1.



4.4 Modelo probabilístico en el dominio continuo

Los modelos probabilísticos en el dominio continuo son modelados mediante una función de densidad de probabilidad (PDF). Para cada EDAs una PDF es seleccionada y sus parámetros son estimados, y una nueva población se genera al muestrear esta PDF.

La distribución de probabilidad más simple y ampliamente utilizada es la distribución normal [49], [51], en donde solo es necesario conocer sus dos parámetros: la media o esperanza de la variable y la desviación estándar denotadas generalmente por μ y σ respectivamente. La densidad de probabilidad normal (PDF) viene dada por la ecuación 4.2:

$$f(x) = (1/\sigma\sqrt{2\pi})e^{-(x-\mu)^2/2\sigma^2} \quad (4.2)$$

La ecuación (4.2) determina la curva en forma de campana, conocida como Campana de Gauss (ver figura 4.2). Así, se dice que una variable x sigue una distribución normal de media μ y desviación estándar σ y se denota como $x(\mu, \sigma)$. La curva alcanza su mayor altura en torno a la media, mientras que sus "ramas" se extienden asintóticamente hacia los ejes; cuando una variable siga una distribución normal, es mucho más probable observar un dato cercano al valor medio que uno que se encuentre muy alejado de éste.

La forma de la campana de Gauss depende de los parámetros μ y σ . La media indica la posición de la campana, de modo que para diferentes valores de la gráfica es desplazada a lo largo del eje horizontal. Por otra parte, la desviación estándar determina el grado de apuntamiento de la curva. Cuanto mayor sea el valor de σ , más se dispersarán los datos en torno a la media y la curva será más plana. Un valor pequeño de este parámetro indica, por tanto, una gran probabilidad de obtener datos cercanos al valor medio de la distribución.




Figura 4.1: Grafica de la campana de Gauss.

Para todos los algoritmos (en el dominio continuo) en esta tesis los modelos probabilísticos son modelados por medio de una distribución normal, y la nueva población es obtenida por el muestreo aleatorio de la distribución normal.

4.5 Clasificación de los EDAs

Los EDAs se clasifican en función del orden de estadística:

1. "Estadísticas de primer orden"

Para problemas en el dominio binario

Algoritmo de Distribución Marginal Univariante (UMDA).

Algoritmo Genético Compacto (AGc).

Población Basada en Aprendizaje Incremental (PBIL).

Para problemas en el dominio continuo

Algoritmo de Distribución Marginal Univariante continuo (UMDAc).

Algoritmo Genético Compacto con valores reales (AGcr).

Población Basada en Aprendizaje Incremental continua (PBILc).

2. "Estadísticas de segundo orden"

Algoritmo de Distribución Marginal bivariante (BMDA).

Combinación de optimizadores con Árbol de Información Mutua (COMIT).

Inclusión Mutua de la Maximización de la información por Agrupamiento de Entrada (IMITAR).

3. "Estadísticas de orden superior"

Extensión del Algoritmo Genético Compacto (ECGA).

Todos los algoritmos de primer orden utilizan modelos probabilísticos simples que no tienen en cuenta las interacciones entre las variables. En otras palabras, se asume que las variables no tienen ninguna acción combinada (son variables independientes).

4.5.1 Algoritmo Genético Compacto (AGc) en el dominio binario

El Algoritmo Genético Compacto (AGc) es una técnica de búsqueda y optimización estocástica, desarrollada por Georges Harik, Fernando Lobo, y David Goldberg [52]. En el AGc la población se representa mediante un vector de probabilidad siempre considerando el dominio binario. Tal vector, en cada posición, especifica la probabilidad $p \in [0,1]$ de ocurrencia del valor "0" o "1", siendo su complemento $1 - p$ la ocurrencia del valor no tomado en cuenta. Para dar diversidad de búsqueda, las posiciones del vector de probabilidad se inicializan en 0.5, y a medida que el proceso de optimización avanza, las posiciones irán acercándose a un valor en particular ya sea "0" o "1". El objetivo del AGc es la de crear un vector de probabilidad que represente con alta probabilidad a los individuos con las mejores soluciones.

En el Algoritmo 4.2 muestra el pseudocódigo del AGc [49]. El AGc comienza inicializando un vector de probabilidad p de n elementos, con cada elemento inicializado en 0.5. El $p(i)$ es la probabilidad del bit de la i -ésima posición de un individuo. Después se generan aleatoriamente dos individuos x_1 y x_2 a partir de p . Posteriormente se determina cuál de los individuos es ganador y perdedor en base al valor de la función objetivo. Luego se re-ordena a los individuos de tal manera que $x_1 = \text{ganador}$ y $x_2 = \text{perdedor}$. Si $x_1(i) \neq x_2(i)$, el vector de probabilidad será actualizado en función del individuo ganador. Si el i -ésimo bit del individuo con



mejor solución es '1', entonces el i -ésimo componente del vector de probabilidades p será incrementado en una constante α . Si el i -ésimo bit del individuo con mejor solución es '0', entonces el i -ésimo componente del vector de probabilidades p será restado en una constante α . Cuando $x_1 = x_2$ el vector de probabilidad no será actualizado. Posteriormente se crea una nueva población muestreando los datos actualizados del vector de probabilidades p a partir de una distribución uniforme (ecuación 4.1).

La variable $\alpha(0,1)$ gobierna la velocidad de convergencia del algoritmo. Si el valor α es cercano a 1 el vector de probabilidad converge en pocas iteraciones y el valor obtenido puede ser muy alejado del óptimo (solución pobre) por el contrario si el valor α es muy pequeño el vector de probabilidad converge muy lentamente, pero con soluciones potencialmente cercanas al valor óptimo.

El siguiente ejemplo muestra la operación básica del AGc, al considerar un problema de minimización en el dominio binario, con un tamaño de 4 bits, $\alpha = 0.15$. Considerando una población inicial de $x_1 = [1\ 1\ 0\ 1]$ y $x_2 = [0\ 1\ 1\ 0]$. Ya que el vector de probabilidad es inicialmente $p = [0.5\ 0.5\ 0.5\ 0.5]$, se procede a medir el valor de la función objetivo de los dos individuos, siendo el que presenta menor valor $x_2 = 2$ ya que $x_1 = 3$. Entonces se procede a actualizar el vector de probabilidad en base a x_2 . El primer bit del individuo x_2 es 0, por lo tanto el primer bit del vector de probabilidad se reduce en 0.25. El segundo bit en ambos individuos es el mismo así que el segundo bit del vector de probabilidad no sufre cambios, El tercer bit del individuo x_2 es 1, por lo tanto el primer bit del vector de probabilidad se incrementa en 0.25, y el cuarto bit se procede de la misma forma que el primer bit. Una vez actualizado el vector de probabilidad $p = [0.35\ 0.5\ 0.65\ 0.35]$ se procede a generar la siguiente generación. La Figura 4.2 muestra la forma de actualizar el vector de probabilidad en el AGc.

Inicializar el vector de probabilidad $\mathbf{p}(x) = [0.5, \dots 0.5]$

Establecer \mathbf{p}_{min} y \mathbf{p}_{max} (mínimo y máximo valor para cada elemento de \mathbf{p})

Establecer α (tasa de incremento del vector de probabilidad)

Mientras no (criterio de parada)

Muestrear \mathbf{p} para obtener **2** individuos

Evaluar los **2** individuos, y reordenar de tal forma de obtener:

$x_{mejor} \leftarrow \text{el mejor valor}$

$x_{peor} \leftarrow \text{el peor valor}$

Actualizar el vector de probabilidades $\mathbf{p}(x)$

Para $k = 1$ hasta n (número de bits en cada solución candidata)

Si $x_{mejor}(k) \neq x_{peor}(k)$ entonces

Si $x_{mejor}(k) = 1$ entonces

$\mathbf{p}(k) \leftarrow \mathbf{p}(k) + \alpha$

Caso contrario

$\mathbf{p}(k) \leftarrow \mathbf{p}(k) - \alpha$

Fin si

Fin si

Verificar si el vector de probabilidad ha convergido

$\mathbf{p}(k) \leftarrow \max(\min(\mathbf{p}(k), \mathbf{p}_{max}), \mathbf{p}_{min})$

Siguiente generación

Algoritmo 4.2: Algoritmo Genético Compacto para la optimización de n bits en el dominio binario.

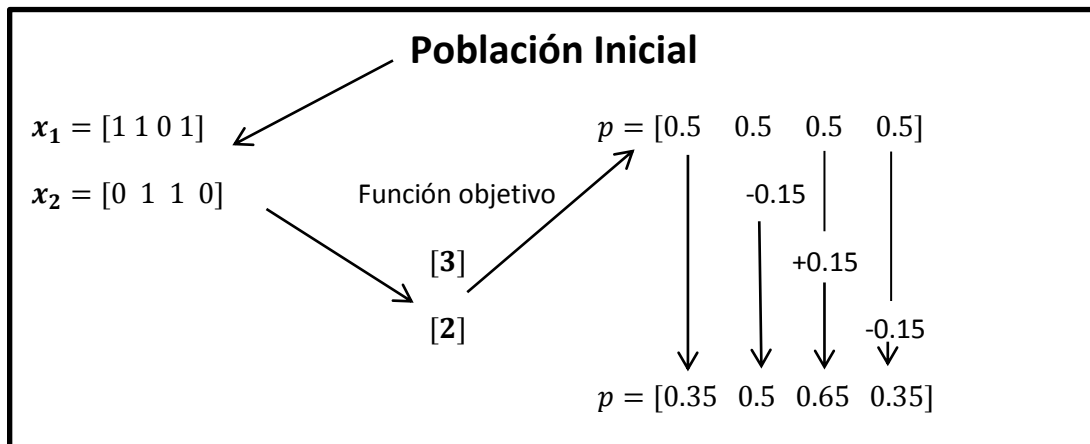


Figura 4.2: Actualización del vector de probabilidades en el AGc (dominio binario).

Existen modificaciones en el AGc con el fin de optimizar la eficiencia de búsqueda, por ello, se ha propuesto incluir nuevas características al algoritmo clásico, por ejemplo, la introducción de elitismo (AGcE) y una versión generalizada del AGc [49].

La primera modificación del AGc es la incorporación de elitismo. El elitismo consiste en mantener el mejor individuo de la generación anterior para la siguiente generación, es decir, el mejor individuo de la generación anterior es incluido con los dos nuevos individuos de la nueva generación, y el individuo con mejor solución de los tres es utilizado para actualizar el vector de probabilidad p . La segunda modificación del AGc es que en cada generación se genere una población de $N \geq 2$ individuos [42]. El AGc no presenta ninguna restricción para que en cada iteración el algoritmo genere más de dos individuos, por lo que existe una versión generalizada del algoritmo genético compacto donde en cada generación en lugar de generar dos individuos se genera un número mayor de individuos, entonces la actualización del vector de probabilidad se da mediante la comparación del mejor individuo con el peor individuo de cada generación. En el Algoritmo 4.3 se presenta la versión generalizada del AGc.



Inicializar los n elementos del vector de probabilidad $\mathbf{p}(x) = [0.5, \dots 0.5]$

Establecer: \mathbf{p}_{min} y \mathbf{p}_{max} (mín. y máx. valor para cada elemento de \mathbf{p})

Establecer: α (tasa de incremento del vector de probabilidad)

Establecer: N (tamaño de población)

Establecer un individuo elite $x_e \rightarrow \mathbf{0}$

Mientras no (criterio de parada)

Muestrear \mathbf{p} para obtener N individuos

Evaluar los N individuos, y obtener:

$x_{mejor} \leftarrow$ *el mejor valor de* $\{x_1, x_2, \dots, x_N, x_e\}$

$x_{peor} \leftarrow$ *el peor valor* $\{x_1, x_2, \dots, x_N, x_e\}$

Actualizar el vector de probabilidades $\mathbf{p}(x)$

Para $k = 1$ hasta n (número de bits en cada solución candidata)

Si $x_{mejor}(k) \neq x_{peor}(k)$ entonces

Si $x_{mejor}(k) = 1$ entonces

$\mathbf{p}(k) \leftarrow \mathbf{p}(k) + \alpha$

Caso contrario

$\mathbf{p}(k) \leftarrow \mathbf{p}(k) - \alpha$

Fin si

Fin si

Verificar si el vector de probabilidad ha convergido

$\mathbf{p}(k) \leftarrow \max(\min(\mathbf{p}(k), \mathbf{p}_{max}), \mathbf{p}_{min})$

Fin para

$X_e \leftarrow X_{mejor}$

Siguiente generación

Algoritmo 4.3: Versión generalizada del AGc con elitismo.



4.6 EDAs de primer orden en el dominio continuo

4.6.1 Algoritmo genético compacto en el dominio continuo (AGcr)

En el AGc, la evolución de las poblaciones se modela mediante el procesamiento de un vector de probabilidad con las normas de actualización especificadas en el AGc clásico (codificación binaria) [42]. En [53], se propone una nueva variante del AGc para dominio continuo, de tal manera de superar los problemas relacionados con los esquemas de codificación binaria.

Al considerar un problema de minimización de n dimensiones; sin pérdida de generalidad del AGc clásico, los parámetros se normalizan en un intervalo determinado de búsqueda, por ejemplo $[-1, 1]$. En el AGc la estimación de distribución de un individuo (en binario) se puede especificar con un escalar en $[0, 1]$ que expresa la probabilidad de encontrar un "0" o un "1" en un bit (ecuación (4.1)). Por el contrario, el AGcr utiliza individuos con valores reales. La distribución de un individuo debe ser definida por una función de distribución de probabilidad (PDF) definida en el intervalo indicado. La distribución de probabilidad del i -ésimo individuo se puede describir como una PDF normal con media $\mu(i)$ y desviación estándar $\sigma(i)$.

Por lo tanto, el vector de probabilidad p para el AGcr a diferencia del AGc en el dominio binario es una matriz de $n \times 2$ que especifica los dos parámetros de la PDF de cada individuo, definida por la ecuación (4.3):

$$p^k = [u^k \ \sigma^k] \quad (4.3)$$

Dónde:

$u^k = [u_1^k \ u_2^k \ \dots \ u_n^k]$: es la media

$\sigma^k = [\sigma_1^k \ \sigma_2^k \ \dots \ \sigma_n^k]$: es la desviación estándar

k : es la iteración



Al igual que el AGc clásico al AGcr se puede incorporar elitismo, que consiste en mantener el mejor individuo de la generación anterior para la siguiente generación, es decir, el mejor individuo de la generación anterior es incluido con los dos nuevos individuos de la nueva generación, y el mejor de los tres es utilizado para actualizar el vector de probabilidad p . También al AGcr en cada generación se puede generar una población de $N \geq 2$ individuos, esto basado en el AGc clásico [49] (ver Algoritmo 4.4).

Las diferencias principales del AGcr y el AGc clásico (dominio binario) residen básicamente en la creación de la población inicial y la segunda en la actualización del vector de probabilidad. La población inicial en el AGcr es generada mediante un muestreo de la distribución de probabilidad con la media $\mu^1 = 0$ y desviación estándar $\sigma(i)^1$ establecida dentro de un intervalo, mientras que en el AGc clásico la población inicial es generada a través del muestreo del vector de probabilidad a partir de una distribución uniforme (ecuación 4.1).

La regla de actualización está diseñada con el fin de asimilar las operaciones del AGc clásico. Se evalúa cada individuo, posteriormente se determina cuál de los individuos es ganador y perdedor en función del valor de la función objetivo (la mejor y peor solución respectivamente). Luego se re-ordena a los individuos de tal manera que $x_1 = \text{ganador}$ y $x_2 = \text{perdedor}$, y aquí surge la otra diferencia, ya que en el AGcr el vector de probabilidad se actualiza mediante las ecuaciones (4.4) y (4.6) [49]. La regla de actualización de la media tiende a seguir la dirección del individuo ganador con pasos que depende del factor α , es decir que para la siguiente generación es más probable observar individuos cercanos a la media actualizada. La regla de actualización de la desviación estándar particularmente conveniente para la aplicación del algoritmo se puede obtener directamente con manipulaciones matemáticas simples [53].

$$\mu_i^{k+1} = \mu_i^k + \alpha * (x_{mejor} - x_{peor}) \quad (4.4)$$



$$[\sigma_j^{k+1}]^2 = \max(0, v_i^k) \quad (4.5)$$

$$[v_i^k]^2 = [\sigma_i^k]^2 + [\mu_i^k]^2 - [\mu_i^{k+1}]^2 + \alpha * ([x_{mejor}]^2 - [x_{peor}]^2) \quad (4.6)$$

Establecer: α (tasa de incremento del vector de probabilidad)

Establecer: N (tamaño de población)

Establecer la desviación estándar inicial: σ^1

Establecer: la media $\mu^1 = \mathbf{0}$

Mientras no (criterio de parada)

Generar N individuos desde $p = [\mu^k \ \sigma^k]$

Evaluar los N individuos, y obtener:

$x_{mejor} \leftarrow$ *el mejor valor de* $\{x_1, x_2, \dots, x_N\}$

$x_{peor} \leftarrow$ *el peor valor* $\{x_1, x_2, \dots, x_N\}$

Actualizar el vector de probabilidades p

$$\mu_i^{k+1} = \mu_i^k + \alpha * (x_{mejor} - x_{peor})$$

$$[\sigma_j^{k+1}]^2 = \max(0, v_i^k)$$

$$[v_i^k]^2 = [\sigma_i^k]^2 + [\mu_i^k]^2 - [\mu_i^{k+1}]^2 + \alpha * ([x_{mejor}]^2 - [x_{peor}]^2)$$

Siguiente generación

Algoritmo 4.4: Algoritmo Genético Compacto para el dominio continuo.

La variable $\alpha(0,1)$ al igual que en AGc clásico (dominio binario) gobierna la velocidad de convergencia del algoritmo. Si el valor α es cercano a 1 el vector de probabilidad converge en pocas iteraciones y el valor obtenido es muy alejado



del óptimo (solución pobre) por el contrario si el valor α es muy pequeño el vector de probabilidad converge muy lentamente, pero con soluciones potencialmente factibles.

4.6.2 Algoritmo de Aprendizaje Incremental Basado en Poblaciones para dominio continuo (PBILc)

El PBILc es también llamado ascenso de colina estocástico con aprendizaje por medio del vector de distribución normal (*stochastic hill climbing with learning by vectors of normal distributions*). El PBILc es una adaptación del algoritmo PBIL (en dominio binario) al dominio continuo [49], [54]. El PBILc crea un vector de probabilidad del que se obtiene individuos representativos en cada generación para producir la población que constituye la siguiente generación. El vector de probabilidad representa en cada posición la probabilidad de contener un valor específico (individuo).

Es decir, el objetivo del PBILc es la de generar y actualizar un vector de probabilidades que represente con alta probabilidad a una población con las mejores soluciones. La actualización del vector de probabilidades permite desplazarse gradualmente hacia las zonas más prometedoras del espacio de búsqueda en función de una regla de actualización. Esa regla toma en consideración dos parámetros: el primero, a aquellos individuos mejores soluciones, y segundo un parámetro llamado tasa o velocidad de aprendizaje.

4.6.3 Enfoque 1 del PBILc_1

El primer punto de vista del algoritmo PBILc, llamado PBILc_1, está representado por un vector de probabilidades p representado por la media μ de la distribución normal. En cada generación el vector de probabilidades se ajusta de acuerdo con las reglas de actualización indicadas en la ecuación (4.7) y (4.8).

$$p(i) = p_{anterior} + \eta(x_{i(mejor)} - p_{anterior}) \quad (4.7)$$



$$p(i) = p_{anterior} - \eta(x_{i(peor)} - p_{anterior}) \quad (4.8)$$

Dónde:

$p_{anterior}$: Vector de probabilidad de la iteración anterior.

$x_{i(mejor)}$: Individuo con mejor solución.

$x_{i(peor)}$: Individuo con peor solución.

$0 \leq \eta \leq 1$: Representa la tasa de aprendizaje. Este valor influye en la velocidad de convergencia del algoritmo. Un pequeño valor corresponde a un proceso de optimización lento y mayor exploración del espacio de búsqueda; por el contrario, un valor cercano a 1 corresponde a un proceso de optimización rápido (rápida convergencia del vector de probabilidades).

Para dar diversidad de búsqueda, al inicio del proceso de optimización se plantea un valor elevado de la desviación estándar, y a medida que avanza el proceso de optimización tal valor se irá reduciendo haciendo que la zona de búsqueda sea alrededor de un valor particular, mientras que el vector de probabilidades (la media μ) es desplazado gradualmente hacia la representación de aquellos individuos con mejores soluciones. Para ello se debe usar una regla de actualización del vector de probabilidades de acuerdo a las ecuaciones (4.7) y (4.8).

La idea de la diversidad de búsqueda se ilustra en la Figura 4.3, donde al inicio para obtener la mayor diversidad de individuos y explorar todas las zonas de búsqueda la desviación estándar se establece en valores altos, es decir, la campana de gauss será más plana y los valores aleatorios presentarán mayor dispersión, y a medida que el proceso de optimización evoluciona el vector de probabilidad (la media μ) se ajusta hacia el valor mínimo o máximo (dependiendo

del problema a optimizar), y ya no se requiere elevada diversidad de búsqueda, ya que se requiere que se explore alrededor de las mejores soluciones actuales, por lo que la desviación estándar debe disminuir en un parámetro α a medida que las avanzan las iteraciones.

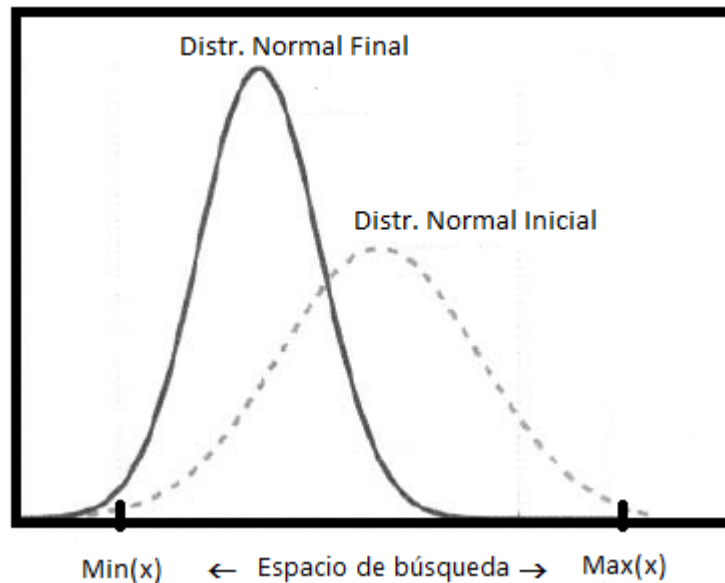


Figura 4.3: Ilustración de la distribución normal al iniciar y al finalizar la optimización con el PBILc_1.

La ecuación (4.7) asegura que para la siguiente generación el vector de probabilidades (la media) tenderá a ser más parecida a los individuos con mejores soluciones. Mientras que la ecuación (4.8) ajusta el vector de probabilidad, de modo que las generaciones posteriores serán menos propensas a ser similares a los individuos con peores soluciones.

El Algoritmo 4.5 muestra el pseudocódigo del PBILc_1. Al considerar una función $f(x)$ donde cada variable independiente $x_i(k)$ de una solución candidata x_i está limitada sobre un dominio definido (ecuación (4.9)):

$$x_i(k) \in [x_{min}(k), x_{max}(k)] \quad (4.9)$$



Establecer: N (tamaño de población)

N_{mejor} : Número de los mejores individuos para actualizar el vector \mathbf{p}

N_{peor} : Número de los peores individuos para actualizar el vector \mathbf{p}

$[x_{min}, x_{max}]$: Dominio del k -ésimo elemento espacio de búsqueda, $k \in [1, n]$

η : Velocidad de aprendizaje

α : Factor de disminución de la desviación estándar

σ_k : Desviación estándar inicial $k \in [1, n]$

Inicializar el vector de probabilidad $\mathbf{p}(x) \leftarrow U[x_{min}(k), x_{max}(k)]$ (PDF)

Mientras no (criterio de parada)

Use \mathbf{p} para generar aleatoriamente N soluciones candidatas:

$$x_i(k) \leftarrow p_k + N(0, \sigma_k)$$

Evaluar los N individuos, y reordenar de tal forma de obtener:

$$f(x_1) \leq f(x_2) \leq \dots \leq f(x_N)$$

Actualizar el vector de probabilidades $\mathbf{p}(x)$

Para $i \in [1, N_{mejor}]$

$$\mathbf{p} \leftarrow \mathbf{p} + \eta(x_i - \mathbf{p})$$

Siguiente i

Fin para

Para $i \in [N - N_{peor}, N]$

$$\mathbf{p} \leftarrow \mathbf{p} - \eta(x_i - \mathbf{p})$$

Siguiente i

Fin para

Algoritmo de mutación de \mathbf{p}

Aplicar el factor de disminución de la desviación estándar (ver Figura 4.3)

Siguiente generación

Algoritmo 4.5: Algoritmo PBILc_1 para el dominio continuo.

Para $i \in [1, N]$ y $k \in [1, n]$, donde N es el tamaño de la población y n es la dimensión del problema; inicialmente se genera un vector de probabilidad \mathbf{p} tal que

$p_k \in [x_{min}(k), x_{max}(k)]$ para $k \in [1, n]$ que represente el valor de la media μ inicial en la PDF, la desviación estándar inicial σ se establece en valores altos para estimular la exploración de todo el espacio de búsqueda. Para crear la población de soluciones candidatas $x_i(k)$ se generan N individuos mediante el muestreo de las distribuciones normal. Posteriormente se evalúa el valor de la función objetivo de cada solución y se seleccionan a N_{mejor} individuos con las mejores soluciones, posteriormente se actualiza el vector de probabilidad por medio de la ecuación (4.7), después se seleccionan a N_{peor} individuos con las peores soluciones, seguidamente se vuelve actualizar el vector de probabilidad por medio de la ecuación (4.8).

A medida que aumenta el número de generaciones, el vector de probabilidad p converge hacia la solución óptima ajustado por las reglas de aprendizaje (ecuaciones (4.7) y (4.8)); mientras que la desviación estándar de la PDF disminuye a medida que aumenta el número de generaciones (ver Figura 4.3).

4.6.4 Enfoque 2 del PBILc_2

El segundo punto de vista del algoritmo PBILc, llamado PBILc_2, constituye un vector de probabilidades representado por $p [2xm]$ (m es la dimensión del problema), donde la columna 1 representa la media μ y la columna dos representa la desviación estándar σ . Al inicio del proceso de optimización se plantea un valor inicial del vector de probabilidades con la media μ dentro de un dominio predefinido y una desviación estándar inicial σ^1 (para tener diversidad de búsqueda). En cada iteración k , la primera columna del vector de probabilidades (la media) será actualizada en base a la regla de actualización indicada en la ecuación (4.10).

$$p_{1i}^k = (1 - \eta)p_{1i}^{k-1} + \eta(P(i, 1) + P(i, 2) - P(i, N)) \quad (4.10)$$

Donde:

$P(i, 1)$ Representa el mejor individuo

$P(i, 2)$ Representa el segundo mejor individuo

$P(i, N)$ Representa el peor individuo de la actual población.

La regla de actualización de la segunda columna del vector de probabilidades (desviación estándar) está indicada en la ecuación (4.11).

$$p_{2j}^k = (1 - \eta) p_{2j}^{k-1} + \eta \sqrt{\sum_{j=1}^{N_{mejor}} \frac{(P(i, j) - \mu_{mejor})^2}{N_{mejor}}} \quad (4.11)$$

Donde:

μ_{mejor} : Representa la media de los N_{mejor} mejores individuos en la actual población.

$0 \leq \eta \leq 1$: Representa la tasa de aprendizaje. Este valor influye en la velocidad de convergencia del algoritmo. Un pequeño valor corresponde a un proceso de optimización lento y mayor exploración del espacio de búsqueda; por el contrario, un valor cercano a 1 corresponde a un proceso de optimización rápido (rápida convergencia del vector de probabilidades).

La ecuación (4.11) ajusta el vector de probabilidad (la desviación estándar), de modo que el parámetro que controla la diversidad de búsqueda (la desviación estándar) dependerá de un cierto número de individuos (N_{mejor}) con mejores soluciones en cada generación. Este valor también influye en la velocidad de convergencia del algoritmo, ya que si los N_{mejor} individuos en la ecuación (4.11) es muy pequeño, el problema puede converger prematuramente debido a que para las siguientes generaciones no se tendrá diversidad de individuos, por el contrario, si los N_{mejor} es un valor elevado este puede hacer al proceso de

optimización lento, debido a que se tiene una diversidad de individuos que hacen que las zona explorada sea muy amplia (ver Figura 4.3).

El Algoritmo 4.6 muestra el pseudocódigo del PBILc_2. Al considerar una función $f(x)$ donde cada variable independiente $x_i(k)$ de una solución candidata x_i está limitada sobre un dominio definido (ecuación (4.9)).

Establecer: N (tamaño de población)

N_{mejor} : Número de los mejores individuos para actualizar el vector \mathbf{p}

$[x_{min}, x_{max}]$: Dominio del k -ésimo elemento espacio de búsqueda, $\mathbf{k} \in [1, \mathbf{n}]$

η : Velocidad de aprendizaje

$\sigma(\mathbf{k})$: Desviación estándar inicial $\mathbf{k} \in [1, \mathbf{n}]$

Inicializar la media del vector de probabilidad $\mu(\mathbf{k}) \leftarrow U[x_{min}(\mathbf{k}), x_{max}(\mathbf{k})]$ (PDF)

Vector de probabilidad $\mathbf{p}(\mathbf{k}) \leftarrow (\mu(\mathbf{k}), \sigma(\mathbf{k}))$

Mientras no (criterio de parada)

Use \mathbf{p} para generar aleatoriamente N soluciones candidatas:

$$x_i(\mathbf{k}) \leftarrow N(\mu(\mathbf{k}), \sigma(\mathbf{k}))$$

Evaluar los N individuos, y reordenar de tal forma de obtener:

$$\mathbf{P} = f(x_1) \leq f(x_2) \leq \dots \leq f(x_N)$$

Actualizar el vector de probabilidades $p(x)$

Para $i \in [1, \mathbf{n}]$

$$p_{1i}^k \leftarrow (1 - \eta)p_{1i}^{k-1} + \eta(P(i, 1) + P(i, 2) - P(i, N))$$

Para $i \in [1: N_{mejor}]$

Para $j \in [1, \mathbf{n}]$

$$p_{2j}^k = (1 - \eta)p_{2j}^{k-1} + \eta \sqrt{\frac{\sum_{j=1}^{N_{mejor}} (P(i,j) - \mu_{mejor})^2}{N_{mejor}}}$$

Fin para

Algoritmo de mutación a $\mathbf{p}(\mu(\mathbf{k}))$

Siguiente generación

Algoritmo 4.6: Algoritmo PBILc_2 para el dominio continuo.

4.6.5 Incorporación de mutación al PBILc

Para aumentar la velocidad de convergencia del PBILc (PBILc_1 y PBILc_2) se le puede incorporar mutación, pero a diferencia de los EAs los cuales realizar la mutación sobre cada individuo de la población o sobre ciertos individuos, en el algoritmo PBILc la mutación se realiza sobre el vector de probabilidades. Para la mutación, se establece una determinada probabilidad de mutación. Cada valor del vector de probabilidad será mutado siempre que se supere ese valor de probabilidad. En caso de que así ocurra, se realizará un desplazamiento aleatorio en un sentido u otro, dicho desplazamiento estará basado en función de valores previamente establecidos al inicio del algoritmo. La regla de mutación se muestra en el Algoritmo 4.7.

```
Establecer:  $p$  (vector de probabilidades)
Establecer:  $p_m$  (probabilidad de mutación)
Establecer:  $MS$  (desplazamiento de mutación)

Para  $i = 1$  hasta  $n$  ( $n$  cada elemento del vector de probabilidades)
    Si  $\text{aleatorio}[0, 1] < p_m$  entonces
        
$$p(i) = p(i) * (1 - MS) + \text{rand} * MS$$

    Fin si
Fin para
```

Algoritmo 4.7: Mutación aplicada al algoritmo PBILc.

4.7 Implementación del algoritmo de solución del PET para el dominio binario

4.7.1 Codificación de un individuo en el dominio binario

Las variables codificadas representan el número de nuevos circuitos añadidos en cada rama (x_{ij}), en un rango desde 0 hasta x_{ij}^{max} . La codificación



utilizada es el código binario reflejado (código Gray) para representar a cada individuo (ver Tabla 4.1).

Tabla 4.1: Sistema binario (Gray)

Decimal	Gray
0	000
1	001
2	011
3	010
4	110
5	111
6	101
7	100

La codificación binaria se utiliza para actualizar el vector de probabilidad mientras que el sistema entero se usa para evaluar la función objetivo. En la Tabla 4.2 se muestra un ejemplo de la estructura de un individuo de dimensión 7, correspondientes a una red con 7 ramas candidatas para añadir nuevos circuitos.

Tabla 4.2: Individuo representado en sistema entero y binario.

Nodos	Decimal	Gray
n_{12}	0	000
n_{14}	1	001
n_{15}	2	011
n_{23}	3	010
n_{24}	4	110
n_{26}	5	111
n_{35}	6	101

4.7.2 Implementación del PET usando el AGc

A continuación, se explica los pasos a seguir para resolver el problema del PET por medio del AGc.



- 1 Seleccionar el sistema a analizar.** Se cargan los datos del modelo de prueba. En esta tesis se utilizarán los modelos de Garver de 6 nodos y el IEEE de 24 nodos, con y sin redespacho.
- 2 Parámetros generales.** Son parámetros que tienen que ver con la convergencia del algoritmo y la meta-heurística seleccionada. Estos parámetros son: tamaño de la población (es un parámetro ajustable, el cual permanece constante durante la ejecución del algoritmo), número máximo de iteraciones, número de veces que se quiere repetir la prueba, número máximo de circuitos permitidos por cada derecho de transmisión en la red, topología base con la que comienza el problema y el método de solución meta-heurístico usado para resolver el problema del PET (En este caso el AGc).
- 3 Inicializar los parámetros del AGc.** Inicializar el vector de probabilidad ($p = [0.5 \dots 0.5]$). Inicializar p_{min} y p_{max} que es el mínimo y máximo valor del vector de probabilidad. Inicializar el valor de α ($0 \leq \alpha \leq 1$) que es la variable que se utiliza para actualizar el vector de probabilidad p en cada iteración. No existe un procedimiento formal para seleccionar el valor α . En esta tesis, se utilizará un proceso de ensayo y error para seleccionar el valor de α que mejores resultados proporcione. Los parámetros que han dado los mejores resultados para los procesos de convergencia son los siguientes: $\alpha = 0.02$, $p_{min} = 0.005$ $p_{max} = 0.095$. Los valores de p_{min} , p_{max} en este caso no se consideraron cero y uno respectivamente, esto debido a que si el vector de probabilidad converge en un mínimo local, este trate de encontrar otras soluciones en el espacio de búsqueda.
- 4 Creación inicial de la población de soluciones.** Con los parámetros establecidos en 2, la población de soluciones iniciales consistirá en una matriz $[m \times n]$, con n igual a la cantidad de individuos en la población y m

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, es decir, los valores de cada elemento de la matriz indicada corresponden a la cantidad de caminos o circuitos por cada derecho de transmisión que conecta dos barras. Tales valores están restringidos de tal forma que no superen el límite máximo de circuitos por derechos de transmisión x_{min} , ni sean inferiores a la topología inicial del sistema en estudio x_{max} .

Establecer x_{min} y x_{max}

Establecer la población inicial $x_{ij} = x_{ij}^{min}$

Establecer $\beta = 10\%$ o $\beta = 25\%$ y calcular $b = \text{int}((\frac{\beta}{100})m)$

Para $i = 1$ hasta N (N es tamaño de población)

 Crear j_{rand_i}

 Crear la población de soluciones iniciales de acuerdo con:

$$x_{i j_{rand_i}} = \text{round}[x_{i j_{rand_i}}^{min} - x_{i j_{rand_i}}^{max}] * \text{rand}$$

 / rand : Es un valor aleatorio distribuido uniformemente entre $[0,1]$

Fin para

Algoritmo 4.8: Creación de la Población de Soluciones Iniciales.

La población inicial se crea de forma aleatoria, usando para ello una distribución uniforme y basada en el supuesto de que en una red eléctrica se agregará al menos un circuito con solo el 10-30% de los derechos de transmisión disponibles [12], esto permitirá que el algoritmo inicie en regiones cercanas al valor óptimo, lo cual puede acelerar el proceso de optimización. El Algoritmo 4.7 presenta la generación de la población inicial basado en el supuesto anterior, donde β representa el porcentaje (entre 10-30% de total disponible de derecho de transmisión candidatos) de derechos



de transmisión para añadir uno o más circuitos. El valor de β depende del sistema de prueba en estudio, es decir, para sistemas pequeños y medianos $\beta = 10\%$, y para sistemas grandes $\beta = 25\%$, posteriormente se calcula $b = \text{int}((\frac{\beta}{100})m)$; entonces se genera un conjunto índices $jrand$ de dimensión b , donde $jrand \subset [1, 2, \dots, m]$ y cada componente de $jrand$ se elige aleatoriamente.

- 5 Evaluación inicial de costos.** Una vez creada la población inicial, el algoritmo evalúa la calidad de todos los individuos mediante la función objetivo. El valor de la función objetivo ha de ser un número real positivo. Este valor mide la calidad de la solución representada por cada individuo de la población, de forma que cuanto mejor es la solución, menor será el valor de la función objetivo. El objetivo del algoritmo es la minimización de esa función.

La función objetivo del problema de planificación (correspondiente a la parte del problema principal de expansión) consiste en minimizar ya sea el costo de inversión y el costo de penalización asociada al corte de carga (3.32) o el costo de inversión, el costo de penalización asociada al corte de carga y el costo asociado a pérdidas (3.50). La evaluación de cada individuo se realiza calculando en primer lugar los costos de inversión, después el costo de penalización asociada al corte de carga y finalmente el costo asociado a las pérdidas. A partir de los valores anteriores se calcula el valor de la función objetivo.

- 6 Evaluación del criterio de parada.** El criterio de parada considerado es el número máximo de iteraciones, el cual limita también el número de evaluaciones de la función objetivo. Hasta que no se cumpla el criterio de parada hacer:



- **Evaluación de costos:** Este componente se utiliza para realizar la evaluación de la función objetivo, donde cada individuo (topología) es evaluado para determinar su costo en función de los siguientes puntos:
 - Se calculan los parámetros de línea equivalentes para cada rama debido a la incorporación de circuitos en cada derecho de transmisión.
 - 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).
 - 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 más los costos asociados a pérdidas (si se incluye costos de pérdidas al problema de optimización) para la configuración óptima de despacho resultante del flujo óptimo de potencia AC. En este cálculo, a las soluciones no factibles, es decir, que no hayan satisfecho los criterios técnicos se penalizan (se colocan costos sumamente altos), mediante la incorporación de generadores ficticios. Sus costos de generación de potencia activa y reactiva están incluidos en los datos de los modelos de red, y por medio de estos se puede estudiar diferentes casos.
- **Elitismo:** El mejor individuo de la población anterior se inserta en la población actual.
- **Selección:** Seleccionar de la población actual (incluido elitismo) como x_1 al individuo que proporcione la mejor solución (menor costo de la función objetivo) y x_2 sea la peor solución (la de mayor costo de la función objetivo).



- **Actualizar el vector de probabilidad p :** El vector de probabilidad será actualizado en función del individuo ganador x_1 (el individuo codificado en binario), de la siguiente manera. Si el i -ésimo bit del individuo con mejor solución es 1, entonces el i -ésimo componente del vector de probabilidades p será incrementado en una constante α . Si el i -ésimo bit del individuo con mejor solución es 0, entonces el i -ésimo componente del vector de probabilidades p será restado de una constante α . Cuando $x_1 = x_2$ el vector de probabilidad no será actualizado.
- **Verificar si el Vector p ha convergido:** Verificar que cada elemento del vector de probabilidades no supere la p_{max} ni sea inferior a p_{min} . Si el valor $p > p_{max}$ o $p < p_{min}$, el valor del elemento de p es establecido en p_{max} o p_{min} respectivamente.
- **Generación de una nueva población:** Muestrear el vector de probabilidad para generar una nueva población a partir de una distribución uniforme entre $[0,1]$ (ver ecuación 4.1). Posteriormente convertir de binario a enteros los individuos generados.
- **Verificar los individuos:** Verificar que los individuos de la población generada no superen el valor máximo ni el mínimo permitido por derecho de transmisión.

En la Figura 4.4 se muestra el diagrama de flujo que sintetiza el proceso anteriormente descrito.




Figura 4.4: Diagrama de flujo Algoritmo Genético Compacto.



4.8 Implementación del algoritmo de solución del PET para el dominio continuo

4.8.1 Codificación de un individuo en el dominio continuo

Las variables codificadas son el número de nuevos circuitos añadidos en cada rama x_{ij} . La codificación se realiza utilizando números enteros con un rango entre 0 hasta x_{max} .

4.8.2 Implementación del PET usando el AGcr

El AGcr es una modificación del AGc clásico para resolver problemas en el dominio continuo. El objetivo de este algoritmo es superar los problemas relacionados con los esquemas de codificación binaria. A continuación, se explica los pasos para resolver el problema del PET por medio del AGcr.

- 1 Seleccionar el sistema a analizar.** Se cargan los datos del modelo de prueba. En esta tesis se utilizarán los modelos de Garver de 6 nodos y el IEEE de 24 nodos, con y sin redespacho.
- 2 Parámetros generales.** Son parámetros que tienen que ver con la convergencia del algoritmo y la meta-heurística seleccionada. Estos parámetros son: tamaño de la población (es un parámetro ajustable, el cual permanece constante durante la ejecución del algoritmo), número máximo de iteraciones, número de veces que se quiere repetir la prueba, número máximo de circuitos permitidos por cada derecho de transmisión en la red, topología base con la que comienza el problema y el método de solución meta-heurístico usado para resolver el problema del PET (En este caso el Algoritmo AGcr).
- 3 Inicializar los parámetros del AGcr.** Inicializar el vector de probabilidad, el cual corresponde a una matriz de $n \times 2$ donde n corresponde a la dimensión

del problema, la primera columna corresponde a la media μ^1 inicial, y la segunda columna corresponde a la desviación estándar σ^1 inicial. Inicializar el valor de α ($0 \leq \alpha \leq 1$) que es la variable que se utiliza para actualizar el vector de probabilidad p en cada iteración. No existe un procedimiento formal para seleccionar el valor α . En esta tesis, se utilizará un proceso de ensayo y error para seleccionar el valor de α que mejores resultados proporcione. Los parámetros que han dado los mejores resultados para los procesos de convergencia son los siguientes $\alpha=0.02$, $\mu^1=0$, $\sigma^1=4.5$ (Este valor de desviación estándar cubre todas las posibles soluciones al momento de realizar el muestreo con una distribución normal aleatoria con media cero).

4 Creación inicial de la población de soluciones. Con los parámetros establecidos en 2, la población inicial se crea de forma aleatoria, 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 transmisión. La población de soluciones iniciales consistirá en una matriz $m \times n$, con n igual a la cantidad de individuos de la población de soluciones y m 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 transmisión que conecta dos barras (ver Algoritmo 4.8).

5 Evaluación inicial de costos. Una vez creada la población inicial, el algoritmo evalúa la calidad de todos los individuos mediante la función objetivo. El valor de la función objetivo ha de ser un número real positivo. Este valor mide la calidad de la solución representada por cada individuo de



la población, de forma que cuanto mejor es la solución, menor será el valor de la función objetivo. El objetivo del algoritmo es la minimización de esa función.

La función objetivo del problema de planificación (correspondiente a la parte del problema principal de expansión) consiste en minimizar ya sea el costo de inversión y el costo de penalización asociada al corte de carga (3.32) o el costo de inversión, el costo de penalización asociada al corte de carga y el costo asociado a pérdidas (3.50). La evaluación de cada individuo se realiza calculando en primer lugar los costos de inversión, después el costo de penalización asociada al corte de carga y finalmente el costo asociado a las pérdidas. A partir de los valores anteriores se calcula el valor de la función objetivo.

6 Evaluación del criterio de parada. El criterio de parada considerado es el número máximo de iteraciones, el cual limita también el número de evaluaciones de la función objetivo. Hasta que no se cumpla el criterio de parada hacer:

- **Evaluación de costos:** Este componente se utiliza para realizar la evaluación de la función objetivo, donde cada individuo (topología) es evaluado para determinar su costo en función de los siguientes puntos:
 - Se calculan los parámetros de línea equivalentes para cada rama debido a la incorporación de circuitos en cada derecho de transmisión.
 - 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).



- 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 más los costos asociados a las pérdidas para la configuración óptima de despacho resultante del flujo óptimo de potencia AC. En este cálculo a las soluciones no factibles, es decir, que no hayan satisfecho los criterios técnicos se penalizan (se colocan costos sumamente altos), mediante la incorporación de generadores ficticios. Sus costos de generación de potencia activa y reactiva están incluidos en los datos de los modelos de red, y por medio de estos se puede estudiar diferentes casos.
- **Elitismo:** El mejor individuo de la población anterior se inserta en la población actual.
- **Selección:** Seleccionar de la población actual (incluido elitismo) como x_1 al individuo que proporcione la mejor solución (menor costo de la función objetivo) y x_2 sea la peor solución (la de costo mayor de la función objetivo).
- **Actualizar el vector de probabilidad p :** El vector de probabilidad será actualizado en función de la media y varianza (ecuaciones 4.4 y 4.5) y los correspondientes individuos x_1 (la mejor solución) y x_2 (la peor solución) actuales.
- **Generación de una nueva población:** Muestrear el vector de probabilidad para generar una nueva población a partir de una distribución normal aleatoria con la media y la desviación estándar actualizadas.




Figura 4.5: Diagrama de flujo Algoritmo Genético Compacto dominio continuo.

- **Verificar los individuos:** Verificar que los individuos de la población generada no superen el valor máximo ni el mínimo permitido por derecho de transmisión.



En la Figura 4.5 se muestra el diagrama de flujo que sintetiza el proceso anteriormente descrito.

4.8.3 Implementación del PET usando PBILc_1 y PBILc_2

A continuación, se explica los pasos a seguir para resolver el problema del PET por medio del PBILc_1 y PBILc_2.

- 1 Seleccionar el sistema a analizar.** Se cargan los datos del modelo de prueba. En esta tesis se utilizarán los modelos de Garver de 6 nodos y el IEEE de 24 nodos, con y sin redespacho.
- 2 Parámetros generales.** Son parámetros que tienen que ver con la convergencia del algoritmo y la meta-heurística seleccionada. Estos parámetros son: tamaño de la población (es un parámetro ajustable, el cual permanece constante durante la ejecución del algoritmo), número máximo de iteraciones, número de veces que se quiere repetir la prueba, número máximo de circuitos permitidos por cada derecho de transmisión en la red, topología base con la que comienza el problema y el método de solución meta-heurístico usado para resolver el problema del PET (En este caso el Algoritmo PBILc_1 o PBILc_2).
- 3 Inicializar los parámetros del algoritmo PBILc.** Dependiendo del enfoque del PBILc se requiere de diferentes parámetros. Para el PBILc_1: N_{mejor} y N_{peor} , donde N_{mejor} representa el porcentaje de la población total con los individuos con menor valor de función objetivo y N_{peor} representa el porcentaje de la población total con los individuos con mayor valor de función objetivo. η que es la velocidad de aprendizaje usado para actualizar el vector de probabilidad. Inicializar la desviación estándar inicial σ^1 . La sintonización de los parámetros que han dado buenos resultados para este algoritmo son: $N_{mejor}=15\%$, $N_{peor} = 15\%$, $\eta =0.08$, $X_{max} = 5$, $X_{min} = 0$,

$F_{inicial} = 1/3$ y $F_{final} = 1/6$, estas dos últimas variables son utilizadas para decrementar el valor de la desviación estándar a medida que avance en el proceso de optimización. Mientras que para el PBILc_2 se requiere de N_{mejor} usado para actualizar la columna dos del vector de probabilidades y η que es la velocidad de aprendizaje. Los parámetros que mejores soluciones han proporcionado son: $N_{mejor} = NI/2$ (NI es el número de individuos por generación) y $\eta = 0.08$. Además de los parámetros anteriores, se requiere inicializar el vector de probabilidades p para los dos enfoques del PBILc, el cual es creado de forma aleatoria mediante una distribución normal uniforme entre los valores comprendidos entre $[x_{min}, x_{max}]$, donde x_{min} , es la topología inicial del sistema en estudio y x_{max} corresponde a la máxima cantidad de circuitos por derecho de transmisión. Asimismo, se utilizó una probabilidad de mutación de 0.02.

4 Creación inicial de la población de soluciones. Con los parámetros establecidos en 2, la población inicial se crea de forma aleatoria, 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 transmisión. La población de soluciones iniciales consistirá en una matriz $m \times n$, con n igual a la cantidad de individuos de la población de soluciones y m 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 transmisión que conecta dos barras (ver Algoritmo 4.8).

5 Evaluación inicial de costos. Una vez creada la población inicial, el algoritmo evalúa la calidad de todos los individuos mediante la función objetivo. El valor de la función objetivo ha de ser un número real positivo. Este valor mide la calidad de la solución representada por cada individuo de



la población, de forma que cuanto mejor es la solución, menor será el valor de la función objetivo. El objetivo del algoritmo es la minimización de esa función.

La función objetivo del problema de planificación (corresponde a la parte del problema principal de expansión) consiste en minimizar el costo de la red, es decir, minimizar el costo de inversión y el costo de penalización asociada al corte de carga. La evaluación de cada individuo se realiza calculando en primer lugar los costos de inversión, posteriormente el costo de penalización asociada al corte de carga y a partir de ello el valor de la función objetivo.

6 Evaluación del criterio de parada. El criterio de parada considerado es el número máximo de iteraciones, el cual limita también el número de evaluaciones de la función objetivo. Hasta que no se cumpla el criterio de parada hacer:

- **Evaluación de costos:** Este componente se utiliza para realizar la evaluación de la función objetivo, donde cada individuo (topología) es evaluado para determinar su costo en función de los siguientes puntos:
 - Se calculan los parámetros de línea equivalentes para cada rama debido a la incorporación de circuitos en cada derecho de vía.
 - 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).
 - 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 a las soluciones no factibles, es decir, que no hayan satisfecho los criterios técnicos se penalizan (se colocan costos sumamente altos), mediante la incorporación de generadores ficticios. Sus costos de generación de potencia activa y reactiva están incluidos en los datos de los modelos de red, y por medio de estos se puede estudiar diferentes casos.

- **Elitismo:** El mejor individuo de la población anterior se inserta en la población actual.
- **Selección:** Para el PBILc_1 seleccionar de la población actual (incluido elitismo) los $N_{mejor}\%$ y $N_{peor}\%$ individuos en porcentaje de la población, mientras que, el PBILc_2 solo selecciona de la población actual (incluido elitismo) los $N_{mejor}\%$ individuos.
- **Actualizar el vector de probabilidad p :** Para el PBILc_1, actualizar el vector de probabilidad de acuerdo con las reglas de actualización (ecuación 4.7 y 4.8), mientras que, para el PBILc_2 actualizar el vector de probabilidad de acuerdo con las reglas de actualización (ecuación 4.10 y 4.11)
- **Mutar el vector de probabilidades:** Aplicar el algoritmo de mutación al vector de probabilidad (ver Algoritmo 4.7).
- **Decrementar el valor de la desviación estándar:** Este proceso está en función de la iteración actual ($iter$) y es realizado solo para el PBILc_1. El valor de la desviación estándar parte de un valor inicial en la primera iteración y a medida que las iteraciones avanzan la desviación estándar



decrementa su valor por medio de la ecuación: $\sigma = \sigma_{Max} - iter * (\sigma_{Max} - \sigma_{Min}) / (MaxIt)$, donde $MaxIt$ es el número total de iteraciones, $\sigma_{Max} = (X_{max} - X_{min}) * F_{inicial}$ y $\sigma_{Min} = (X_{max} - X_{min}) * F_{final}$.

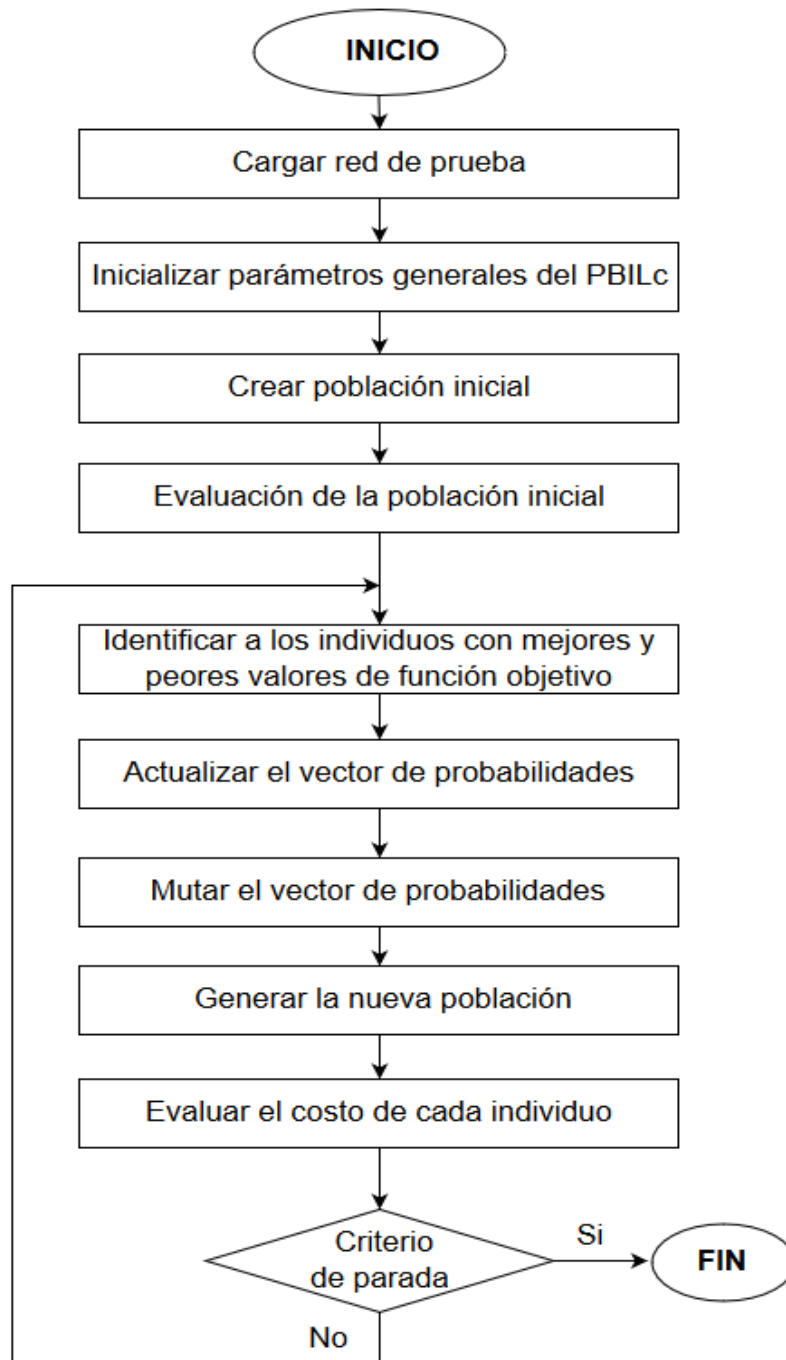


Figura 4.6: Diagrama de flujo Algoritmo PBILc_1 y PBILc_2.

- **Generación de una nueva población:** Para el BILc_1 muestrear el vector de probabilidad para generar una nueva población a partir distribución de



probabilidad con media igual al vector de probabilidad actualizado y con una desviación estándar decrementada. Para el PBILc_2 muestrear el vector de probabilidades actualizado a través de una distribución normal aleatoria $N(\mu, \sigma)$.

- **Verificar los individuos:** Verificar los individuos de la población generada no superen el valor máximo ni el mínimo permitido por derecho de transmisión.

En la Figura 4.6 se muestra el diagrama de flujo que sintetiza el proceso anteriormente descrito.



CAPÍTULO 5

PRUEBAS Y RESULTADOS

Introducción

Para resolver el problema de PET, se utilizó las técnicas de optimización basadas en algoritmos de estimación de distribución (específicamente AGc, AGcr y PBILc_1 y PBILc_2, descritos en el capítulo anterior), que son algoritmos que optimizan una función realizando un seguimiento de las estadísticas de la población de soluciones candidatas en cada generación (iteración).

Para comparar los resultados obtenidos por los algoritmos se han usado dos sistemas eléctricos: el sistema de Garver de 6 nodos y el sistema IEEE de 24 nodos, que son sistemas de prueba muy conocidos en la literatura y proporcionan una buena base de comparación de los resultados obtenidos en esta tesis. Los datos completos de los sistemas de pruebas, se muestra en los Anexos A y B, o se pueden encontrar en [12], [20], [32]. Para los dos sistemas de prueba se creó dos escenarios principales con y sin redespacho de generación. En el escenario con redespacho, los generadores se pueden ajustar dentro de sus límites de capacidad de generación. Por otra parte, en el escenario sin redespacho los generadores presentan una generación fija.

Los algoritmos fueron implementados en MATLAB, que se ejecuta en una plataforma de *hardware Intel Core i5, 3.10 GHz, 8 GB de RAM*. Se utilizó la herramienta de código abierto MATPOWER [55], 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, la cual utiliza una técnica especial de punto interior [56].



En este capítulo se describen las pruebas realizadas y se muestran los resultados obtenidos para diferentes escenarios de planeamiento; además, se hacen comparaciones con resultados encontrados en trabajos mencionados precedentemente.

5.1 Resultados

Los resultados mostrados son obtenidos para diferentes números de poblaciones (2, 20, 40, 60, 80, 100, 120 individuos), para un total de 10 experimentos realizados para cada escenario. El número de iteraciones máximo permitido fue escogido dependiendo de la complejidad del escenario de prueba planteado.

Para determinar el desempeño de los algoritmos, se consideraron tres parámetros principales. 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 consiga el valor de mínimo local, un mínimo global o un valor de referencia conocido. 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 función de los resultados de cada una de las 10 simulaciones obtenidas, el cual es un indicativo de la variabilidad de convergencia (alto o bajo componente de búsqueda aleatoria) del algoritmo utilizado. El tercer parámetro es la tasa de éxito, el cual es un indicativo de la eficiencia del algoritmo, ya que permite determinar mediante un porcentaje el número de veces que se obtiene el valor mínimo (mínimo local, un mínimo global o un valor de referencia conocido) del total de ensayos realizados. Además de estos parámetros, se presenta el valor promedio del número de evaluaciones de la función objetivo (F.O.) de todas las pruebas, el valor mínimo encontrado por el algoritmo y el tiempo de cálculo promedio en alcanzar el valor mínimo encontrado.

5.2 Sistema Garver de 6 barras

Este sistema tiene 6 nodos y 15 líneas candidatas, con una demanda total de 760MW de potencia activa, 152Mvar de demanda total de potencia reactiva y una potencia máxima de generación de 1,100 MW. El número máximo de circuitos permitidos por derecho de transmisión son de cinco y el número de topologías factibles y no factibles es $(5 + 1)^{15} = 6^{15}$. El sistema posee una configuración inicial de 6 líneas de transmisión. En la Figura 5.1 se presenta el diagrama unifilar de este sistema de prueba. En el Anexo A se presenta un mayor detalle de los datos de este sistema.




Figura 5.1: Sistema Garver- Topología base.

5.2.1 Sistema Garver con Redespacho (utilizando los algoritmos AGc, AGcr, PBILc_1 y PBILc_2)

Para el sistema de Garver con redespacho se analizaron dos situaciones. La primera de ellas, sin límite de reactivos (Garver_AC_A1). En este escenario se



permiten tener reactivos ilimitados y esto se consigue colocando la compensación shunt con un costo de US\$ 0/Mvar. Se modelan los reactivos a través de los generadores artificiales. El menor valor de inversión que se encontró para ese escenario es US\$ 110,000, con la adición de las siguientes líneas:

$$n_{3-5} = 1 \text{ y } n_{2-6} = 3 \quad (5.1)$$

Es decir, fue incorporada una línea entre las barras 3 y 5, y tres líneas entre las barras 2-6. Adicionalmente, se establece que para hacer operativamente factible este plan se requiere de compensación shunt en las siguientes barras: $r_{Q2} = 270.09$, $r_{Q4} = 73.92$, $r_{Q5} = 105.14$ Mvar.

El siguiente escenario analizado para el sistema de Garver con redespacho no se permite tener compensación de reactivos, al cual lo denominamos Garver_AC_A2. Esto se consigue al colocar un valor de cero a la potencia suministrada por los generadores artificiales, lo que puede considerarse equivalente a desconectar tales generadores. El menor valor de inversión encontrado en el modelo explicado es US\$ 220,000 e implica la adición de las siguientes líneas:

$$n_{1-2} = 2 ; n_{2-6} = 2 ; n_{3-5} = 1 \text{ y } n_{4-6} = 2 \quad (5.2)$$

Se compara el desempeño de los algoritmos AGc, AGcr, PBILc_1 y PBILc_2 aplicados a los dos escenarios de Garver con redespacho. El propósito es observar la velocidad de convergencia en cada uno de los algoritmos así como su desempeño. Para las simulaciones se establece poblaciones de 2, 20, 40, 60, 80, 100, 120 individuos para el caso del AGc y el AGcr con un límite máximo de 200 iteraciones; mientras que para los algoritmos PBILc_1 y PBILc_2 se establece poblaciones de 20, 40, 60, 80, 100, 120 individuos y un límite máximo de 150 iteraciones. Los resultados se muestran en las Tablas 5.1 - 5.8.



Tabla 5.1: Desempeño del AGc (Dominio binario). Modelo de Garver AC sin restricción de reactivos. Max. 200 iteraciones. (Garver_AC_A1).

Población	2	20	40	60	80	100	120
Tasa de éxito (%)	10	40	40	10	50	40	40
Iteraciones promedio	62	111	94	119	108	85	94
Desv. Est. iteraciones	0	7	28	0	20	15	15
Valor promedio F.O.	124	1,962	3,497	6,097	7,886	7,902	1,130
Valor mínimo (US\$x1,000)	110	110	110	110	110	110	110
Tiempo computacional (s)	4.83	26.64	36.66	66.64	77.004	73.61	95.88

Tabla 5.2: Desempeño del AGcr (Dominio continuo). Modelo de Garver AC sin restricción de reactivos. Max. 200 iteraciones. (Garver_AC_A1).

Población	2	20	40	60	80	100	120
Tasa de éxito (%)	50	100	100	100	100	100	100
Iteraciones promedio	105	105	63	77	70	62	47
Desv. Est. iteraciones	39	26	20	24	16	21	18
Valor promedio F.O.	210	2,110	2,609	4,612	5,634	6,284	5,745
Valor mínimo (US\$x1,000)	110	110	110	110	110	110	110
Tiempo computacional (s)	7.875	23.835	23.43	40.5	47.74	50.84	46.53

Tabla 5.3: Desempeño de algoritmo PBILc_1. Modelo de Garver AC sin restricción de reactivos. Max. 150 iteraciones. (Garver_AC_A1).

Población	20	40	60	80	100	120
Tasa de éxito (%)	20	20	20	30	10	40
Iteraciones promedio	128	81	71	55	67	64
Desv. Est. iteraciones	2	16	32	15	0	18
Valor promedio F.O.	2,560	3,240	4,260	4,453	6,700	7,770
Valor mínimo (US\$x1,000)	110	110	110	110	110	110
Tiempo computacional (s)	32	31.266	38.695	39.6	57.017	66.048



Tabla 5.4: Desempeño de algoritmo PBILc_2. Modelo de Garver AC sin restricción de reactivos. Max. 150 iteraciones. (Garver_AC_A1).

Población	20	40	60	80	100	120
Tasa de éxito (%)	70	80	50	50	50	30
Iteraciones promedio	53	51	52	47	51	49
Desv. Est. iteraciones	19	9	13	5	8	4
Valor promedio F.O.	1,010	2,075	3,132	3,376	5,120	5,960
Valor mínimo (US\$x1,000)	110	110	110	110	110	110
Tiempo computacional (s)	12.455	19.737	28.756	32.71	44.064	50.96

Tabla 5.5: Desempeño de AGc (Dominio binario). Modelo de Garver AC sin compensación de reactivos. Max. 200 iteraciones (Garver_AC_A2).

Población	2	20	40	60	80	100	120
Tasa de éxito (%)	10	30	40	20	40	60	70
Iteraciones promedio	190	120	104	135	119	117	82
Desv. Est. iteraciones	0	25	44	22	21	16	34
Valor promedio F.O.	380	2,389	3,753	7,206	8,605	10,571	9,489
Valor mínimo (US\$x1,000)	250	220	220	220	220	220	220
Tiempo computacional (s)	15.01	27	39.72	72.9	85.44	98.51	94.95

Tabla 5.6: Desempeño del AGcr (Dominio continuo). Modelo de Garver AC sin compensación de reactivos. Max. 200 iteraciones (Garver_AC_A2).

Población	2	20	40	60	80	100	120
Tasa de éxito (%)	10	10	10	30	40	60	60
Iteraciones promedio	158	152	193	138	78	93	80
Desv. Est. iteraciones	0	0	0	46	23	27	23
Valor promedio F.O.	1,570	3,040	7,720	7,968	6,183	9,028	7,158
Valor mínimo (US\$x1,000)	240	240	258	220	220	220	220
Tiempo computacional (s)	15.54	26.4	120.23	73.3	76.51	85.5	96.4



Tabla 5.7: Desempeño de Algoritmo PBILc_1. Modelo de Garver AC sin compensación de reactivos. Max. 150 iteraciones (Garver_AC_A2).

Población	20	40	60	80	100	120
Tasa de éxito (%)	80	80	80	80	100	100
Iteraciones promedio	90	85	73	55	52	37
Desv. Est. iteraciones	19	9	14	20	9	14
Valor promedio F.O.	3,402	3,435	4,402	4,368	5,210	4,044
Valor mínimo (US\$x1,000)	220	220	220	220	220	220
Tiempo computacional (s)	20.61	34.085	38.982	38.17	52.572	41.255

Tabla 5.8 Desempeño de Algoritmo PBILc_2. Modelo de Garver AC sin compensación de reactivos. Max. 150 iteraciones (Garver_AC_A2).

Población	20	40	60	80	100	120
Tasa de éxito (%)	90	80	90	100	80	80
Iteraciones promedio	57	60	59	62	55	53
Desv. Est. iteraciones	9	6	6	12	11	5
Valor promedio F.O.	1,146	2,400	3,553	5,024	5,550	6360
Valor mínimo (US\$x1,000)	220	220	220	220	220	220
Tiempo computacional (s)	13.33	23.34	32.33	43.83	46.14	54.37

En cuanto al valor mínimo de inversión, las soluciones mostradas en las tablas anteriores relacionadas al escenario Garver_AC_A1 concuerdan con los resultados obtenidos en [2], [12], mientras que para el escenario Garver_AC_A2 resulta en un valor mayor al establecido en aquellas referencias.

Para la condición más relajada de prueba Garver_AC_A1 (Tablas 5.1 – 5.3) se observó que cada algoritmo se comporta de diferente manera. El AGc presenta una tasa de éxitos para los 10 ensayos entre 10-50%, y se puede notar que, para poblaciones de 2 individuos por generación, el algoritmo realiza una búsqueda aleatoria, resultando muy ineficiente para esa cantidad de individuos. A medida que aumenta el número de individuos por generación, el algoritmo mejora su



desempeño de convergencia; la tasa de convergencia representada por el número de iteraciones promedio requeridas está entre 85 y 119, y la desviación estándar de las simulaciones está entre 7 y 28. Esto indica que el algoritmo presenta un bajo componente de búsqueda aleatoria. Por otra parte, el AGcr presenta un mejor desempeño que el AGc ya que la tasa de éxito para 10 ensayos es notablemente mejor; esto debido a que con poblaciones pequeñas (2 individuos) se tiene una tasa de éxito del 50%, y a medida que aumenta la población se tiene un 100% de éxito. El número de iteraciones promedio requeridas se encuentra entre 62 y 105, y la desviación estándar de las simulaciones entre 16 y 39. Por otro lado, el algoritmo PBILc_1 presenta una tasa de éxito entre 10-30%, con el número de iteraciones promedio requeridas entre 55 y 81, y la desviación estándar entre 15 y 32. El algoritmo PBILc_2 presenta un mejor desempeño que el algoritmo PBILc_1 en términos de la tasa de éxitos (50-80%) y el número de iteraciones promedio (49-71).

Para la condición menos relajada del modelo de prueba Garver Garver_AC_A2 (ver Tablas 5.5 – 5.8), al no permitir compensación shunt mediante generación de reactivos, el menor valor encontrado por los algoritmos es superior al presentado en [2], [12]. De los cuatro algoritmos, el PBILc_2 es el que mejor desempeño presenta, y un aspecto notorio entre los algoritmos PBILc_1 y PBILc_2 se presenta para poblaciones pequeñas (20 y 40 individuo), donde se tiene similares tasas de éxitos, pero el número de iteraciones promedio requeridas hasta alcanzar el valor mínimo encontrado se reduce a la mitad para el PBILc_2.

Los algoritmos presentan diferentes comportamientos, donde se nota claramente que el AGcr presenta un buen desempeño para problemas simples y a medida que aumenta la complejidad del problema su desempeño se reduce; mientras que el PBILc_1, aunque su eficiencia es baja para problemas simples, su poder de convergencia para sistemas más complejos mejora en comparación con

AGc y AGcr, pero es el PBILc_2 el que mejor comportamiento presenta para los dos escenarios analizados.




Figura 5.2: Presentación de la convergencia del AGc (dominio binario) para 10 ensayos. Escenario Garver_AC_A1. Población 80 individuos.

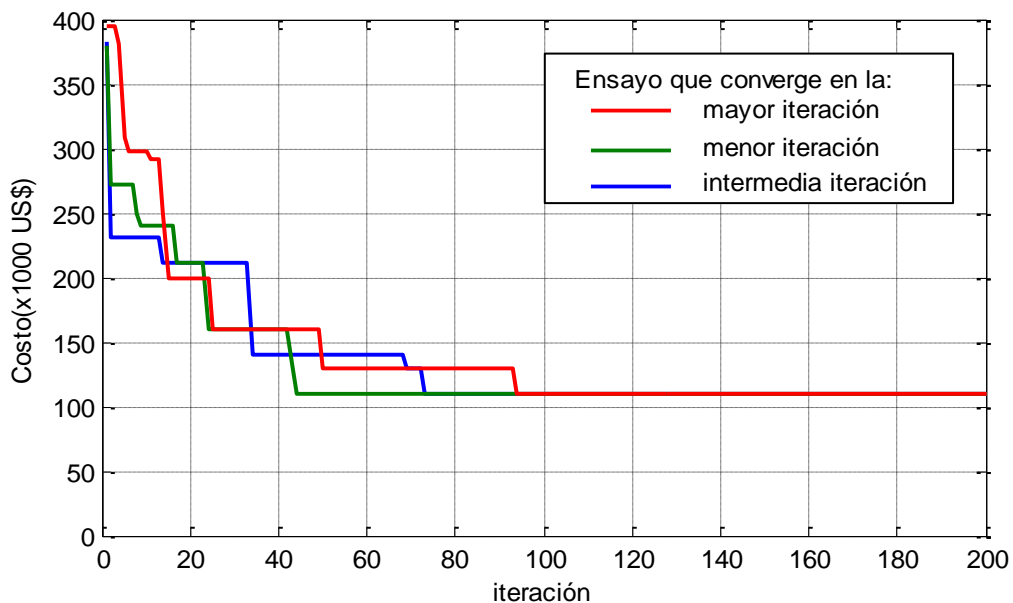


Figura 5.3: Convergencia del AGcr (dominio continuo) para 3 de 10 ensayos. Escenario Garver_AC_A1. Población 80 individuos.




Figura 5.4: Convergencia del Algoritmo PBILc_1 para 10 ensayos. Escenario Garver_AC_A1. Población 80 individuos.




Figura 5.5: Convergencia del Algoritmo PBILc_2 para 10 ensayos. Escenario Garver_AC_A1. Población 80 individuos.




Figura 5.6: Convergencia del AGc para 10 ensayos. Escenario Garver_AC_A2. Población 100 individuos.




Figura 5.7: Convergencia del AGcr para 10 ensayos. Escenario Garver_AC_A2. Población 100 individuos.

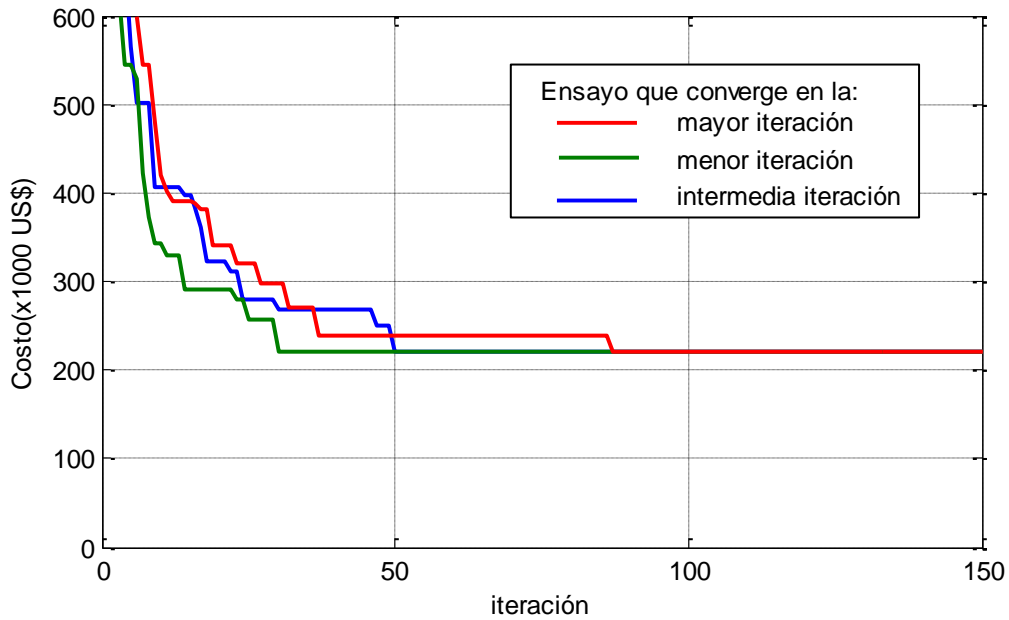


Figura 5.8: Convergencia del Algoritmo PBILc_1 para 3 de 10 ensayos. Escenario Garver_AC_A2. Población 100 individuos.




Figura 5.9: Convergencia del Algoritmo PBILc_2 para 10 ensayos. Escenario Garver_AC_A2. Población 100 individuos.



En las Figuras 5.2 - 5.9 se presentan las características de convergencia de las poblaciones con mejor rendimiento para los dos escenarios de Garver (Garver_AC_A1 y Garver_AC_A2).

5.2.2 Sistema Garver sin Redespacho

El sistema de Garver sin redespacho es aquel donde los generadores presentan una generación fija durante el proceso de solución del flujo óptimo de potencia, para el cual se analizaron tres escenarios. El primer escenario corresponde a la generación de reactivos ilimitados con un costo de 0 \$/Mvar, al que lo llamaremos Garver_AC_B1. Este modelo corresponde a la condición más relajada. En el segundo escenario no se permite la generación de reactivos, al que lo llamaremos Garver_AC_B2 que corresponde a la condición menos relajada. Por último, se analiza un escenario donde la generación de reactivos presenta un costo de US\$ 1,000/Mvar, al que lo llamaremos Garver_AC_B3. Este escenario corresponde a la condición intermedia entre los escenarios anteriores.

5.2.2.1 Algoritmo Genético Compacto en el dominio binario

Utilizando el algoritmo AGc el menor valor de inversión encontrado para el escenario Garver sin redespacho y considerando compensación ilimitada de reactivos (Garver_AC_B1) es US\$ 188,000 con la adición de las siguientes líneas:

$$n_{3-6} = 1 ; n_{2-6} = 2 ; n_{3-5} = 1 \text{ y } n_{4-6} = 2 \quad (5.3)$$

Mientras que el menor valor de inversión encontrado para el escenario Garver_AC_B2 es US\$ 268,000 con la adición de las siguientes líneas:

$$n_{1-2} = 2 ; n_{2-6} = 2 ; n_{3-5} = 1 ; n_{3-6} = 1 \text{ y } n_{4-6} = 2 \quad (5.4)$$



Por último, para el escenario Garver_AC_B3 el resultado es igual al caso anterior, en el que el mínimo valor de inversión encontrado es US\$ 268,000; adicionalmente se establece que no se requiere de compensación shunt.

Para determinar la característica de convergencia del AGc se ha ejecutado 10 ensayos para poblaciones de 60, 80, 100 y 120 individuos, aplicados a cada uno de los escenarios de Garver sin redespacho. Los resultados (tasa de éxito, iteraciones promedio, valor mínimo, evaluaciones promedio de la función objetivo) se muestran en las Tablas 5.9 - 5.11.

Tabla 5.9: Desempeño del AGc (Dominio binario). Modelo de Garver AC sin redespacho sin restricción de reactivos. Max. 200 iteraciones. (Garver_AC_B1).

Población	60	80	100	120
Tasa de éxito (%)	10	10	30	10
Iteraciones promedio	103	100	77	72
Desv. Est. iteraciones	0	0	15	0
Valor promedio F.O.	5,160	7,464	7,404	8,638
Valor mínimo (US\$x1,000)	188	188	188	188
Tiempo computacional (s)	57.68	70	67.452	72

Tabla 5.10: Desempeño del AGc (Dominio binario). Modelo de Garver AC sin redespacho sin generación de reactivos. Max. 200 iteraciones. (Garver_AC_B2).

Población	60	80	100	120
Tasa de éxito (%)	10	20	30	10
Iteraciones promedio	129	113	119	100
Desv. Est. iteraciones	0	21	10	0
Valor promedio F.O.	7,709	10,096	11,525	11,876
Valor mínimo (US\$x1,000)	311	268	268	268
Tiempo computacional (s)	74.949	83.168	105.434	105



Tabla 5.11: Desempeño del AGc (Dominio binario). Modelo de Garver AC sin redespacho con costo de reactivos. Max. 200 iteraciones. (Garver_AC_B3).

Población	60	80	100	120
Tasa de éxito (%)	10	30	40	20
Iteraciones promedio	129	131	132	119
Desv. Est. iteraciones	0	38	9	35
Valor promedio F.O.	7,168	9,760	12,455	13,402
Valor mínimo (US\$x1,000)	268	268	268	268
Tiempo computacional (s)	71.982	92.093	114.708	130.9

De los resultados obtenidos en las tablas anteriores se puede observar que el AGc aplicado al escenario sin restricción de reactivos (Garver_AC_B1) no presenta un buen desempeño ya que la tasa máxima de éxito es del 40%, alcanzada en una población de 100 individuos, mientras que para el resto de poblaciones (60, 80 y 120) se presenta una tasa de éxito de solo el 10%. Para el segundo escenario de Garver sin redespacho sin permitir la compensación de reactivos (Garver_AC_B2), también presenta un bajo desempeño ya que la tasa de éxito no supera el 30%, alcanzada en una población de 100 individuos. Para la condición intermedia de las dos anteriores (costo por generación de reactivos de 1,000 US\$/Mvar), éste presenta un mejor rendimiento que el escenario anterior, esto se debe a que este escenario es más simple que el escenario Garver_AC_B2, pero de la misma forma el desempeño no es notablemente bueno, alcanzando una tasa de éxito del 40% con una desviación estándar menor a 38. De los resultados anteriores, se puede notar que el AGc reduce su eficiencia y desempeño a medida que los sistemas de prueba son más complejos.

En las Figuras 5.10 - 5.12 se presenta las características de convergencia del AGc para el sistema de Garver sin redespacho. Se han efectuado 10 ensayos y se ha permitido que se ejecuten hasta 200 iteraciones.




Figura 5.10: Convergencia del AGc (dominio binario) para 10 ensayos. Escenario Garver_AC_B1. Población 100 individuos.




Figura 5.11: Convergencia del AGc (dominio binario) para 10 ensayos. Escenario Garver_AC_B2. Población 100 individuos.




Figura 5.12: Convergencia del AGc (dominio binario) para 10 ensayos. Escenario Garver_AC_B3. Población 100 individuos.

5.2.2.2 Algoritmo Genético Compacto en el dominio continuo (AGcr)

Utilizando el algoritmo AGcr, el menor valor de inversión encontrado para el escenario Garver sin redespacho y considerando compensación ilimitada de reactivos (Garver_AC_B1) es US\$ 200,000 con la adición de las siguientes líneas:

$$n_{2-6} = 3 ; n_{3-5} = 1 \text{ y } n_{4-6} = 3 \quad (5.5)$$

Mientras que el menor valor de inversión encontrado para el escenario Garver_AC_B2 es US\$ 268,000 con la adición de las siguientes líneas:

$$n_{1-2} = 2 ; n_{2-6} = 2 ; n_{3-5} = 1 ; n_{3-6} = 1 \text{ y } n_{4-6} = 2 \quad (5.6)$$



Tabla 5.12: Desempeño del AGcr. Modelo de Garver AC sin redespacho sin restricción de reactivos. Max. 200 iteraciones. (Garver_AC_B1).

Población	60	80	100	120
Tasa de éxito (%)	60	90	90	70
Iteraciones promedio	70	93	80	87
Desv. Est. iteraciones	38	35	28	39
Valor promedio F.O.	4,236	7,423	8,072	10,430
Valor mínimo (US\$x1,000)	200	200	200	200
Tiempo computacional (s)	37.8	63.24	66.08	87

Tabla 5.13: Desempeño del AGcr. Modelo de Garver AC sin redespacho sin generación de reactivos. Max. 200 iteraciones. (Garver_AC_B2).

Población	60	80	100	120
Tasa de éxito (%)	10	10	10	10
Iteraciones promedio	66	51	59	105
Desv. Est. iteraciones	0	0	0	0
Evaluaciones promedio F.O.	3,944	4,051	5,900	12,597
Valor mínimo (US\$x1,000)	311	316	268	268
Tiempo computacional (s)	37.686	43.146	51.035	121.065

Tabla 5.14: Desempeño del AGcr. Modelo de Garver AC sin redespacho con costo de reactivos 1,000 US\$/Mvar). Max. 200 iteraciones. (Garver_AC_B3).

Población	60	80	100	120
Tasa de éxito (%)	10	10	20	10
Iteraciones promedio	87	99	127	89
Desv. Est. iteraciones	0	0	17	0
Valor promedio F.O.	5,210	7,902	12,671	10,657
Valor mínimo (US\$x1,000)	320	318	298	288
Tiempo computacional (s)	47.15	69.003	107.06	89

Para determinar la característica de convergencia del AGcr se ha ejecutado 10 ensayos para poblaciones de 60, 80, 100 y 120 individuos, aplicados a cada uno de los escenarios de Garver sin redespacho. Los resultados se muestran en las Tablas 5.12 - 5.14.

De los resultados obtenidos en las tablas anteriores se puede observar que el algoritmo AGcr al igual que el AGc no presenta un buen desempeño, e incluso es más ineficiente ya que para la condición sin restricción de reactivos el valor óptimo encontrado es mayor (US\$ 200,000) al encontrado en AGc (US\$ 188,000), esto indica que a medida que el sistema de prueba se vuelve más complejo, el AGcr presenta menor desempeño.

Desde la Figura 5.13 hasta la Figura 5.15 se presentan las características de convergencia del AGcr para los tres escenarios de Garver sin redespacho. Se han efectuado 10 ensayos y se ha permitido que se ejecuten hasta 200 iteraciones.




Figura 5.13: Convergencia del AGcr para 10 ensayos. Escenario Garver_AC_B1. Población 100 individuos.




Figura 5.14: Convergencia AGcr para 10 ensayos. Escenario Garver_AC_B2. Población 120 individuos.




Figura 5.15: Convergencia del AGcr para 10 ensayos. Escenario Garver_AC_B3. Población 100 individuos.



5.2.2.3 Algoritmos PBILc_1 y PBILc_2

El menor valor de inversión encontrado para el escenario Garver_AC_B1 es US\$ 188,000 con la adición de las siguientes líneas:

$$n_{3-6} = 1 ; n_{2-6} = 2 ; n_{3-5} = 1 \text{ y } n_{4-6} = 2 \quad (5.7)$$

Mientras que el menor valor de inversión encontrado para el escenario Garver_AC_B2 es US\$ 268,000 con la adición de las siguientes líneas:

$$n_{1-2} = 2 ; n_{2-6} = 2 ; n_{3-5} = 1 ; n_{3-6} = 1 \text{ y } n_{4-6} = 2 \quad (5.8)$$

Por último, para el escenario Garver_AC_B3 el resultado es igual al caso anterior, el mínimo valor de inversión encontrado es US\$ 268,000, adicionalmente se establece que no se requiere de compensación shunt.

$$n_{1-2} = 2 ; n_{2-6} = 2 ; n_{3-5} = 1 ; n_{3-6} = 1 \text{ y } n_{4-6} = 2 \quad (5.9)$$

Tabla 5.15: Desempeño de Algoritmo PBILc_1. Modelo de Garver AC sin restricción de reactivos. Max. 150 iteraciones (Garver_AC_B1).

Población	60	80	100	120
Tasa de éxito (%)	50	70	60	60
Iteraciones promedio	69	66	67	64
Desv. Est. iteraciones	16	19	12	23
Valor promedio F.O.	4,188	5,291	6,783	7,780
Valor mínimo (US\$x1,000)	188	188	188	188
Tiempo computacional (s)	37.812	53.196	63.114	64



Tabla 5.16: Desempeño de Algoritmo PBILc_1. Modelo de Garver AC sin compensación shunt. Max. 150 iteraciones (Garver_AC_B2).

Población	60	80	100	120
Tasa de éxito (%)	20	50	50	30
Iteraciones promedio	78	95	88	92
Desv. Est. iteraciones	16	6	10	10
Valor promedio F.O.	4,710	7,648	8,800	11,120
Valor mínimo (US\$x1,000)	268	268	268	268
Tiempo computacional (s)	41.496	63.84	72.248	89.884

Tabla 5.17: Desempeño de Algoritmo PBILc_1. Modelo de Garver AC con costo por compensación 1,000 US\$/Mvar. Max. 150 iteraciones (Garver_AC_B3).

Población	60	80	100	120
Tasa de éxito (%)	40	30	30	20
Iteraciones promedio	87	93	80	82
Desv. Est. iteraciones	18	14	10	21
Valor promedio F.O.	5,220	7,440	8,833	9,900
Valor mínimo (US\$x1,000)	268	268	268	268
Tiempo computacional (s)	48.633	65.1	66.32	86.1

Tabla 5.18: Desempeño de Algoritmo PBILc_2. Modelo de Garver AC sin restricción de reactivos. Max. 150 iteraciones (Garver_AC_B1).

Población	60	80	100	120
Tasa de éxito (%)	80	90	80	90
Iteraciones promedio	79	82	63	64
Desv. Est. iteraciones	27	16	4	12
Valor promedio F.O.	4,792	6604	6,387	7,706
Valor mínimo (US\$x1,000)	188	188	188	188
Tiempo computacional (s)	44.793	55.268	52.41	68.864



Tabla 5.19: Desempeño de Algoritmo PBILc_2. Modelo de Garver AC sin compensación shunt. Max. 150 iteraciones (Garver_AC_B2).

Población	60	80	100	120
Tasa de éxito (%)	80	80	100	100
Iteraciones promedio	74	74	72	67
Desv. Est. iteraciones	5	10	6	10
Valor promedio F.O.	4,447	5,968	7,280	8,088
Valor mínimo (US\$x1,000)	268	268	268	268
Tiempo computacional (s)	39.88	51.57	62.064	68.34

Tabla 5.20: Desempeño de Algoritmo PBILc_2. Modelo de Garver AC con costo por compensación 1,000 US\$/Mvar. Max. 150 iteraciones (Garver_AC_B3).

Población	60	80	100	120
Tasa de éxito (%)	100	80	100	100
Iteraciones promedio	75	74	71	64
Desv. Est. iteraciones	11	5	12	7
Valor promedio F.O.	4,548	5,960	7,190	7,692
Valor mínimo (US\$x1,000)	268	268	268	268
Tiempo computacional (s)	39.75	50.542	64.326	64.96

Para determinar la característica de convergencia de los algoritmos PBILc_1 y PBILc_2 se ha ejecutado 10 ensayos para poblaciones de 60, 80, 100 y 120 individuos, aplicados a cada uno de los escenarios de Garver sin redespacho. Los resultados se muestran en las Tablas 5.15- 5.20.

Para el escenario Garver_AC_B1, con el algoritmo PBILc_1 se requiere de iteraciones promedio de entre 60-70 para obtener el valor mínimo encontrado. La tasa de éxito para 10 ensayos, está entre 50% y 70% con una tendencia a que la tasa de éxito aumente de 60 a 80 individuos, y para poblaciones mayores la tasa

de éxito tiende a disminuir. Esto indica que un incremento elevado de la población disminuye la eficiencia del PBILc_1, lo cual se puede producir debido a que para actualizar el vector de probabilidad el porcentaje de individuos (mejores individuos) seleccionados deben ser muy semejantes entre sí; y por tanto tendiendo a una zona de búsqueda de mínimo local (solución prematura). Por otra parte, al utilizar el escenario Garver_AC_B2, las iteraciones promedio para obtener el valor mínimo son mayores que el caso anterior (entre 78 y 95 iteraciones) para 10 ensayos efectuados con 60, 80, 100 y 120 individuos, mientras que la tasa de éxito decae al rango entre el 20% y el 50%. Eso es comprensible debido a que es un escenario más complejo que el escenario anterior. Finalmente, para el escenario de Garver_AC_B3, el desempeño del algoritmo PBILc_1 presenta una tasa de éxito muy baja semejante al caso anterior. Por otro lado, el algoritmo PBILc_2 proporciona un mejor desempeño que el PBILc_1 para cada escenario analizado, tanto en términos de la tasa de éxito como en las iteraciones promedio requeridas hasta alcanzar el mínimo valor encontrado.




Figura 5.16: Convergencia del Algoritmo PBILc_1 para 10 ensayos. Escenario Garver_AC_B1. Población 100 individuos.




Figura 5.17: Convergencia del Algoritmo PBILc_2 para 10 ensayos. Escenario Garver_AC_B1. Población 100 individuos.




Figura 5.18: Convergencia del Algoritmo PBILc_1 para 10 ensayos. Escenario Garver_AC_B2. Población 100 individuos.




Figura 5.19: Convergencia del Algoritmo PBILc_2 para 10 ensayos. Escenario Garver_AC_B2. Población 100 individuos.




Figura 5.20: Convergencia del Algoritmo PBILc_1 para 10 ensayos. Escenario Garver_AC_B3. Población 100 individuos.




Figura 5.21: Convergencia del Algoritmo PBILc_2 para 10 ensayos. Escenario Garver_AC_B3. Población 100 individuos.

En las Figuras 5.16 - 5.21 se presenta las características de convergencia del algoritmo PBILc_1 y PBILc_2 para los tres escenarios de Garver sin redespacho. Se han efectuado 10 ensayos y se ha permitido que se ejecuten hasta 150 iteraciones.

5.3 Sistema IEEE de 24 barras

Este sistema es uno de los más utilizados para probar la eficiencia de los algoritmos para resolver el problema de la planificación de la expansión del sistema de transmisión. Se trata de un sistema de 24 barras y 41 caminos candidatos, de las cuales 7 son ramas nuevas y en 34 de ellas existen circuitos en la configuración inicial, como se muestra en la Figura 5.22. La demanda prevista del sistema es de 8,550MW y una demanda total de reactivos de 1,746Mvar. El número máximo de líneas adicionadas por camino es 5. El número de topologías posibles es de $(5 + 1)^{41} = 6^{41}$. En el Anexo B se muestra los datos completos para este sistema.




Figura 5.22: Sistema IEEE - Topología Base.



5.3.1 Sistema IEEE de 24 barras con redespacho aplicando el algoritmo PBILc_1 y PBILc_2

Para este sistema con redespacho se analizó el escenario con compensación shunt ilimitada. El menor valor encontrado es US\$ 51,000 [2], [12], con la adición de las siguientes líneas:

$$n_{1-2} = 1 ; n_{6-10} = 1 \text{ y } n_{7-8} = 2 \quad (5.10)$$

Adicionalmente, se requiere para este plan una compensación shunt en las siguientes barras: $r_{Q3} = 387.77$, $r_{Q4} = 80.86$, $r_{Q5} = 57.68$, $r_{Q8} = 135.75$, $r_{Q9} = 348$, $r_{Q10} = 87.95$, $r_{Q19} = 153.94$ y $r_{Q20} = 239.1$.

Para este escenario se han ejecutado 10 ensayos para poblaciones de 80, 100 y 120 individuos con un máximo de 200 iteraciones. En las Tablas 5.21- 5.22 se presenta los parámetros de convergencia para este escenario, donde el PBILc_2 presenta el mejor desempeño, en cuanto a la tasa de éxitos e incluso en robustez, ya que las iteraciones promedio (entre 77-82 iteraciones) requeridas por el PBILc_2 hasta alcanzar el mínimo encontrado es mucho menor del que se necesita para el PBILc_1 (entre 134-146 iteraciones).

Tabla 5.21: Desempeño de Algoritmo PBILc_1. Modelo IEEE con redespacho. Max. 200 iteraciones.

Población	80	100	120
Tasa de éxito (%)	50	60	100
Iteraciones promedio	134	146	140
Dev. Est. iteraciones	25	12	28
Valor promedio F.O..	10,784	14,666	16,884
Valor mínimo (US\$x1,000)	51	51	51
Tiempo computacional (s)	222.44	202.064	227.5

Tabla 5.22: Desempeño de Algoritmo PBILc_2. Modelo IEEE con redespacho.
 Max. 200 iteraciones.

Población	80	100	120
Tasa de éxito (%)	100	80	80
Iteraciones promedio	82	82	77
Desv. Est. iteraciones	2	3	7
Valor promedio F.O.	6,560	8,262	9285
Valor mínimo (US\$x1,000)	51	51	51
Tiempo computacional (s)	88.232	103.56	118.58

En las Figuras 5.23- 5.24 se muestra las características del comportamiento del algoritmo PBILc_1 y PBILc_2 para el modelo IEEE de 24 nodos con redespacho y sin límite de reactivos.




Figura 5.23: Convergencia del Algoritmo PBILc_1 para 10 ensayos. Modelo IEEE con redespacho para 3 de 10 ensayos. Población 120 individuos.




Figura 5.24: Convergencia del Algoritmo PBILc_2 para 10 ensayos. Modelo IEEE con redespacho para 3 de 10 ensayos. Población 120 individuos.

5.3.2 Sistema IEEE de 24 barras sin redespacho

Para esta condición se analizaron tres escenarios. El primer escenario corresponde a la generación de reactivos ilimitados con un costo de US\$ 0/Mvar, al que lo llamaremos IEEE_AC_A1. Este modelo corresponde a la condición más relajada. En el segundo escenario no se permite la generación de reactivos, al que lo llamaremos IEEE_AC_A2 que corresponde a la condición menos relajada. Por último, se analizará un escenario donde la generación de reactivos presenta un costo de US\$ 100/Mvar, al que lo llamaremos IEEE_AC_A3. Este modelo corresponde a la condición intermedia entre los dos primeros escenarios. Para todos los escenarios se han aplicado el algoritmo PBILc_1 y PBILc_2. Se han ejecutado 10 ensayos para poblaciones de 80, 100 y 120 individuos, con 200 iteraciones para cada ensayo.

El menor valor de inversión encontrado para el escenario IEEE_AC_A1 es US\$ 113,000 con la adición de las siguientes líneas:



$$n_{1-2} = 1 ; n_{6-10} = 1 ; n_{7-8} = 2 \text{ y } n_{13-14} = 1 \quad (5.11)$$

Tabla 5.23: Desempeño de Algoritmo PBILc_1. Modelo IEEE sin redespacho, sin restricción de reactivos (IEEE_AC_A1). Max. 200 iteraciones.

Población	80	100	120
Tasa de éxito (%)	60	60	100
Iteraciones promedio	136	165	149
Desv. Est. iteraciones	13	22	18
Valor promedio F.O.	10,880	16,566	17,964
Valor mínimo (US\$x1,000)	113	113	113
Tiempo computacional (s)	134.64	191.4	208.6

Tabla 5.24: Desempeño de Algoritmo PBILc_2. Modelo IEEE sin redespacho, sin restricción de reactivos (IEEE_AC_A1). Max. 200 iteraciones.

Población	80	100	120
Tasa de éxito (%)	100	100	100
Iteraciones promedio	90	89	90
Desv. Est. iteraciones	6	5	9
Valor promedio F.O.	7,232	8,900	10,800
Valor mínimo (US\$x1,000)	113	113	113
Tiempo computacional (s)	91.8	108.58	121.5

La Tablas 5.23- 5.24 presenta los parámetros de convergencia para el escenario IEEE_AC_A1 del sistema IEEE de 24 barras, donde se aprecia que la solución del problema de planeamiento presenta un valor de US\$ 113,000, que es mayor al resultado encontrado en las referencias [2], [12]. En el PBILc_1 la cantidad de iteraciones promedio requeridas hasta alcanzar el menor valor esta entre 136-165, mientras que para el PBILc_2 las iteraciones promedio no son mayores a 90 iteraciones. Además, para el PBILc_1 a medida que aumenta la



población, la tasa de éxito se incrementa, llegando a una tasa de éxito de 100% con 120 individuos, mientras que el 100% de éxitos con el PBILc_2 se alcanza desde una población 80 individuos.

El menor valor de inversión encontrado para el escenario IEEE_AC_A2 es US\$ 149,000 con la adición de las siguientes líneas:

$$n_{1-2} = 1 ; n_{6-10} = 1 ; n_{7-8} = 2 ; n_{13-14} = 1 \text{ y } n_{16-17} = 1 \quad (5.12)$$

Las Tablas 5.25- 5.26 presentan los parámetros de convergencia para el escenario IEEE_AC_A2 del sistema IEEE de 24 barras, donde se aprecia que el PBILc_1 presenta un eficiencia similar al PBILc_2, pero la diferencia recae en el número de iteraciones promedio requeridas hasta alcanzar el valor mínimo encontrado, por lo que el PBILc_2 requiere un menor número de evaluaciones de la función objetivo para alcanzar el mínimo valor encontrado.

Tabla 5.25: Desempeño de Algoritmo PBILc_1. Modelo IEEE sin redespacho, sin compensación shunt (IEEE_AC_A2). Max. 200 iteraciones.

Población	80	100	120
Tasa de éxito (%)	90	100	100
Iteraciones promedio	146	154	155
Desv. Est. iteraciones	13	11	12
Valor promedio F.O.	11,680	15,430	18,672
Valor mínimo (US\$x1,000)	149	149	149
Tiempo computacional (s)	133.32	142.38	163.71



Tabla 5.26: Desempeño de Algoritmo PBILc_2. Modelo IEEE sin redespacho, sin compensación shunt (IEEE_AC_A2). Max. 200 iteraciones.

Población	80	100	120
Tasa de éxito (%)	90	100	100
Iteraciones promedio	98	154	90
Desv. Est. iteraciones	6	11	6
Valor promedio F.O.	7,884	15,430	10,800
Valor mínimo (US\$x1,000)	149	149	149
Tiempo computacional (s)	98	122.4	132.3

Por último, para el escenario IEEE_AC_C3 el menor valor de inversión encontrado por el PBILc_1 es US\$ 169,000, con la adición de las siguientes líneas:

$$n_{1-2} = 2 ; n_{6-10} = 2 ; n_{7-8} = 2 \text{ y } n_{13-14} = 1 \quad (5.12)$$

Mientras que con el PBILc_2, el escenario IEEE_AC_C3 presenta un costo de inversión de US\$ 168,000, con la adición de las siguientes líneas:

$$n_{1-2} = 1 ; n_{6-10} = 1 ; n_{7-8} = 2 \text{ y } n_{11-13} = 1 \quad (5.13)$$

Adicionalmente se establece que para el costo de inversión de US\$ 168,000 se requiere una compensación shunt con un costo de \$ 66,330, en las siguientes barras: $r_{Q3} = 76.56$, $r_{Q4} = -47.15$, $r_{Q5} = -85.84$, $r_{Q8} = -81.56$, $r_{Q9} = -72.19$, $r_{Q10} = -100$, $r_{Q19} = -100$ y $r_{Q20} = -100$ MVAR.

Las Tablas 5.27- 5.28 presentan los parámetros de convergencia para el escenario IEEE_AC_A3, donde, aunque con el PBILc_2 se tiene una tasa de éxitos muy baja, el valor mínimo encontrado es menor al proporcionado por el PBILc_1.

Tabla 5.27: Desempeño de Algoritmo PBILc_1. Escenario IEEE_AC_A3. Max. 200 iteraciones.

Población	80	100	120
Tasa de éxito (%)	100	100	100
Iteraciones promedio	132	113	107
Desv. Est. iteraciones	16	9	18
Valor promedio F.O.	10,592	11,340	12,864
Valor mínimo (US\$x1,000)	169	169	169
Tiempo computacional (s)	144.102	178.64	218.55

Tabla 5.28: Desempeño de Algoritmo PBILc_2. Escenario IEEE_AC_A3. Max. 200 iteraciones.

Población	80	100	120
Tasa de éxito (%)	10	40	30
Iteraciones promedio	100	102	90
Desv. Est. iteraciones	0	9	2
Valor promedio F.O.	8,000	10,275	10,840
Valor mínimo (US\$x1,000)	168	168	168
Tiempo computacional (s)	98	194.04	135.9

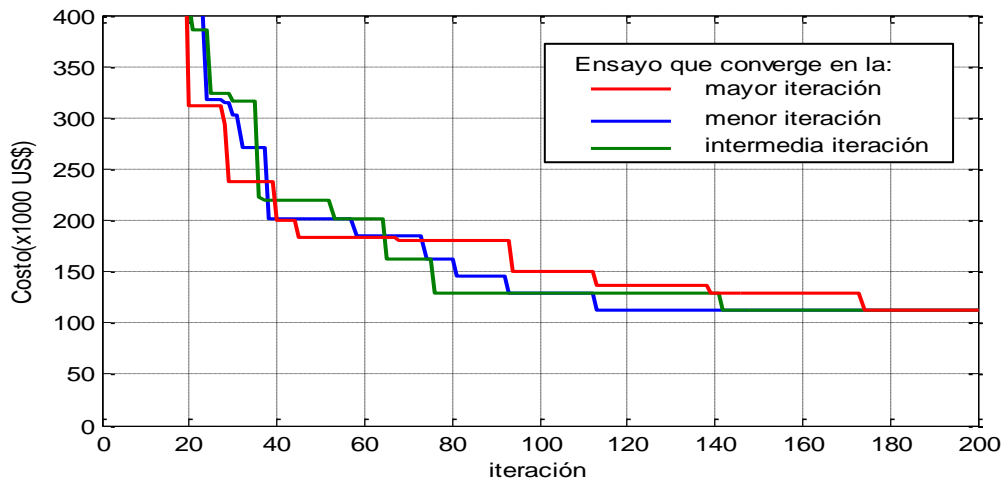


Figura 5.25: Convergencia del Algoritmo PBILc_1 para 3 de 10 ensayos con 120 individuos. Escenario IEEE_AC_A1.




Figura 5.26: Convergencia del Algoritmo PBILc_1 para 3 de 10 ensayos con 100 individuos. Escenario IEEE_AC_A2.

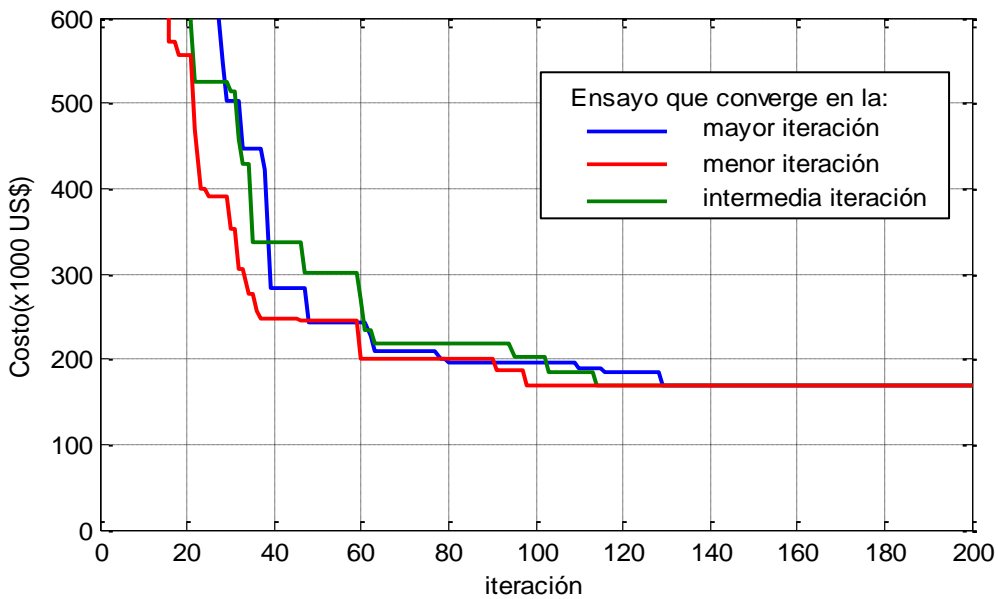


Figura 5.27: Convergencia del Algoritmo PBILc_1, para 100 individuos. Escenario IEEE_AC_A3 para 3 de 10 ensayos.




Figura 5.28: Convergencia del Algoritmo PBILc_2 para 3 de 10 ensayos con 120 individuos. Escenario IEEE_AC_A1.

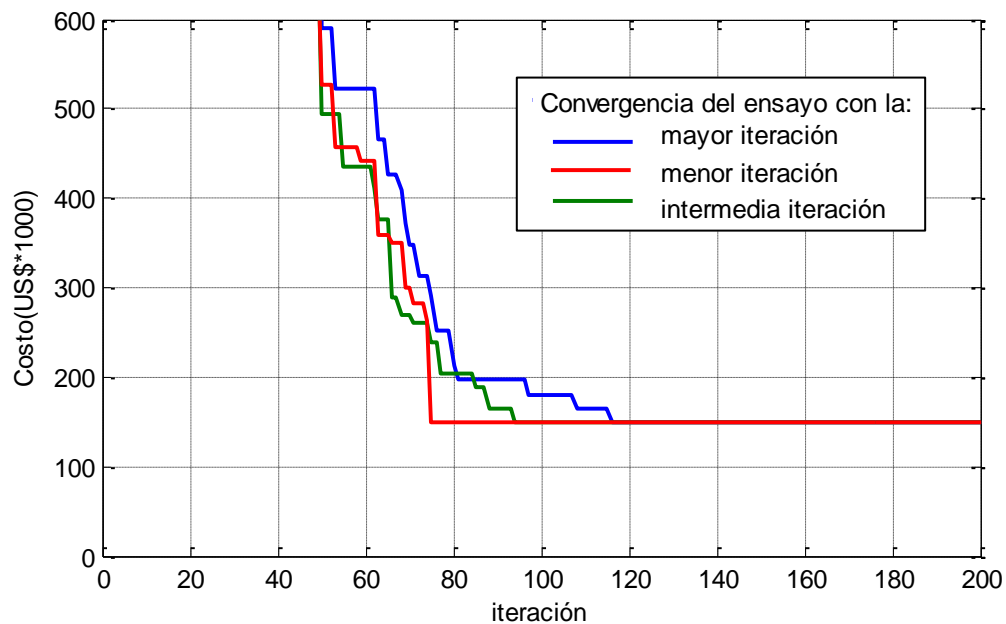


Figura 5.29: Convergencia del Algoritmo PBILc_2 para 3 de 10 ensayos con 100 individuos. Escenario IEEE_AC_A2.




Figura 5.30: Convergencia del Algoritmo PBILc_2, para 100 individuos. Escenario IEEE_AC_A3 para 3 de 10 ensayos.

Las Figuras 5.25 - 5.30 presentan el proceso de convergencia para el PBILc_1 y PBILc_2.

5.4 Escenarios de prueba con costo de pérdidas

Si se desea incorporar las pérdidas de potencia activa al problema del PET, se calcula las pérdidas de potencia activa para cada topología por medio de la función *get_loss* de Matpower y su herramienta de Flujo Óptimo de Potencia con el modelo de red AC (*runopf.m*), tal función permite calcular las pérdidas correspondientes a cada derecho de transmisión, posteriormente se suma las pérdidas para encontrar la pérdida total del sistema de prueba. La función objetivo a minimizar en este caso resulta en el costo total anualizado por inversión más el costo anualizado por pérdidas de potencia activa de acuerdo a la ecuación (3.50).



5.4.1 Sistema Garver con redespacho incluyendo costo de pérdidas

Para este sistema incluyendo costo de pérdidas se analizaron dos escenarios: el primero de ellos sin límite de reactivos, al cual lo denominamos Garver_AC_A1_P1. En este escenario se permiten tener reactivos ilimitados y esto se consigue colocando la compensación shunt con un costo de US\$ 0/Mvar. Se modelan los reactivos a través de los generadores artificiales.

Tabla 5.29: Parámetros para el cálculo de las pérdidas de potencia activa.

Parámetros	Garver_AC_A1_P1	
Costo unitario de la energía (λ) (US\$/MWh)	0.175	0.35
Factor de pérdidas f_{perd}	1	1
Factor de recuperación de capital CFR	1	1

Los parámetros necesarios para el cálculo de las pérdidas de potencia activa se detallan en la Tabla 5.29. Por simplificación, se considera que el factor de recuperación de capital y el factor de pérdidas anuales son iguales a la unidad. Para el costo unitario de la energía (λ) se consideran diferentes valores de tal forma de determinar cómo influye el costo de pérdidas en el plan final.

5.4.1.1 Escenario Garver_AC_A1_P1 aplicando el AGcr

El valor de la energía (λ) se considera un tanto de forma arbitraria de tal manera que coincida con la solución del caso Garver_AC_A1 sin incluir pérdidas ecuación (5.1), posteriormente se considera un escenario con el costo de la energía con un valor mayor al anterior (ver Tabla 5.29).

En la Tabla 5.30 se muestra los resultados de las topologías encontradas para el escenario Garver_AC_A1_P1, para diferentes valores de costo unitario de la energía (λ).



Para evaluar la incidencia del costo de pérdidas en el costo total de inversión, en la Tabla 5.30 también se incluye el costo que se obtendría minimizando únicamente el costo de inversión (adición de líneas), el cual corresponde al escenario Garver_AC_A1 (En este caso la configuración de mínimo costo corresponde a la expresión (5.1)). Adicionalmente, se establece que para hacer operativamente factibles los planes se requiere de compensación shunt en las siguientes barras: $r_{Q2} = 113.24$, $r_{Q4} = 93.60$, $r_{Q5} = 98.87$ Mvar, para el costo total anual de US\$ 183,500; mientras que para el costo total anual de US\$ 203.47 se requiere la compensación shunt en las siguientes barras: $r_{Q2} = 28.38$, $r_{Q4} = 125.90$, $r_{Q5} = 56.44$ Mva.

Tabla 5.30: Solución del problema de planeamiento para el escenario Garver_AC_A1_P1, aplicando el AGcr.

Sistema Garver con redespacho	Topología obtenida con costo de pérdidas		Topología obtenida sin costo de pérdidas	
Circuitos adicionados				
n_{1-2}	0	1	0	0
n_{2-3}	0	1	0	0
n_{3-5}	1	1	1	1
n_{2-6}	2	1	3	3
n_{4-6}	2	2	0	0
Costo unitario de la energía (λ)	0.175	0.35	0.175	0.35
Pérdidas totales (MW)	28.38	10.91	49.05	49.05
Costo de inversión anual (US\$ * 10^3)	140	170	110	110
Costo de pérdidas anual (US\$ * 10^3)	43.5	33.45	75.19	150.38
Costo total anual (US\$ * 10^3)	183.5	203.47	185.19	260.38

Para el caso en el que el costo de la energía $\lambda = 0,175$ el costo de inversión es de US\$ 110,000 para el sistema sin incluir pérdidas, menor al plan encontrado con costo de pérdidas (que es US\$ 140,000). El plan obtenido con costo de pérdidas puede resultar ventajoso durante la vida útil del sistema debido a que esta última presenta menores pérdidas de potencia (28MW). En la Figura 5.31 se muestra la influencia de los costos de las pérdidas para encontrar el plan mínimo, ya que cuando el costo de las líneas es de US\$ 110,000 (línea celeste) entre las iteraciones 70-86, las pérdidas totales en el sistema (49MW) son las mayores encontradas (línea verde), y por lo tanto en ese caso se tiene el mayor costo de pérdidas (línea roja), lo que hace que al final este plan aunque tiene el menor costo por adición de líneas no sea el plan mínimo, ya que el costo total (líneas y pérdidas) aún no es el mínimo encontrado. Por el contrario, el plan encontrado en la iteración 87 (≥ 87), con un costo de líneas US\$ 140,000 (línea celeste) es la mínima encontrada, ya que aunque no es la topología con menor pérdidas (28MW) en todo el proceso de optimización, el costo total (líneas y pérdidas) hacen que esta topología proporcione el plan mínimo encontrado (línea azul).

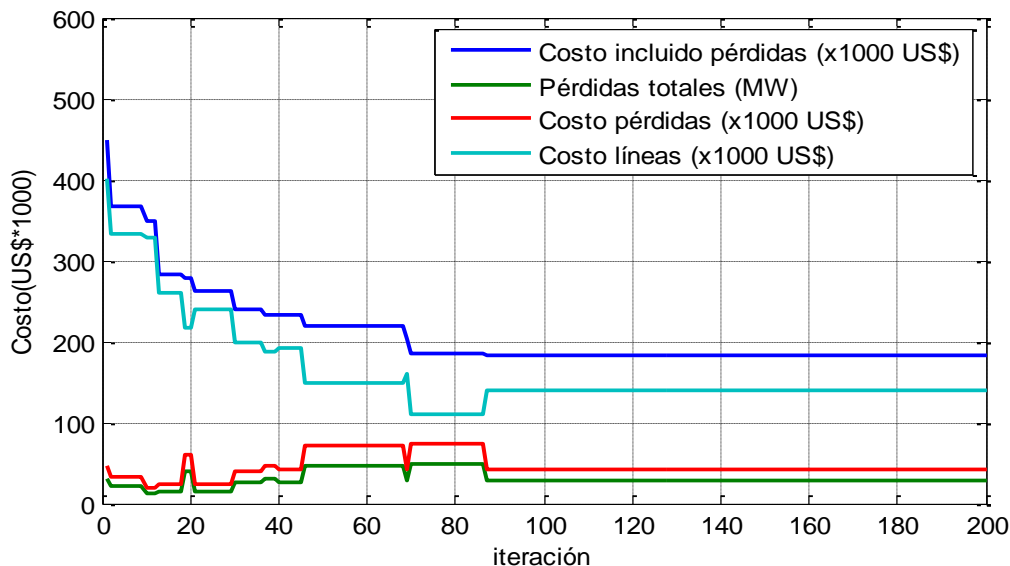


Figura 5.31: Influencia del costo de las pérdidas en el proceso de optimización. Escenario Garver_AC_A1_P1 con el AGcr, con costo de la energía $\lambda = 0.175$



En la Tabla 5.30 también se observa que al aumentar el costo de la energía, el mejor plan encontrado se obtiene añadiendo más circuitos al sistema, ya que a menor cantidad de líneas en un sistema mayor sobrecarga en las líneas y mayores pérdidas, y ya que las pérdidas están en base al costo de la energía, el plan mínimo encontrado determina que resulta ser más económico aumentar líneas para reducir el costo de pérdidas, siempre que se tiene elevados valores de costo unitario de la energía. Lo anteriormente indicado se puede ver en la Figura 5.32 donde por ejemplo, entre la iteración 110-127 se tiene un plan con un costo de líneas de transmisión de US\$ 150,000 (línea celeste), pero este aún no es el plan mínimo encontrado, ya que se tiene un elevado costo de pérdidas (línea roja) debido a que se tiene un alto valor de pérdidas totales del sistema (22MW) haciendo que el plan total (línea azul) con un costo de US\$ 220,000 (costo líneas y pérdidas) no sea el menor plan encontrado, por el contrario, el plan encontrado en la iteración 128 (≥ 128), con un costo por adición de líneas US\$ 170,000 (línea celeste) es el plan mínimo encontrado, con un plan que presenta menores pérdidas (línea verde) que entre las iteraciones 110-127 (10.9MW); y por lo tanto menor costo de pérdidas (US\$ 57,380), por lo que este plan llega a ser el mínimo encontrado con un costo total del plan de US\$ 203,400 (línea azul) que corresponde al costo de líneas y pérdidas. Lógicamente al optimizar el PET incluyendo costo de pérdidas en la función objetivo, el plan final dependerá del valor que tome el costo unitario de la energía.

Para determinar la característica de convergencia del AGcr se ha ejecutado 10 ensayos con una población de 80 individuos para un máximo de 200 iteraciones. El desempeño del AGcr se muestra en la Tabla 5.31.




Figura 5.32: Influencia del costo de las pérdidas en el proceso de optimización. Escenario Garver_AC_A1_P1 con el AGcr, con costo de energía de $\lambda = 0.35$

Tabla 5.31: Desempeño de Algoritmo AGcr. Escenario Garver_AC_A1_P1. Max. 200 iteraciones.

Población	80	80
Costo unitario de la energía (λ)	0.175	0.35
Tasa de éxito (%)	100	20
Iteraciones promedio	93	143
Desv. Est. iteraciones	25	21
Valor promedio F.O.	7,451	11,431
Valor mínimo (US\$x1,000)	183.5	203.4
Compensación shunt total	305.71	210.72
Tiempo computacional (s)	68.44	121.15

En las Figuras 5.33- 5.34 se presentan las características de convergencia del AGcr para el escenario de Garver_AC_A1_P1.




Figura 5.33: Convergencia del AGcr para 80 individuos. Escenario Garver_AC_A1_P1 para 3 de 10 ensayos, con costo de la energía de $\lambda = 0.175$.




Figura 5.34: Convergencia del AGcr para 80 individuos. Escenario Garver_AC_A1_P1 con costo de la energía de $\lambda = 0.35$.



5.4.1.2 Escenario Garver_AC_A1_P1 aplicando el algoritmo PBILc_1 y PBILc_2.

El valor de la energía se considera un tanto de forma arbitraria (ver Tabla 5.29) de tal manera que coincida con la solución del caso Garver_AC_A1 sin incluir pérdidas ecuación (5.1), posteriormente se considera un escenario con el costo de la energía del doble del valor anterior.

En la Tabla 5.32 se muestra los resultados de las topologías encontradas para el escenario Garver_AC_A1_P1.

Tabla 5.32: Solución del problema de planeamiento para el escenario Garver_AC_A1_P1 con el algoritmo PBILc_1 y PBILc_2.

Sistema Garver con redespacho	Topología obtenida con costo de pérdidas		Topología obtenida sin costo de pérdidas	
Circuitos adicionales				
n_{1-2}	0	1	0	
n_{2-3}	0	1	0	
n_{3-5}	1	1	1	
n_{2-6}	2	1	3	
n_{4-6}	2	2	0	
Costo unitario de la energía (λ)	0.175	0.35	0.175	0.35
Pérdidas totales (MW)	28.38	10.91	49.05	49.05
Costo de inversión anual (US\$ * 10³)	140	170	110	110
Costo de pérdidas anual (US\$ * 10³)	43.5	33.45	75.19	150.38
Costo total anual (US\$ * 10³)	183.5	203.47	185.19	260.38

Para evaluar el impacto en el costo total que tiene la adición del costo por pérdidas en la función objetivo, en la Tabla 5.32 también se incluye el costo que se

obtendría minimizando únicamente el costo de inversión (en este caso la configuración de mínimo costo sería la ecuación expresión (5.1)). Adicionalmente, se establece que para hacer operativamente factibles los planes se requiere de compensación shunt en las siguientes barras: $r_{Q2} = 113.24$, $r_{Q4} = 93.60$, $r_{Q5} = 98.87$ Mvar, para el costo total anual de US\$ 183,500; mientras que para el costo total anual de US\$ 203,470 se requiere la compensación shunt en las siguientes barras: $r_{Q2} = 28.38$, $r_{Q4} = 125.90$, $r_{Q5} = 56.44$ Mvar.




Figura 5.35: Influencia del costo de las pérdidas en el proceso de optimización. Escenario Garver_AC_A1_P1 con el algoritmo PBILc_1 para un costo unitario de la energía de $\lambda = 0.35$

En la Tabla 5.32 se observa que al aumentar el costo de la energía la topología de mínimo costo se obtiene añadiendo más circuitos al sistema, ya que con un mayor número de líneas se obtiene menores pérdidas totales en el sistema (ver Figura 5.35). Lo anteriormente indicado lógicamente dependerá del valor del costo unitario de la energía.



Para determinar el desempeño de los algoritmos PBILc_1 y PBILc_2 incorporando costo por pérdidas en la función objetivo se han ejecutado 10 ensayos con una población de 100 individuos para un máximo de 150 iteraciones. Los resultados se muestran en la Tabla 5.33, presentando un mejor desempeño el PBILc_2, con tasa de éxito del 100% en un numero de iteraciones promedio hasta alcanzar el menor valor encontrado de entre 56-58 iteraciones.

Tabla 5.33: Desempeño de los algoritmos PBILc_1 y PBILc_2. Escenario Garver_AC_A1_P1. Max. 150 iteraciones.

Algoritmo	PBILc_1	PBILc_1	PBILc_2	PBILc_2
Población	100	100	100	100
Costo unitario de la energía (λ)	0.175	0.35	0.175	0.35
Tasa de éxito (%)	90	50	50	60
Iteraciones promedio	40	100	48	52
Dev. Est. iteraciones	12	40	4	5
Valor promedio F.O.	4,066	10,020	4,860	5,216
Valor mínimo (US\$x1,000)	183.5	203.4	183.5	203.4
Compensación shunt total (Mvar)	305.71	210.72	305.71	210.72
Tiempo computacional (s)	78.57	87.2	41.95	53.34

Las Figuras 5.36 a 5.39 presentan las características de convergencia de los algoritmos PBILc_1 y PBILc_2 para el escenario Garver_AC_A1_P1 con los diferentes costos unitarios de la energía, y aunque el que mejor tasa de éxitos presenta es el PBILc_1, su rendimiento global es débil, debido a que para el caso de $\lambda = 0.35$ presenta un elevada iteraciones promedio hasta alcanzar el valor mínimo encontrado y su alta desviación estándar (40).




Figura 5.36: Convergencia del Algoritmo PBILc_1 para 100 individuos. Escenario Garver_AC_A1_P1 con costo unitario de la energía de $\lambda = 0.175$.




Figura 5.37: Convergencia del Algoritmo PBILc_1 para 100 individuos. Escenario Garver_AC_A1_P1 con costo unitario de la energía de $\lambda = 0.35$.




Figura 5.38: Convergencia del Algoritmo PBILc_2 para 100 individuos. Escenario Garver_AC_A1_P1 con costo unitario de la energía de $\lambda = 0.175$.




Figura 5.39: Convergencia del Algoritmo PBILc_2 para 100 individuos. Escenario Garver_AC_A1_P1 con costo unitario de la energía de $\lambda = 0.35$.



5.4.2 Sistema Garver sin redespacho incluyendo el costo de pérdidas

Para este sistema se analizó únicamente el escenario correspondiente a la generación de reactivos ilimitados con un costo de 0 \$/Mvar, al que lo llamaremos Garver_AC_B1_P1.

Los parámetros necesarios para el cálculo de las pérdidas de energía se detallan en la Tabla 5.34.

Tabla 5.34: Parámetros para el cálculo de las pérdidas de potencia activa con el escenario Garver_AC_B1_P1.

Parámetros	Valor	
Costo unitario de la energía (λ) (US\$/MWh)	0.175	0.35
Factor de pérdidas f_{perd}	1	1
Factor de recuperación de capital CFR	1	1

5.4.2.1 Escenario Garver_AC_B1_P1 aplicando el algoritmo PBILc_1 y PBILc_2.

Para este escenario también se considera valores distintos para el costo unitario de la energía (λ). El costo de la energía se considera un tanto de forma arbitraria de tal forma que coincida con la solución del escenario Garver_AC_B1 sin incluir pérdidas, posteriormente se considera un escenario con el costo de la energía de mayor valor. Las soluciones para este escenario se muestran en la Tabla 5.35.

Para evaluar el impacto en el costo total que tiene la adición del costo de pérdidas en la función objetivo, en la Tabla 5.35 también se incluye el costo que se obtendría minimizando únicamente el costo de inversión (en este caso la configuración de mínimo costo sería la ecuación expresión (5.3)). Adicionalmente, se establece que para hacer operativamente factibles los planes se requiere de compensación shunt en las siguientes barras: $r_{Q2} = 157.30$, $r_{Q4} = 126.26$, $r_{Q5} =$



109.66Mvar, para el costo total anual de US\$ 253,670; mientras que para el costo total anual de US\$291,890 se requiere la compensación shunt en las siguientes barras: $r_{Q2} = 85.70$, $r_{Q4} = 94.64$, $r_{Q5} = 76.87$ Mva.

Tabla 5.35: Solución del problema de planeamiento para el escenario Garver_AC_B1_P1 con el algoritmo PBILc_1 y PBILc_2.

Sistema Garver sin redespacho	Topología obtenida con costo de pérdidas		Topología obtenida sin costo de pérdidas	
	Circuitos adicionados			
n_{3-6}	1	1	1	
n_{2-6}	2	2	2	
n_{3-5}	1	0	1	
n_{5-6}	0	2	0	
n_{4-6}	2	2	2	
n_{1-2}	0	1	0	
Costo unitario de la energía (λ)	0.175	0.35	0.175	0.35
Pérdidas totales (MW)	42.84	20.83	42.84	42.84
Costo de inversión anual (US\$ * 10³)	188	228	188	188
Costo de pérdidas anual (US\$ * 10³)	65.67	63.89	65.67	131.34
Costo total anual (US\$ * 10³)	253.67	291.89	253.67	319.34

En la Tabla 5.35 se observa que al aumentar el costo de la energía la topología de mínimo costo se obtiene añadiendo más circuitos al sistema. Lo anteriormente indicado se puede ver en la Figura 5.40, ya que el plan mínimo se basa en encontrar una topología de menor costo de líneas (línea celeste), pero a su vez que las pérdidas no sean muy elevadas (línea verde), para que el costo por

perdidas no sea elevado, de tal manera que el costo total (línea azul) sea el menor posible.




Figura 5.40: Influencia del costo de las pérdidas en el proceso de optimización. Escenario Garver_AC_A2_P1 con el algoritmo PBILc_2 para un costo unitario de la energía de $\lambda = 0.35$.

Para determinar la característica de convergencia de los algoritmos PBILc_1 y PBILc_2 se ha ejecutado 10 ensayos para una población de 100 individuos con un máximo de 150 iteraciones. Los resultados obtenidos (Tabla 5.36) muestran que el PBILc_2 presenta el mejor desempeño debido a su elevada tasa de éxitos.

Tabla 5.36: Desempeño de Algoritmo PBILc. Escenario Garver_AC_B1_P1. Max. 150 iteraciones.

Algoritmo	PBILc_1	PBILc_1	PBILc_2	PBILc_2
Población	100	100	100	100
Costo unitario de la energía (λ)	0.175	0.35	0.175	0.35
Tasa de éxito (%)	50	60	100	90
Iteraciones promedio	62	72	63	64



Desv. Est. iteraciones	16	15	4	15
Valor promedio F.O.	6,280	7,216	6,330	6,677
Valor mínimo (US\$x1,000)	253.67	291.89	253.67	291.89
Compensación shunt total (Mvar)	393.22	257.21	393.22	257.21
Tiempo computacional (s)	66.58	77.24	55.4	56.28




Figura 5.41: Convergencia del Algoritmo PBILc_1 para 100 individuos. Escenario Garver_AC_B1_P1 con costo unitario de la energía de $\lambda = 0.35$.




Figura 5.42: Convergencia del Algoritmo PBILc_2 para 100 individuos. Escenario Garver_AC_B1_P1 con costo unitario de la energía de $\lambda = 0.35$.

Las Figuras 5.41 y 5.42 presentan las características de convergencia del algoritmo PBILc_1 y PBILc_2 para el escenario Garver_AC_B1_P1 con $\lambda = 0.35$.

5.4.3 Sistema IEEE con redespacho con costo de pérdidas aplicando el algoritmo PBILc_1 y PBILc_2

Para este sistema se analizó únicamente el escenario correspondiente a la generación de reactivos ilimitados con un costo de 0 \$/Mvar, al que lo llamaremos IEEE_AC_A1_P1.

Para este escenario se considera valores distintos para el costo unitario de la energía (ver Tabla 5.28). El valor de la energía se considera un tanto de forma arbitraria de tal forma que coincida con la solución del caso IEEE_AC_A1 sin incluir pérdidas, posteriormente se considera un escenario con el costo unitario de la energía mayor al anterior. Los parámetros necesarios para el cálculo de las pérdidas de potencia activa se detallan en la Tabla 5.37.

Tabla 5.37: Parámetros para el cálculo de las pérdidas de potencia activa con el escenario IEEE_AC_A1_P1.

Parámetros	Valor	
	Costo unitario de la energía (λ) (US\$/MWh)	0.005
Factor de pérdidas f_{perd}	1	1
Factor de recuperación de capital CFR	1	1

Las soluciones para este escenario se detallan en la Tabla 5.38. En la Tabla 5.38 se observa que al aumentar el costo de la energía la topología de mínimo costo se obtiene añadiendo más circuitos al sistema, lo cual reduce las pérdidas del sistema. Lo anteriormente indicado se puede ver en la Figura 5.43, ya que el plan mínimo se basa en encontrar una topología de menor costo de líneas (línea celeste), pero a su vez que las pérdidas no sean muy elevadas (línea verde), para que el costo de pérdidas también no sea elevado, de tal manera que el costo total (línea azul) sea el menor posible. Lógicamente el plan mínimo dependerá del valor del costo unitario de la energía, ya que si el valor es pequeño como por ejemplo $\lambda=0.005$, el costo por pérdidas no presenta mayor influencia en la topología final, por lo que el plan final es similar al caso donde no se considera el costo por pérdidas.

Tabla 5.38: Solución del problema de planeamiento para el escenario IEEE_AC_A1_P1 con el algoritmo PBILc_1 y PBILc_2.

Sistema IEEE sin redespacho	Sistema con costo de pérdidas		Sistema sin costo de pérdidas
Circuitos adicionales			
n_{1-2}	1	2	1
n_{6-10}	1	2	1
n_{7-8}	2	2	2
n_{13-14}	1	1	1



Costo unitario de la energía (λ)	0.005	0.05	0.005	0.05
Pérdidas totales (MW)	168.54	97.506	186.69	168.54
Costo de inversión anual (US\$ * 10³)	51	57	51	51
Costo de pérdidas anual (US\$ * 10³)	7.38	42.707	7.38	73.82
Costo total anual (US\$ * 10³)	58.3823	99.7078	58.3823	124.82

Para determinar la característica de convergencia de los algoritmos PBILc_1 y PBILc_2 se han ejecutado 10 ensayos para una población de 80 individuos con un máximo de 200 iteraciones. Los resultados se muestran en la Tabla 5.39.

La Figura 5.44 y 5.45 presentan las características de convergencia del PBILc_1 y PBILc_2 para el escenario IEEE_AC_A1_P1 para un costo de energía $\lambda = 0.05$.




Figura 5.43: Influencia del costo por pérdidas en el proceso de optimización. Escenario IEEE_AC_A1_P1 con el algoritmo PBILc_2. Costo de energía $\lambda = 0.05$.

Tabla 5.39: Desempeño de Algoritmo PBILc_1 y PBILc_2. Escenario IEEE_AC_A1_P1. Max. 200 iteraciones.

Algoritmo	PBILc_1	PBILc_1	PBILc_2	PBILc_2
Población	80	80	80	80
Costo unitario de la energía (λ)	0.005	0.05	0.005	0.05
Tasa de éxito (%)	90	10	60	100
Iteraciones promedio	151	116	82	84
Desv. Est. iteraciones	39	22	5	7
Valor promedio F.O.	12,124	9,336	4,920	6,720
Valor mínimo (US\$x1,000)	58.382	99.707	58.382	99.707
Tiempo computacional (s)	169.87	130.5	92.76	99.12




Figura 5.44: Convergencia del Algoritmo PBILc_2 para 80 individuos. Escenario IEEE_AC_A1_P1 con costo unitario de la energía de $\lambda = 0.05$.




Figura 5.45: Convergencia del Algoritmo PBILc_1 para 80 individuos. Escenario IEEE_AC_A1_P1 con costo unitario de la energía de $\lambda = 0.05$.



Los resultados para los diferentes escenarios prueban que el sistema con mejor desempeño para resolver el problema del PET es el PBILc_2, debido a que presenta la mayor tasa de éxitos para los diferentes escenarios y con el más bajo requerimiento de evaluaciones de la función objetivo, y un aspecto importante es que para el sistema IEEE con redespacho sin considerar pérdidas se obtuvo un mejor valor al encontrado en las referencias [2].



CAPÍTULO 6

CONCLUSIONES Y RECOMENDACIONES

6.1 Conclusiones

Se implementó una nueva técnica de optimización para resolver el PET problema de planeamiento de la expansión del sistema de transmisión estático a largo plazo usando el modelo AC con ecuaciones de flujo de carga no lineales.

La sintonización de los parámetros de control para cada EDAs resulta ser crucial, dado que, un mal ajuste de los mismos puede hacer que el algoritmo trabaje de manera ineficiente. La sintonización de los parámetros es un proceso de prueba y error, ya que los valores de los mismos dependerán del problema a tratar.

Un aporte importante de esta tesis es la incorporación del costo por pérdidas en la función objetivo, con el fin de obtener costos y planes de expansión más realistas. El plan final incluyendo costo por pérdidas dependerá fundamentalmente del valor de costo unitario de la energía, ya que se puede obtener un importante ahorro durante la vida útil de la red, aunque esto implique un mayor costo de inversión.

Los resultados obtenidos son similares a los encontrados en la literatura especializada.

De acuerdo con los resultados obtenidos, se puede observar que de los algoritmos implementados (AGc, AGcr, PBILc_1 y PBILc_2), el algoritmo PBILc_2 es el que mejor desempeño presenta (en cuanto a la tasa de éxitos y el número de iteraciones promedio) para los distintos escenarios analizados.



6.2 Recomendaciones y trabajos futuros

Aunque los EDAs proporcionan soluciones relevantes (pero con una baja tasa de éxitos) en trabajos futuros se podría incluir alguna técnica de mutación a los individuos repetidos en cada generación, para aumentar el desempeño de esta meta-heurística.

Puede aplicarse otra variación del AGc (dominio binario) al problema de PET, como la incorporación de elitismo con mutación (AGcEM) que de acuerdo con [57] converge más rápidamente que el AGc clásico, y que proporciona soluciones de mejor calidad; también, se puede introducir otra forma de actualización del vector de probabilidades, similar al AGc clásico, pero esta vez el individuo ganador competirá con el resto de individuos generados en cada generación [52].

Sería importante formular el problema del PET incluyendo costo por pérdidas en la función objetivo y tomando en consideración criterios de seguridad frente a contingencias (N-1).

También sería interesante aplicar la metodología planteada y los algoritmos propuestos para resolver sistemas de prueba de mayor tamaño como el sistema de 118 nodos.



Anexo A

Datos del Sistema Garver de 6 nodos

Este sistema tiene 6 nodos y 15 líneas candidatas, con una demanda total de 760MW de potencia activa, 152Mvar de demanda de potencia reactiva y una potencia máxima de generación de 1,100MW. El número máximo de circuitos permitidos por derecho de transmisión son 5. La topología inicial del sistema posee 6 líneas de transmisión (ver Figura 5.1).

En la Tabla A.1 se dan los datos de generación y demanda y en la Tabla A.2 se dan los datos de las líneas.

Tabla A.1: Datos de las líneas del sistema Garver

Nodo	$P_G^{min}(MW)$	$P_G(MW)$	$P_G^{max}(MW)$	$Q_G^{min}(MVAR)$	$Q_G(MVAR)$	$Q_G^{max}(MVAR)$
1	0	50	150	-10	40	48
2	0	0	0	0	0	0
3	0	165	360	-10	100	101
4	0	0	0	0	0	0
5	0	0	0	0	0	0
6	0	545	600	-10	150	183

Tabla A.2: Datos de las líneas del sistema Garver

Desde i	Hasta j	r (pu)	x (pu)	c_{ij} (10^3 US\$)	n_{ij}^0
1	2	0.040	0.40	40	1
1	3	0.038	0.38	38	0
1	4	0.060	0.60	60	1
1	5	0.020	0.20	20	1
1	6	0.068	0.68	68	0
2	3	0.020	0.20	20	1
2	4	0.040	0.40	40	1
2	5	0.031	0.31	31	0
2	6	0.030	0.30	30	0
3	4	0.059	0.59	59	0
3	5	0.020	0.20	20	1



3	6	0.048	0.48	48	0
4	5	0.063	0.63	63	0
4	6	0.030	0.30	30	0
5	6	0.061	0.61	61	0



Anexo B

Datos del Sistema IEEE de 24 nodos

Este sistema consta de 24 nodos y 41 líneas candidatas, de las cuales 7 son ramas nuevas y en 34 de ellas existen circuitos en la configuración inicial (ver Figura 5.22). El número máximo de circuitos permitidos por derecho de transmisión son 5.

En la Tabla B.1 se dan los datos de generación y demanda en los nodos. Los datos de las líneas se dan en la Tabla B.2.

Tabla B.1: Datos de generación y demanda del sistema IEEE de 24 nodos

Nodo	$P_G^{min}(MW)$	$P_G(MW)$	$P_G^{max}(MW)$	$Q_G^{min}(MVAR)$	$Q_G(MVAR)$	$Q_G^{max}(MVAR)$
1	0	576	576	-150	0	240
2	0	576	576	-150	0	240
3	0	0	0	0	0	0
4	0	0	0	0	0	0
5	0	0	0	0	0	0
6	0	0	0	-300	0	0
7	0	900	900	0	0	540
8	0	0	0	0	0	0
9	0	0	0	0	0	0
10	0	0	0	0	0	0
11	0	0	0	0	0	0
12	0	0	0	0	0	0
13	0	1457	1773	0	0	720
14	0	0	0	-150	0	600
15	0	325	645	-150	0	330
16	0	282	465	-150	0	240
17	0	0	0	0	0	0
18	0	603	1200	-150	0	600
19	0	0	0	0	0	0
20	0	0	0	0	0	0
21	0	951	1200	-150	0	600
22	0	900	900	-180	0	288
23	0	1980	1980	-375	0	930



24	0	0	0	0	0	0
----	---	---	---	---	---	---

Tabla B.2: Datos de las líneas del sistema IEEE de 24 nodos

Desde i	Hasta j	r (pu)	x (pu)	b (pu)	c_{ij} (10^3 US\$)	n_{ij}^0
1	2	0.0026	0.0139	0.4611	3	1
1	3	0.0546	0.2112	0.0572	55	1
1	5	0.0218	0.0845	0.0229	22	1
2	4	0.0328	0.1267	0.0343	33	1
2	6	0.0497	0.1920	0.0520	50	1
3	9	0.0308	0.1190	0.0322	31	1
3	24	0.0023	0.0839	0.0000	50	1
4	9	0.0268	0.1037	0.0281	27	1
5	10	0.0228	0.0883	0.0239	23	1
6	10	0.0139	0.0605	24.590	16	1
7	8	0.0159	0.0614	0.0166	16	1
8	9	0.0427	0.1651	0.0447	43	1
8	10	0.0427	0.1651	0.0447	43	1
9	11	0.0023	0.0839	0.0000	50	1
9	12	0.0023	0.0839	0.0000	50	1
10	11	0.0023	0.0839	0.0000	50	1
10	12	0.0023	0.0839	0.0000	50	1
11	13	0.0061	0.0476	0.0999	66	1
11	14	0.0054	0.0418	0.0879	58	1
12	13	0.0061	0.0476	0.0999	66	1
12	23	0.0124	0.0966	0.2030	134	1
13	23	0.0111	0.0865	0.1818	120	1
14	16	0.0050	0.0389	0.0818	54	1
15	16	0.0022	0.0173	0.0364	24	1
15	21	0.0063	0.0490	0.1030	68	2
15	24	0.0067	0.0519	0.1091	72	1
16	17	0.0033	0.0259	0.0545	36	1
16	19	0.0030	0.0231	0.0485	32	1
17	18	0.0018	0.0144	0.0303	20	1
17	22	0.0135	0.1053	0.2212	146	1
18	21	0.0033	0.0259	0.0545	36	2
19	20	0.0051	0.0396	0.0833	55	2
20	23	0.0028	0.0216	0.0455	30	2



21	22	0.0087	0.0678	0.1424	94	1
1	8	0.0348	0.1344	0.0000	35	0
2	8	0.0328	0.1267	0.0000	33	0
6	7	0.0497	0.1920	0.0000	50	0
13	14	0.0057	0.0447	0.0000	62	0
14	23	0.0080	0.0620	0.0000	86	0
16	23	0.0105	0.0822	0.0000	114	0
19	23	0.0078	0.0606	0.0000	84	0



Referencias Bibliográficas

- [1] A. R. Gallego Rendón, A. Escobar Zuluaga, R. A. Romero Lázaro, and A. Monticelli, "Planeamiento de la Expansión de Sistemas de Transmisión de Energía Eléctrica," Universidad Tecnológica de Pereira.
- [2] S. P. Torres and C. A. Castro, "Specialized Differential Evolution Technique to Solve the Alternating Current Model Based Transmission Expansion Planning Problem," *Int. J. Electr. Power Energy Syst.*, vol. 68, pp. 243–251, 2015.
- [3] P. B. Callejas, C. T. Mancera, and G. L. Bayona, "Planeamiento Estático de la Expansión de Sistemas de Transmisión: Comparación de Algoritmos Genéticos, Búsqueda Tabú y Enumeración Truncada," *Rev. UIS Ing.*, vol. 2, no. 2, 2011.
- [4] S. P. Torres, C. A. Castro, and M. Rolando, "Comparison of Particle Swarm Based Meta- heuristics for the Electric Transmission Network Expansion Planning Problem," *Power and Energy Society General Meeting*, pp. 1–7, 2011.
- [5] S. P. Torres and C. A. Castro, "Parallel Particle Swarm Optimization Applied to the Static Transmission Expansion Planning Problem," *Latin America Conference and Exposition (T&D-LA)*, pp. 1–6, 2012.
- [6] L. A. Gallego and A. E. Zuluaga, "Planeamiento de la Expansión de Sistemas de Transmisión de Energía Eléctrica Considerando Contingencias," *Sci. Tech.*, vol. 1, no. 30, 2006.
- [7] W. E. Barreto, S. P. Torres, S and C. A. Castro, "Study of Particle Swarm Optimization Variations Applied to Transmission Expansion Planning," *PowerTech (POWERTECH), 2013 IEEE Grenoble*, pp. 1–6, 2013.



- [8] A. A. Domínguez, R. G. Rendón, and A. Escobar, "Propuesta de Reducción de Modelo Para el Problema de Planeamiento de la Expansión de la Transmisión," *Sci. Tech.*, vol. 3, no. 49, pp. 7–13, 2011.
- [9] L. M. E. Vargas, A. D. Gomez, J. N. M. Gutierrez, y A. H. E. Zuluaga, "Planeamiento de Sistemas de Transmisión de Energía Eléctrica Usando AMPL," *Sci. Tech.*, vol. 2, no. 51, pp. 22–27, 2012.
- [10] A. C. Rueda, "Planeamiento de la Expansión de Sistemas de Transmisión con Incertidumbre en la Demanda e Incorporando Pérdidas Usando Búsqueda Tabú," Diss. Dissertação (Mestrado)-Universidad Tecnológica de Pereira, 2008.
- [11] C. Franco, "Distribución de Costos Considerando Cargos por Uso en el Proceso de la Expansión de Sistemas de Transmisión Aplicando Teoría de Juegos," Tesis de Maestría, Universidad Tecnológica de Pereira, 2003.
- [12] S. P. Torres and C. A. Castro, "Expansion planning for smart transmission grids using AC model and shunt compensation," *IET Gener. Transm. Distrib.*, vol. 8, no. 5, pp. 966–975, 2014.
- [13] S. P. Torres, R. A. de Araujo, C. A. Castro, and J. Pissolato, "Security constrained transmission expansion planning for smart transmission grids based on the AC network model," in *Transmission & Distribution Conference and Exposition-Latin America (PES T&D-LA), 2014 IEEE PES*, pp. 1–6, 2014.
- [14] J. A. Taylor and F. S. Hover, "Conic ac transmission system planning," *IEEE Trans. Power Syst.*, vol. 28, no. 2, pp. 952–959, 2013.
- [15] L. A. Gallego Pareja, R. A. Romero, and J. M. López Lezama, "Planeamiento de la Expansión de Sistemas de Transmisión Considerando Contingencias y Demanda Incierta," *Revista Facultad de Ingeniería*, pp. 188–200, 2009.
-



- [16] R. Romero, A. Monticelli, A. Garcia, and S. Haffner, "Test Systems and Mathematical Models for Transmission Network Expansion Planning," *IEE Proceedings-Generation, Transm. Distrib.*, vol. 149, no. 1, pp. 27–36, 2002.
- [17] L. Bahiense, G. C. Oliveira, M. Pereira, and S. Granville, "A Mixed Integer Disjunctive Model for Transmission Network Expansion," *Power Syst. IEEE Trans.*, vol. 16, no. 3, pp. 560–565, 2001.
- [18] R. Mínguez, R. García-Bertrand and J. M. Arroyo, "On the Solution of Large-Scale Robust Transmission Network Expansion Planning under Uncertain Demand and Generation Capacity," *arXiv preprint arXiv*, pp. 1–8, 2016.
- [19] R. Mínguez and R. García-Bertrand, "Robust Transmission Network Expansion Planning in Energy Systems: Improving Computational Performance," *European Journal of Operational Research*, p. 21-32, 2016.
- [20] J. I. R. Rodriguez, D. M. Falcao, G. N. Taranto, and H. L. S. Almeida, "Short-term Transmission Expansion Planning by a Combined Genetic Algorithm and Hill-Climbing Technique," in *Intelligent System Applications to Power Systems, 2009. ISAP'09. 15th International Conference on*, pp. 1–6, 2009.
- [21] J. Rodríguez, D. Camac, M. Uribe, D. Falcão, and G. Taranto, "Expansión del Sistema de Transmisión Eléctrico Nacional Utilizando Algoritmos Genéticos," 2011.
- [22] C. A. C. Flórez, G. A. C. Muñoz, R. A. Bolaños, and M. G. Echeverri, "Análisis Comparativo de Técnicas Metaheurísticas Para Resolver el Planeamiento de la Transmisión," *epsilon*, no. 22, pp. 81–105, 2014.
- [23] H. Seifi and M. S. Sepasian, *Electric Power System Planning: Issues, Algorithms and Solutions*. Springer Science & Business Media, 2011.
- [24] T. Gonen, *Modern Power System Analysis*. CRC Press, 2013.



- [25] R. E. Aguirre Proaño, “Cursos, Seminarios de Energía Eléctrica,” 2010.
- [26] J. A. Sánchez Rodríguez, “Planificación Estática de la Red Eléctrica de Transporte Mediante Algoritmos Genéticos,” 2014.
- [27] J. Schlabbach and K.-H. Rofalski, “Power System Engineering: Planning, Design, and Operation of Power Systems and Equipment, ” John Wiley & Sons, 2008.
- [28] R. Bent, G. L. Toole, and A. Berscheid, “Transmission Network Expansion Planning with Complex Power Flow Models,” *Power Syst. IEEE Trans.*, vol. 27, no. 2, pp. 904–912, 2012.
- [29] R. Bent, C. Coffrin, R. R. E. Gumucio, and P. Van Hentenryck, “Transmission Network Expansion Planning: Bridging the gap Between ac Heuristics and dc Approximations,” in *Power Systems Computation Conference (PSCC)*, pp. 1–8, 2014.
- [30] M. J. Rider, A. V Garcia, and R. Romero, “Power System Transmission Network Expansion Planning Using AC Model,” *Gener. Transm. Distrib. IET*, vol. 1, no. 5, pp. 731–742, 2007.
- [31] J. A. Taylor and F. S. Hover, “Linear relaxations for transmission system planning,” *IEEE Transactions on Power Systems*, vol. 26, no 4, pp. 2533–2538, 2011.
- [32] L. L. Garver, “Transmission Network Estimation Using Linear Programming,” *IEEE Trans. Power Appar. Syst.*, no. 7, pp. 1688–1697, 1970.
- [33] N. Alguacil, A. L. Motto, and A. J. Conejo, “Transmission Expansion Planning: a Mixed-Integer LP Approach,” *Power Syst. IEEE Trans.*, vol. 18, no. 3, pp. 1070–1077, 2003.
- [34] M. A. Farrag and M. M. El-Metwally, “New Method for Transmission Planning



- Using Mixed-Integer Programming,” in *Generation, Transmission and Distribution, IEE Proceedings C*, vol. 135, no. 4, pp. 319–323, 1988.
- [35] A. Escobar, “Planeamiento dinámico de la Expansión de Sistemas de Transmisión Usando Algoritmos Combinatoriales,” *Univ. Tecnológica Pereira, tesis Maest.*, 2002.
- [36] H. K. Youssef and R. Hackam, “New Transmission Planning Model,” *IEEE Trans. Power Syst.*, vol. 4, no. 1, pp. 9–18, 1989.
- [37] J. P. U. WESS, “Planificación de la Expansión de Sistemas Eléctricos Vía Descomposición de Benders,” *Pontificia Universidad Católica de Chile*, 1995.
- [38] R. Romero and A. Monticelli, “A Hierarchical Decomposition Approach For Transmission Network Expansion Planning,” *Power Syst. IEEE Trans.*, vol. 9, no. 1, pp. 373–380, 1994.
- [39] S. Haffner, A. Monticelli, A. Garcia, and R. Romero, “Specialised Branch-and-Bound Algorithm For Transmission Network Expansion Planning,” in *Generation, Transmission and Distribution*, vol. 148, no. 5, pp. 482–488, 2001.
- [40] E. N. Asada, E. Carre, R. Romero, and A. V Garcia, “A Branch-and-Bound Algorithm For the Multi-stage Transmission Expansion Planning,” in *Power Engineering Society General Meeting. IEEE*, pp. 171–176, 2005.
- [41] R. A. Jabr, “Optimization of AC Transmission System Planning,” *IEEE Transactions on Power Systems*, vol. 28, no 3, p. 2779-2787, 2013.
- [42] C. Coffrin, H. Hijazi, P. Van Hentenryck, and O. C. Jan, “Strengthening the SDP Relaxation of AC Power Flows with Convex Envelopes , Bound Tightening , and Lifted Nonlinear Cuts,” *IEEE Transactions on Power Systems*, pp. 1–26, 2016.



- [43] A. H. Escobar, R. A. Gallego, and R. Romero, "Multistage and Coordinated Planning of the Expansion of Transmission Systems," *Power Syst. IEEE Trans.*, vol. 19, no. 2, pp. 735–744, 2004.
- [44] T. S. Chung, K. K. Li, G. J. Chen, J. D. Xie, and G. Q. Tang, "Multi-Objective Transmission Network Planning by a Hybrid GA Approach With Fuzzy Decision Analysis," *Int. J. Electr. Power Energy Syst.*, vol. 25, no. 3, pp. 187–192, 2003.
- [45] A. M. L. da Silva, L. S. Rezende, L. M. Honório, and L. A. F. Manso, "Performance Comparison of Metaheuristics to Solve the Multi-stage Transmission Expansion Planning Problem," *IET Gener. Transm. Distrib.*, vol. 5, no. 3, pp. 360–367, 2011.
- [46] H. Mori and Y. Sone, "A Parallel Tabu Search Based Approach to Transmission Network Expansion Planning," in *Power Tech Proceedings, 2001 IEEE Porto*, vol. 2, 2001.
- [47] R. A. Bolaños, C. A. Correa, and M. G. Echeverri, "Optimización Por Colonia de Hormigas Aplicada al Problema de Planeamiento de la Transmisión," *Rev. Ing.*, no. 30, pp. 33–40, 2009.
- [48] J. J. Grefenstette, "Optimization of Control Parameters For Genetic Algorithms," *IEEE Trans. Syst. Man. Cybern.*, vol. 16, no. 1, pp. 122–128, 1986.
- [49] D. Simon, *Evolutionary Optimization Algorithms*. John Wiley & Sons, 2013.
- [50] J. A. L. Pedro Larrañaga, *Estimation of Distribution Algorithms: A New Tool for Evolutionary Computation*. Springer Science & Business Media, 2001.
- [51] A. Yazici and C. Sener, *Computer and Information Sciences--ISCIS 2003: 18th International Symposium, Antalya, Turkey, November 3-5, 2003*.



Proceedings, vol. 2869. Springer, 2003.

- [52] G. R. Harik, F. G. Lobo, and D. E. Goldberg, “The Compact Genetic Algorithm,” *Evol. Comput. IEEE Trans.*, vol. 3, no. 4, pp. 287–297, 1999.
- [53] E. Mininno, F. Cupertino, and D. Naso, “Real-valued Compact Genetic Algorithms For Embedded Microcontroller Optimization,” *IEEE Trans. Evol. Comput.*, vol. 12, no. 2, pp. 203–219, 2008.
- [54] M. Sebag and A. Ducoulombier, “Extending Population-Based Incremental Learning to Continuous Search Spaces,” in *International Conference on Parallel Problem Solving from Nature*, 1998, pp. 418–427.
- [55] R. D. Zimmerman, C. E. Murillo-Sánchez, and R. J. Thomas, “MATPOWER: Steady-State Operations, Planning, and Analysis Tools for Power Systems Research and Education,” *Power Syst. IEEE Trans.*, vol. 26, no. 1, pp. 12–19, 2011.
- [56] H. Wang, C. E. Murillo-Sanchez, R. D. Zimmerman, and R. J. Thomas, “On Computational Issues of Market-Based Optimal Power Flow,” *IEEE Trans. Power Syst.*, vol. 22, no. 3, pp. 1185–1193, 2007.
- [57] A. León Javier, “Diseño e Implementación en Hardware de un Algoritmo Bioinspirado,” Instituto Politécnico Nacional. Centro de Investigación en Computación, 2009.