

Optimización de Tensión en Redes de Distribución utilizando Técnicas Evolutivas

por

Francisco Gil Montoya

Tesis Doctoral para la obtención del grado de doctor

por la

Universidad de Granada

Directores:

Antonio Espín Estrella

Consolación Gil Montoya

Raúl Baños Navarro

Universidad de Granada, España, 2009

Editor: Editorial de la Universidad de Granada
Autor: Francisco Gil Montoya
D.L.: GR. 2058-2009
ISBN: 978-84-692-2258-4

UNIVERSIDAD DE GRANADA



OPTIMIZACIÓN DE TENSIÓN EN REDES DE
DISTRIBUCIÓN UTILIZANDO TÉCNICAS
EVOLUTIVAS

TESIS DOCTORAL

Francisco Gil Montoya

2009

D. Antonio Espín Estrella, Profesor Titular de Universidad del Departamento de Ingeniería Civil de la Universidad de Granada, D. Consolación Gil Montoya, Profesora Titular de Universidad del Departamento de Arquitectura de Computadores y Electrónica de la Universidad de Almería y D. Raúl Baños Navarro, Doctor Investigador del departamento de Arquitectura de Computadores y Electrónica de la Universidad de Almería.

CERTIFICAN

Que el trabajo de investigación que se recoge en la presente Memoria, titulada “Optimización de Tensión en Redes de Distribución utilizando Técnicas Evolutivas” presentada por D. Francisco Gil Montoya para optar al grado de Doctor por la Universidad de Granada, ha sido realizado en su totalidad bajo nuestra dirección en nuestros departamentos de la Universidad de Granada y Almería.

Granada a 12 de Febrero de 2.009

Fdo.: Antonio Espín Estrella

Fdo.: Consolación Gil Montoya

Fdo.: Raúl Baños Navarro

Agradecimientos

Mi más sincero agradecimiento a todos aquellos que habéis estado junto a mí en este largo trayecto de mi vida.

Especialmente quiero agradecer a mis directores, Antonio, Conso y Raúl, su valía personal y profesional la cual ha servido para guiar el trabajo en la buena dirección. Su apoyo ha sido incesante y su conocimiento en las diferentes materias ha sido excelente. Todo ello ha permitido obtener una tesis de muy alta calidad. Gracias.

También tengo palabras de agradecimiento para los principales sufridores de todo esta historia: mi familia. Mi mujer Fely, mis tres hijos Paquito, Manuel y María, mis hermanos Manuel, Mari y Conso (doblemente). Por supuesto, mi madre Dolores que siempre estuve a la mira de que no me despistara un ápice del buen camino...

Mi inseparable e infatigable compañero de faena, Julio, también ha contribuido enormemente a que este trabajo salga adelante en tiempo y forma. Alfredo por su colaboración, así como sus apreciaciones más que relevantes. Fernando, por sus comentarios y consejos en el planteamiento inicial de la Tesis.

Agradecer también el apoyo de la UAL, la Junta de Andalucía y el Ministerio de Educación, los cuales me han ayudado a través de su financiación económica.

Dedicatoria

Dedicado a mi padre, Manuel Gil, que seguro estará viendo lo que a él tanto le gustaba: **el trabajo bien hecho de sus hijos.**

Índice general

Capítulo 1	23
Introducción y Objetivos	23
1.1 Planteamiento del problema.....	23
1.2 Objetivos de la tesis	27
1.3 Estructura de la Tesis	30
Capítulo 2.....	33
Optimización mediante algoritmos evolutivos.....	33
2.1 Técnicas clásicas de optimización.....	34
2.1.1 Optimización lineal.....	34
2.1.2 Complejidad Computacional.....	37
2.1.3 Heurísticas	39
2.1.4 Dificultades y complicaciones	40
2.2 Técnicas evolutivas	42
2.2.1 Programación evolutiva.....	44
2.2.2 Estrategias evolutivas.....	47
2.2.3 Algoritmos genéticos.....	50

2.2.4	Diferencias, ventajas e inconvenientes de las técnicas evolutivas respecto de las tradicionales.....	52
2.3	Algoritmos genéticos.....	54
2.3.1	Representación.....	58
2.3.2	Población Inicial.....	61
2.3.3	Función objetivo y aptitud.....	61
2.3.4	Selección.....	64
2.3.5	Cruce o Recombinación.....	73
2.3.6	Mutación.....	79
2.3.7	Elitismo.....	79
2.3.8	Manejo de restricciones e individuos no factibles.....	81
2.4	Algoritmos Multi-objetivo.....	82
2.4.1	Introducción a la optimización multi-objetivo basada en frentes de Pareto.....	83
2.4.2	Técnicas heurísticas de optimización multi-objetivo.....	87
Capítulo 3	97
Optimización de tensiones	97
3.1	Estado del arte.....	97
3.1.1	Sistemas reguladores de tensión de uso cotidiano.....	98
3.1.2	Propuestas tradicionales para mejora de la regulación de tensión.....	103
3.1.3	Uso de técnicas evolutivas.....	115
3.1.4	Uso de técnicas convencionales.....	119
Capítulo 4	123
Aplicación de algoritmos genéticos a la optimización de tensiones	123
4.1	Estructura y características del algoritmo genético desarrollado.....	125

4.1.1	Representación.....	129
4.1.2	Medida de calidad o “ <i>fitness</i> ”.....	132
4.1.3	Generación de la población inicial	133
4.1.4	Generación de descendientes.....	135
4.2	Casos de estudio.....	141
4.2.1	Algoritmo genético monoetapa	142
4.2.2	Algoritmo genético multietapa	179
Capítulo 5.....		233
Aplicación de algoritmos multi-objetivo a la optimización de tensiones		233
5.1	Estructura y características de los algoritmos multi-objetivo desarrollados.	235
5.1.1	Técnica PAES (Pareto Archived Evolution Strategy).....	236
5.1.2	MultiStart-PAES	240
5.1.3	Annealing-PAES.....	242
5.1.4	Tabu-PAES	246
5.1.5	Hibridación de Annealing y Tabu-PAES.....	249
5.2	Casos de estudio.....	251
5.2.1	Red IEEE30.....	252
5.2.2	Red RTS.....	257
5.3	Métricas implementadas.....	262
5.3.1	Métrica de cobertura	264
5.3.2	Métrica de hipervolumen	264
5.3.3	Aplicación de métricas a redes en estudio	265
Capítulo 6.....		275
Conclusiones, aportaciones y líneas futuras de trabajo.....		275
6.1	Resumen y Conclusiones	275

6.2	Aportaciones realizadas.....	278
6.3	Líneas futuras de investigación	280
6.4	Publicaciones al amparo de la tesis.....	281
Apéndice A Tablas de entrada de datos		283
A.1	Datos de entrada para las redes en estudio	284
A.1.1	Red IEEE30.....	284
A.1.2	Red IEEE57.....	286
A.1.3	Red RTS.....	290
Apéndice B Fundamentos matemáticos de los algoritmos genéticos		295
B.1	Teorema de los esquemas.....	296
B.1.1	Concepto de esquema	296
B.1.2	Paralelismo Implícito	303
B.1.3	Análisis mediante cadenas de Markov	305
B.1.4	Algoritmos genéticos no elitistas.....	307
Bibliografía.....		313

Índice de Figuras

Figura 1.1 Esquema típico de una red eléctrica de potencia. Fuente Wikipedia y elaboración propia según normativa española.	24
Figura 1.2 Modelo en π equivalente de un transformador de tomas	28
Figura 2.1 Región factible de un sistema de desigualdades	37
Figura 2.2 Jerarquía de Complejidad	38
Figura 2.3 Ejemplo de función continua y no continua.....	40
Figura 2.4 Ejemplo de conjunto convexo y no convexo.....	41
Figura 2.5 Algunas etapas del conjunto de Cantor	41
Figura 2.6 Estructura de un algoritmo evolutivo típico	43
Figura 2.7 Autómata finito de 3 estados. Estado inicial C.....	46
Figura 2.8 Codificación binaria en algoritmos genéticos.....	51
Figura 2.9 Ejemplo de cromosoma con codificación binaria.	55
Figura 2.10 Ejemplo de gen dentro de un cromosoma.....	55
Figura 2.11 Ejemplo de Fenotipo	55
Figura 2.12 Procedimiento de selección en el método de la Ruleta	66
Figura 2.13 Procedimiento de selección en Muestreo Estocástico Universal.....	69
Figura 2.14 Cruce de un punto o monopunto.....	75
Figura 2.15 Cruce de dos puntos o bipunto.....	76

Figura 2.16 Cruce uniforme.....	77
Figura 2.17 Mutación de un cromosoma binario	79
Figura 2.18 Esquema de la aplicación de una estrategia elitista.	80
Figura 2.19 Relación de pareto-dominancia	86
Figura 4.1 Esquema típico de un algoritmo genético secuencial.....	126
Figura 4.2 Representación de la codificación binaria de las tomas de los transformadores.....	129
Figura 4.3 Representación de la codificación entera para un población de transformadores.....	131
Figura 4.4 Ejemplo de población aleatoria. Matriz de 20 individuos por 14 transformadores.....	134
Figura 4.5 Cruce de un sólo punto para la codificación entera de tomas	138
Figura 4.6 Cruce de dos puntos para codificación entera de tomas	138
Figura 4.7 Mutación de la toma de un transformador	139
Figura 4.8 Esquema detallado de algoritmo genético monoetapa.....	144
Figura 4.9 Red de potencia IEEE 30.....	145
Figura 4.10 Curva de demanda horaria total en el sistema IEEE30	146
Figura 4.11 Nivel de carga en el caso 1 de la Red IEEE30	149
Figura 4.12 Distribución de tensiones nodales para el caso 1 de la red IEEE30	150
Figura 4.13 Evolución de la población para el caso 1 de la IEEE30	151
Figura 4.14 Vista 1 de la ejecución del algoritmo genético con diferentes parametrizaciones.....	153
Figura 4.15 Vista 2 de la ejecución del algoritmo genético con diferentes parametrizaciones.....	154
Figura 4.16 Evolución de las tomas de los transformadores de la red IEEE30 para un conjunto de parámetros genéticos	156
Figura 4.17 Individuos óptimos para cada subconjunto de parámetros genéticos ...	157
Figura 4.18 Nivel de tensión para la red IEEE30 y caso 2, en su nivel óptimo.....	158

Figura 4.19 Nivel de tensión para la red IEEE30, caso 2 y peor individuo.	159
Figura 4.20 Tiempo empleado para las ejecuciones óptimas de la red IEEE30, caso 2.	162
Figura 4.21 Red de potencia IEEE57	164
Figura 4.22 Representación gráfica de las tomas para la red IEEE57.....	166
Figura 4.23 Nivel de carga en la Red IEEE57.....	168
Figura 4.24 Distribución de tensiones nodales para la red IEEE57.....	169
Figura 4.25 Evolución de la población para la red IEEE57.....	170
Figura 4.26 Red de potencia RTS	172
Figura 4.27 Representación gráfica de las tomas para la red RTS.....	174
Figura 4.28 Nivel de carga en la Red RTS.....	176
Figura 4.29 Distribución de tensiones nodales para la red RTS.....	177
Figura 4.30 Evolución de la población para la red RTS.....	178
Figura 4.31 Curva base de carga diaria confeccionada con datos reales de http://www.ree.es	180
Figura 4.32 Esquema detallado de algoritmo genético multietapa	181
Figura 4.33 Conjunto de IDT's de la red IEEE57 en un periodo de 24 horas.....	183
Figura 4.34 Representación gráfica de las tomas para la red IEEE57 en un periodo de 24 horas	185
Figura 4.35 Evolución de la población en la red IEEE57 para un periodo horario cualquiera	205
Figura 4.36 Conjunto de IDT's de la red RTS en un periodo de 24 horas.....	207
Figura 4.37 Representación gráfica de las tomas para la red RTS en un periodo de 24 horas (I)	208
Figura 4.38 Representación gráfica de las tomas para la red RTS en un periodo de 24 horas (II)	209
Figura 4.39 Evolución de la población para un periodo horario cualquiera de la red RTS.....	232

Figura 5.1 Ilustración de la evolución de la malla adaptativa.....	238
Figura 5.2 Ejemplo de la acción del enfriamiento simulado	243
Figura 5.3 Pseudo-código de un algoritmo básico de enfriamiento simulado	244
Figura 5.4 Red de potencia IEEE 30.....	252
Figura 5.5 Frente de Pareto para el caso IEEE30 con 5 ejecuciones de PAES.	253
Figura 5.6 Posición de las tomas para varias ejecuciones de PAES en la red IEEE30	254
Figura 5.7 Frente de Pareto para el caso IEEE30 con 5 ejecuciones de Annealing- PAES.	255
Figura 5.8 Frente de Pareto para el caso IEEE30 con 5 ejecuciones de Tabú-PAES.	256
Figura 5.9 Frente de Pareto para el caso IEEE30 con 5 ejecuciones de Annealing- Tabú-PAES.....	256
Figura 5.10 Posición de las tomas para varias ejecuciones de Annealing-Tabú-PAES en la red IEEE30.....	257
Figura 5.11 Frente de Pareto para el caso RTS con 5 ejecuciones de PAES	258
Figura 5.12 Posición de las tomas para una ejecución aleatoria de PAES en la red RTS.....	259
Figura 5.13 Frente de Pareto para el caso RTS con 5 ejecuciones de Annealing- PAES.	260
Figura 5.14 Frente de Pareto para el caso RTS con 5 ejecuciones de Tabú-PAES.	261
Figura 5.15 Frente de Pareto para el caso RTS con 5 ejecuciones de Annealing- Tabú-PAES.....	262
Figura 5.16 Comparativa entre PAES, A-PAES, T-PAES y AT-PAES para IEEE30	266
Figura 5.17 Comparativa entre PAES, A-PAES, T-PAES y AT-PAES para RTS	268
Figura 5.18 Ejecución de PAES mono-objetivo para la red IEEE30 (I).....	270
Figura 5.19 Ejecución de PAES mono-objetivo para la red IEEE30 (II)	271
Figura 5.20 Ejecución de PAES mono-objetivo para la red RTS.....	273

Índice de Tablas

Tabla 2.1 Tabla de transición de un autómata	45
Tabla 2.2 Probabilidades de selección y número esperado de individuos	67
Tabla 2.3 Probabilidad de selección y número esperado o de individuos (con reemplazo)	68
Tabla 2.4 Probabilidad de selección y número esperado o de individuos (sin reemplazo)	68
Tabla 4.1 Relación entre la toma del cambiador y su representación entera.	132
Tabla 4.2 Parámetros del algoritmo genético monoetapa inicial	147
Tabla 4.3 Posición de las tomas de los cambiadores para el caso 1 IEEE30	147
Tabla 4.4 Situación de cargas en el caso 1 para la red IEEE30	148
Tabla 4.5 Características de la máquina empleada	150
Tabla 4.6 Conjunto parametrizador para Algoritmo genético monoetapa.....	152
Tabla 4.7 Distribución de soluciones óptimas para el caso IEEE30 en función de un conjunto de parámetros genéticos.	154
Tabla 4.8 Estado de las tomas para el Caso 2 y red IEEE30.....	157
Tabla 4.9 Valor de IDT y tiempo empleado en alcanzar el óptimo para el caso 2 de la red IEEE30.....	162
Tabla 4.10 Parámetros genéticos para la resolución de la red IEEE57	164
Tabla 4.11 Posición de las tomas de los cambiadores para la red IEEE57.....	165

Tabla 4.12 Situación de cargas para la red IEEE57.....	167
Tabla 4.13 Parámetros genéticos para la resolución de la red RTS	171
Tabla 4.14 Posición de las tomas de los cambiadores para la red RTS.....	173
Tabla 4.15 Situación de cargas para la red RTS.....	176
Tabla 4.16 Parámetros genéticos para la resolución de la red IEEE57 en periodos de 24 horas.....	182
Tabla 4.17 Índices de desviación de tensión para la red IEEE57 y un periodo de 24 horas.....	183
Tabla 4.18 Posición de las tomas de los cambiadores para la red IEEE57 en un periodo de 24 horas (I).....	186
Tabla 4.19 Posición de las tomas de los cambiadores para la red IEEE57 en un periodo de 24 horas (II).....	187
Tabla 4.20 Situación de cargas para la red IEEE57 en un periodo de 24 horas (I). 190	
Tabla 4.21 Situación de cargas para la red IEEE57 en un periodo de 24 horas (II) 192	
Tabla 4.22 Situación de cargas para la red IEEE57 en un periodo de 24 horas (III)	195
Tabla 4.23 Situación de cargas para la red IEEE57 en un periodo de 24 horas (IV)	197
Tabla 4.24 Tiempos de resolución para cada hora de la red IEEE57.....	205
Tabla 4.25 Parámetros genéticos para la resolución de la red RTS en periodos de 24 horas.....	206
Tabla 4.26 Índices de desviación de tensión para la red RTS y un periodo de 24 horas.....	206
Tabla 4.27 Posición de las tomas de los cambiadores para la red RTS en un periodo de 24 horas (I).....	210
Tabla 4.28 Posición de las tomas de los cambiadores para la red RTS en un periodo de 24 horas (II)	211
Tabla 4.29 Situación de cargas para la red RTS en un periodo de 24 horas (I).....	214
Tabla 4.30 Situación de cargas para la red RTS en un periodo de 24 horas (II)	217

Tabla 4.31 Situación de cargas para la red RTS en un periodo de 24 horas (III) ...	220
Tabla 4.32 Situación de cargas para la red RTS en un periodo de 24 horas (IV) ...	223
Tabla 4.33 Tiempos de resolución para cada hora de la red RTS	232
Tabla 5.1 Parámetros en la ejecución de PAES para la red IEEE30	253
Tabla 5.2 Parámetros en la ejecución de PAES para la red RTS	259
Tabla 5.3 Resultados experimentales para la métrica de cobertura en IEEE30	266
Tabla 5.4 Resultados experimentales para la métrica de hipervolumen en IEEE30	266
Tabla 5.5 Ranking de métricas para la red IEEE30.....	267
Tabla 5.6 Resultados experimentales para la métrica de cobertura en RTS	268
Tabla 5.7 Resultados experimentales para la métrica de hipervolumen en RTS.....	268
Tabla 5.8 Ranking de métricas para la red RTS.....	269
Tabla 5.9 Comparativa entre PAES y AG para IEEE30	269
Tabla 5.10 Comparativa entre PAES y AG para RTS	272

Capítulo 1

Introducción y Objetivos

1.1 Planteamiento del problema

Los sistemas de potencia para distribución de energía eléctrica están formados por diferentes elementos interconectados entre sí. Un esquema general para el sistema español puede ser como el indicado en la figura 1.1. Partiendo de las centrales generadoras, se obtiene la energía eléctrica, a un determinado valor de tensión, para posteriormente elevar su magnitud en las subestaciones de transformación, al objeto de minimizar las pérdidas de potencia ocasionadas por el efecto Joule en los conductores de las líneas de transporte. El proceso de transporte suele transcurrir durante decenas o centenas de kilómetros hasta las denominadas subestaciones de reparto. En ellas se suele producir una reducción de la tensión mediante grandes transformadores eléctricos, de forma que la tensión de salida se adecua a niveles más convenientes para la red de reparto. En estas subestaciones se suelen instalar transformadores con posibilidad de regulación y, por tanto, con cambiadores de tomas para ajustar la tensión.

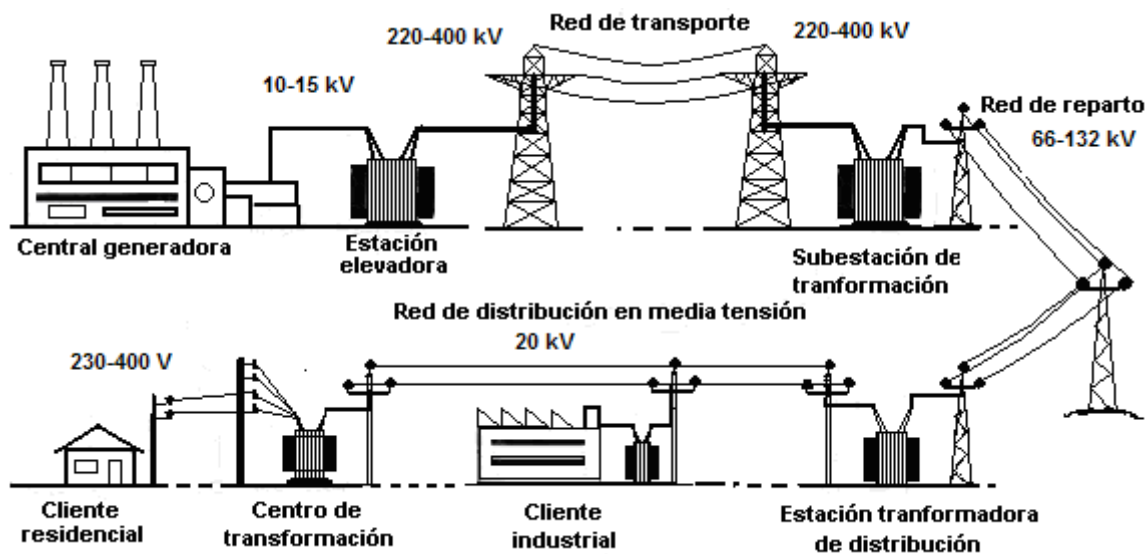


Figura 1.1 Esquema típico de una red eléctrica de potencia. Fuente Wikipedia y elaboración propia según normativa española.

Conforme la energía fluye por las líneas de reparto y se va aproximando a las grandes poblaciones, se necesitan nuevas subestaciones, llamadas de distribución. La tensión es nuevamente reducida a un nivel típico de 20 kV para su posterior distribución a los diferentes centros de transformación que pueblan la red eléctrica de atención a los usuarios finales.

En este proceso de transporte, distribución y ajuste de tensiones es fundamental tener un control sobre las tensiones eléctricas al objeto de mantener el sistema dentro de ciertos parámetros óptimos de control y seguridad. Además, la energía eléctrica que se distribuye a los diferentes usuarios de un sistema eléctrico, debe presentar una calidad adecuada para su uso cotidiano. Esta energía, normalmente se distribuye en MT y fundamentalmente en BT, por lo que se hace necesario establecer criterios de actuación que permitan controlar y, en ocasiones, actuar sobre dicho sistema eléctrico.

En la actualidad, la normativa existente en España (REAL DECRETO 1955/2000, *de 1 de diciembre por el que se regulan las actividades de transporte, distribución, comercialización, suministro y procedimientos de autorización de instalaciones de energía eléctrica*) prevé unos límites máximos de desviación de tensión con respecto a la nominal de $\pm 7\%$, pero sin establecer unos objetivos claros a la hora de conseguir una calidad óptima.

En este Decreto no se aclara, en ningún momento, qué métodos son aplicables para la determinación de la calidad de una red en cuanto a los niveles de tensión óptimos.

Únicamente se hace referencia a la norma UNE 50.160, como documento de referencia para el cálculo de posibles índices de calidad. Sin embargo, en dicha norma tampoco aparece expresado, con claridad, ninguna indicación acerca de cómo obtener o valorar la desviación que un determinado conjunto de tensiones nodales provoca en una red de distribución y, por tanto, en sus usuarios.

En este trabajo se presenta un nuevo método que, usando técnicas de optimización evolutiva (algoritmos genéticos y multi-objetivo), permite ajustar de manera global las tensiones de los nudos dentro de un rango preseleccionado, de forma que se consiga un control óptimo en la configuración de las tomas de regulación de los transformadores existentes en la red de distribución, tanto en los transformadores AT/MT como en los transformadores MT/BT. Estas técnicas de optimización se han usado con éxito en otras aplicaciones relacionadas con las redes eléctricas, según se desprende de [Miranda 94], [Arroyo 02], [Augugliaro 04], [Furong 05].

Además, usando novedosas técnicas multi-objetivo, también se puede optimizar de manera conjunta otros parámetros del sistema como la pérdida de potencia en las líneas de la red o incluso el número de veces que el regulador de un transformador determinado va a entrar en funcionamiento en periodos horarios definidos. Por ello, se hace uso de un índice de calidad de tensión modificado, el cual fue propuesto por [Aznar 99] basado en un trabajo previo de [Ailleret 56], y que tiene en cuenta las desviaciones de tensión respecto de la nominal independientemente del nivel de potencia de las cargas conectadas en cada nudo.

El método implementado busca las soluciones de la función objetivo

$$f(x) = \min D \quad (1.1)$$

donde D es el nuevo índice, llamado **Índice de Desviación de Tensión** o **IDT**, que está sujeto a las restricciones reglamentarias de $\pm 7\%$.

En nuestro caso, las variables de decisión serán las posiciones de las tomas de los transformadores, bien sea AT/AT, AT/MT, MT/MT o MT/BT que forman la red, de manera que se consiga el óptimo, según el IDT, para las tensiones a partir de la expresión (1.2)

$$D = \sum_{i=1}^{N_T} \frac{(U_i - U_{ni})^2}{U_{ni}^2} \quad (1.2)$$

donde:

D : índice de desviación de tensión o IDT.

U_i : tensión nudo i

U_{ni} : tensión nominal de la red en el nivel de tensión del nudo i

N_T : número de nudos de la red

A efectos prácticos, se trabajará en magnitudes unitarias y por tanto los U_i estarán cercanos a la unidad y los U_{ni} siempre serán iguales a la unidad.

Una versión mejorada del algoritmo anterior consistirá en la adaptación a entornos multi-objetivo. En este caso, la función objetivo será

$$\min f_i(x) \tag{1.3}$$

donde $f_i(x)$ podrá ser el IDT o la suma de las pérdidas de potencia en las líneas eléctricas.

Es importante destacar el gran esfuerzo realizado por las empresas de distribución de la energía eléctrica en la medición de los tiempos de interrupción y su valoración con diferentes índices. Sin embargo, es también notorio el escaso o nulo uso de índices en cuanto a la calidad de la tensión suministrada. En una zona de la red pueden producirse muy pocas interrupciones, pero por contra, puede ser necesario tomar medidas en ella debido a la aparición, de forma regular, de desviaciones de la tensión con relación a la nominal en los nudos de consumo o distribución. El problema es difícil de precisar ya que las potencias a suministrar varían aleatoriamente y evolucionan considerablemente en el tiempo.

En general, el objetivo fijado por las compañías distribuidoras consiste únicamente en el cumplimiento de la reglamentación vigente, la cual introduce unas bandas alrededor de la tensión nominal en las que las tensiones de todos los nudos deben quedar incluidas, en cualquier momento.

El procedimiento anterior no tiene en cuenta si en el interior de dichas bandas la calidad de servicio se mantiene cerca o lejos del límite, dependiendo la calidad de la tensión del usuario peor servido.

Por otra parte, el funcionamiento y la vida útil de los diversos equipos y receptores es dependiente de la tensión a que están sometidos a lo largo del tiempo, especialmente los equipos electrónicos, cuyo número ha aumentado de manera exponencial en los últimos años.

Con la adecuación de tensiones se aumentan los beneficios al dilatar en el tiempo las inversiones necesarias para disminuir las caídas de tensión. Por ello, es deseable que la tensión de alimentación esté lo más próxima posible a la correspondiente tensión nominal a lo largo del tiempo y con independencia, en lo posible, de los estados de carga de la red eléctrica.

También hay que tener en cuenta que la liberalización del mercado eléctrico va a producir un aumento de la competencia entre las diferentes compañías distribuidoras, que se verán obligadas a suministrar un producto, la energía eléctrica, con la mayor calidad posible con el fin de aumentar su cuota de mercado.

Todo el conjunto de razones comentadas anteriormente, resalta la importancia del tema tratado en este trabajo y evidencia el interés de profundizar en el campo de la mejora de la calidad de tensión en las redes de distribución.

1.2 Objetivos de la tesis

El principal objetivo de la tesis es la consecución de un perfil óptimo de tensiones mediante la actuación en el estado de las tomas de los cambiadores de un conjunto de transformadores en una red eléctrica de distribución, de forma que las tensiones nodales en dicha red estén lo más próximo que se pueda a sus tensiones nominales. Para ello se ha implementado un nuevo método basado en algoritmos genéticos capaz de lidiar con la complejidad no lineal y combinatoria del problema.

El método desarrollado cumple los siguientes criterios:

- Se hace cumplir el escenario de demanda de potencias activa y reactiva al que está sujeto la red.
- Se emplea un algoritmo basado en técnicas genéticas con selección, cruce y mutación. Cada regulador de tomas de los transformadores es modelado como parte de un individuo que tiene la capacidad de “aparearse”, “tener descendencia” y “sufrir cambios aleatorios” con los demás individuos o sí

mismo. Este planteamiento se realiza modelando las tomas como números enteros cuyo rango de variación se encuentra comprendido entre el valor mínimo y máximo del regulador.

- Se usa un modelo de flujo de cargas completo (no lineal) de activa y reactiva para las restricciones de red. Se hace uso de la librería MATPOWER¹ específica para resolver flujos de cargas completos de la Universidad de Wisconsin (USA). Se realiza una resolución completa por cada topología generada al variar las tomas de los transformadores, según el modelo estándar del transformador de tomas.




Figura 1.2 Modelo en π equivalente de un transformador de tomas

- Se consideran cualquier tipo de cargas en la red, incluidas cargas reactivas no lineales o electrónicas (STATCOM, condensadores síncronos, etc)
- Obtención de una solución, en cuanto a tensiones nodales de red, que cumpla las ecuaciones del flujo de cargas impuesto y que a su vez presente un mínimo en la función de calidad propuesta.

¹ <http://www.pserc.cornell.edu/matpower/>

- Coordinación centralizada de todos los elementos de control de tensión de una red a nivel de regulación de transformación.

Además, se ha desarrollado un nuevo algoritmo multi-objetivo que permite la inclusión de nuevos aspectos en el problema. Concretamente, se ha planteado un objetivo adicional al IDT:

- **Optimización de la pérdida de potencia** en las líneas eléctricas. Se plantea un escenario de optimización de las tensiones en conjunción con la pérdida de potencia, de manera que sea posible obtener un abanico de soluciones “no dominadas” según el criterio de Pareto. Se observa como ambos objetivos son contradictorios, es decir, una minimización en el índice de desviación de tensiones supone un aumento en las pérdidas de energía y viceversa.

Se hace referencia a la introducción de un posible tercer objetivo relacionado con la vida útil de los cambiadores de tomas (aunque no ha llegado a implementarse del todo)

- **Optimización de la vida útil de los cambiadores de tomas.** A diferencia del caso anterior, ahora lo que se pretende es que la resolución horaria del algoritmo de optimización de tensiones no genere un excesivo desgaste en los cambiadores debido a un uso frecuente de los mismos. Para ello se plantea un nuevo objetivo que consiste en minimizar el número de veces que los cambiadores de la red sufren variaciones a lo largo de un periodo concreto. Se observa como ambos objetivos son contradictorios, ya que una minimización del índice de tensiones conlleva un alto uso de los cambiadores, y viceversa, no actuar sobre los cambiadores conlleva un índice de tensiones superior al deseado.

Por último, destacar que, aparte de los objetivos principales anteriormente expuestos, se han tenido presentes otras metas u objetivos secundarios:

- Desarrollar un nuevo sistema que permita la regulación de tensión en una red de distribución, atendiendo no sólo a criterios reglamentarios o de reducción de costes de la propia red, sino que permita que las tensiones de los puntos de la red sean óptimas, desde la perspectiva de la desviación de la tensión nominal.
- Utilización de nuevas técnicas matemáticas diferentes a las empleadas con anterioridad. Empleo de algoritmos genéticos frente a algoritmos de optimización no lineal, tipo Newton-Raphson-Kantorovich.

- Establecer índices estándar y bien definidos que permitan la comparativa entre diferentes redes.
- Valorar la aplicación del método a redes reales de distribución de energía eléctrica.
- Extraer conclusiones en cuanto a la idoneidad de la aplicación del proceso y los beneficios que pueda generar.

1.3 Estructura de la Tesis

Esta Tesis doctoral incluye seis capítulos y varios apéndices cuyos contenidos se detallan a continuación.

Capítulo 1. Se realiza una introducción al problema objeto de la Tesis, describiendo los principales paradigmas del mismo, así como el enfoque planteado para su resolución. Por otro lado, se enumeran los objetivos a alcanzar en este trabajo, detallando los principales criterios tenidos en cuenta y otros objetivos deseables. Por último, se detalla de manera pormenorizada todo el contenido de la tesis, realizando un breve resumen de los contenidos de cada capítulo.

Capítulo 2. En este capítulo se presenta, de forma general, el método empleado para resolver el problema de la optimización de tensiones en redes eléctricas, así como una breve descripción de las técnicas matemáticas que han venido siendo utilizadas con anterioridad, es decir, técnicas basadas en optimización lineal. Se habla, en primer lugar y brevemente, de las técnicas clásicas de optimización para posteriormente describir las dos técnicas más relevantes pertenecientes a la computación evolutiva. A continuación se presenta en detalle las dos técnicas de resolución empleada en este trabajo: algoritmos genéticos y el algoritmos multi-objetivo.

Capítulo 3. En este capítulo se hace un repaso al estado del arte referente a la optimización de tensiones en redes eléctricas. Se analizan los métodos y técnicas usados en la actualidad, así como las mejoras y nuevas propuestas realizadas recientemente basadas en algoritmos evolutivos o convencionales que permiten abordar el problema de la optimización de tensiones.

Capítulo 4. En este capítulo se presenta la aplicación de un algoritmo genético a la resolución del problema de optimización de tensiones en redes de distribución eléctrica. La estructura del capítulo se compone de la presentación de las características del algoritmo genético desarrollado, haciendo hincapié en su estructura general y todas las particularidades y adaptaciones que han sido necesarias realizar para adecuarlo a este problema concreto. Posteriormente se describen los distintos operadores que se han implementado en la resolución del problema. También, se presentan los casos estudiados y que han servido de base para la comprobación de las bondades del algoritmo desarrollado. Como casos de estudio, se han usado las redes de potencia estándar IEEE30, IEEE57 y la red RTS. Cabe destacar que no ha sido posible el estudio de una red real debido a la negativa de la compañía SEVILLANA-ENDESA a ceder los datos de alguna de sus redes para este estudio. Además, se presentan los resultados obtenidos en cada una de las redes, mostrando diferentes gráficas y tablas explicativas del proceso.

Capítulo 5. En este capítulo se detalla la nueva aportación basada en técnicas multi-objetivo que buscan minimizar otros factores además de la calidad en la tensión, como es la pérdida de potencia en las líneas. Se describen los diferentes métodos implementados, y se hace notar la mejora que supone el uso de dichas técnicas frente a los algoritmos genéticos. Se han vuelto a tomar como redes de prueba los estándares de la organización IEEE usados en el capítulo 4. Además, se presentan los resultados obtenidos, en cada una de las redes, mostrando diferentes gráficas y tablas explicativas del proceso.

Capítulo 6. Por último, en este capítulo se recogen las principales conclusiones del trabajo realizado en el ámbito de la presente Tesis, proponiendo asimismo, futuros desarrollos y líneas de investigación.

Apéndices Se presentan los diferentes datos de entrada usados como base en la resolución de los algoritmos, así como el código fuente implementado en MATLAB (soporte informático). También se muestran algunos principios matemáticos sobre los que se asienta la teoría sobre algoritmos evolutivos.

Bibliografía Se presenta, finalmente, la bibliografía consultada a lo largo del período de investigación que ha concluido con la publicación de esta Tesis.

Capítulo 2

Optimización mediante algoritmos evolutivos

En este capítulo se presenta la base teórica de los métodos de resolución empleados para resolver el problema de la optimización de tensiones en redes eléctricas, así como una breve descripción de las técnicas matemáticas que han venido siendo utilizadas con anterioridad, es decir, técnicas basadas en optimización lineal. Estas técnicas de resolución se encuadran dentro de las llamadas “técnicas de computación evolutiva”. Este tipo de computación evolutiva agrupa al conjunto de técnicas de optimización inspiradas en la naturaleza y en la evolución de los seres vivos. Particularmente, se ha trabajado en profundidad el método del algoritmo genético.

La elección de un algoritmo genético para resolver el problema de optimización de tensiones en redes eléctricas se debe, entre otras, a dos razones fundamentales:

1. La optimización de tensiones en redes eléctricas es un problema de programación matemática no lineal, no convexo, entero-mixto, combinatorio y de gran dimensión. Lo anterior implica que no existe técnica alguna capaz de resolver de forma exacta este problema para sistemas de energía eléctrica de tamaño realista. La técnica del algoritmo genético permite modelar cualquier tipo de no linealidad y no convexidad y, por lo tanto, es capaz de obtener soluciones factibles del problema a resolver.

2. Como se verá más adelante, la adaptación de cualquier técnica de computación evolutiva a un problema general de optimización no es, en general, sencilla. Sin embargo, la aplicación de un algoritmo genético al problema de optimización de tensiones en redes eléctricas es directa debido a la naturaleza combinatoria y discreta de este problema.

En este capítulo se habla, en primer lugar y brevemente, de las técnicas clásicas de optimización para posteriormente describir las técnicas más relevantes pertenecientes a la computación evolutiva. Por último, se presentan en detalle las dos técnicas de resolución empleadas en este trabajo: algoritmos genéticos y algoritmos multi-objetivo.

2.1 Técnicas clásicas de optimización

El término optimización es usado comúnmente para describir el proceso de hallar la “mejor” solución de entre un conjunto de opciones llamadas “espacio de búsqueda”.

La mejor solución es dicha en el sentido de óptimo global (el cual será definido a continuación) referente a una cierta función objetivo f del espacio de búsqueda.

Definición 1. Dado un problema de minimización para una función

$$f : A \subseteq S = \mathbb{R}^n \rightarrow \mathbb{R}, \quad A \neq \emptyset$$

El valor $-\infty < f^* := f(\vec{x}^*)$ es llamado el óptimo global (o mínimo) si y sólo si para todos los valores

$$\vec{x} \in A \text{ se cumple que } f(\vec{x}^*) \leq f(x)$$

A la función f se le conoce como función objetivo.

2.1.1 Optimización lineal

Definición 2. Se llama igualdad (ecuación) lineal *no homogénea* en las variables x_1, x_2, \dots, x_n a una expresión de la forma:

$$a_1x_1 + a_2x_2 + a_3x_3 + \dots + a_nx_n = b$$

con los escalares $a_i, b \in \Pi$ donde Π puede ser \mathbb{R}, \mathbb{Q} ó \mathbb{Z} .

Definición 3. Al conjunto de m ecuaciones lineales con n incógnitas se le llama *sistema* de ecuaciones lineales de tamaño $m \times n$.

$$\begin{array}{cccccccc} a_{11}x_1 & + & a_{12}x_2 & + & \cdots & + & a_{1n}x_n & = & b_1 \\ a_{21}x_1 & + & a_{22}x_2 & + & \cdots & + & a_{2n}x_n & = & b_2 \\ \vdots & & \vdots & & \vdots & & \vdots & & \vdots \\ a_{m1}x_1 & + & a_{m2}x_2 & + & \cdots & + & a_{mn}x_n & = & b_m \end{array}$$

Definición 4. Una desigualdad lineal o inecuación lineal es una expresión que puede tomar una de las siguientes cuatro formas:

$$\begin{array}{l} a_1x_1 + a_2x_2 + a_3x_3 + \cdots + a_nx_n < b \\ a_1x_1 + a_2x_2 + a_3x_3 + \cdots + a_nx_n \leq b \\ a_1x_1 + a_2x_2 + a_3x_3 + \cdots + a_nx_n > b \\ a_1x_1 + a_2x_2 + a_3x_3 + \cdots + a_nx_n \geq b \end{array}$$

Análogamente a la definición 3, puede definirse un sistema de desigualdades lineales.

Definición 5. El conjunto de valores ordenados lexicográficamente

$$x_1 = c_1, x_2 = c_2, \dots, x_n = c_n$$

con $c_i \in Q$, donde Q puede ser \mathbb{R}, \mathbb{Q} ó \mathbb{Z} , se dice ser una solución a un sistema S si y sólo si la sustitución de los valores x_1, x_2, \dots, x_n en S mantiene la consistencia en el sistema. Por ejemplo para un sistema de igualdades lineales tener

$$a_{i1}c_1 + a_{i2}c_2 + a_{i3}c_3 + \cdots + a_{in}c_n = b_i$$

para todo $i = 1, 2, \dots, m$.

La solución a un sistema de ecuaciones (o desigualdades) lineales puede verse como la solución a la ecuación matricial:

$$Ax = b \quad (Ax \leq b)$$

donde

$$A = \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \vdots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{pmatrix}$$

y

$$x = \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix}$$

representan coeficientes e incógnitas, y cuyos términos independientes están dados por:

$$b = \begin{pmatrix} b_1 \\ b_2 \\ \vdots \\ b_n \end{pmatrix}$$

La producción industrial, el flujo de recursos en la economía y el manejo de finanzas, entre otros ejemplos, requieren de la coordinación de actividades relacionadas entre sí. Si estos sistemas pueden modelarse (o aproximarse de manera razonable) a través de desigualdades y/o igualdades lineales, su estudio puede entonces catalogarse dentro del área de la programación lineal. No basta con hallar las proporciones para que un sistema de los anteriores pueda funcionar, sino que hay que hallar la distribución correcta entre sí para que den un rendimiento mayor, es decir hallar la solución óptima.

La programación lineal se basa en el estudio de la convexidad de las regiones factibles (también llamadas espacio solución). Debido a que las restricciones en un programa lineal son hiper-planos contenidos en algún espacio de \mathbb{R}^n , se prueba que la intersección de estas restricciones es una región convexa; aplicando entonces algunos resultados de convexidad podemos demostrar que los óptimos de funciones lineales sobre este tipo de regiones se hallan en los vértices (también conocidos como puntos extremos) de éstas.

De esta forma se han desarrollado métodos matriciales y algebraicos como el “*Simplex*” que de manera algorítmica, para un problema lineal, nos conduce al óptimo. En [Dantzig 97] y [Gass 03] se da una extensa metodología para la resolución de problemas lineales.




Figura 2.1 Región factible de un sistema de desigualdades

2.1.2 Complejidad Computacional

Un problema, usualmente, está determinado por un conjunto de hipótesis y parámetros que lo especifican y un conjunto más de condiciones que al ser descritas nos dan la solución del problema. Muchos problemas requieren, para su solución, una serie de pasos que al agruparse forman lo que se conoce como algoritmo. Los algoritmos se describen de manera conceptual y posteriormente se pueden implementar en computadores. Normalmente, los algoritmos se estudian para mejorar su eficiencia, pero ¿qué es la eficiencia en un algoritmo? Existen varias formas de describir la eficiencia de un algoritmo. Algunos estudios se enfocan a que el algoritmo sea más rápido para decir que es más eficiente; otros buscan que el algoritmo ahorre memoria de manera considerable. Una manera de normalizar el análisis de la eficiencia de un algoritmo es comparar el número de ciclos de ejecución que éste representa, así los resultados dependerán del algoritmo de manera conceptual y no de la computadora en la que se implemente.

Un algoritmo de tiempo polinomial es aquél cuya complejidad temporal es $O(p(n))$, donde $p(n)$ es un polinomio. Este tipo de algoritmos describen problemas a los cuales se conoce como *problemas tratables*. Un algoritmo de tiempo exponencial es aquel que no puede ser acotado por una función polinomial. Este tipo de algoritmos describen problemas a los cuales se conoce como *problemas intratables*.

Otra clasificación de problemas, dada por Alan Turing en la primera mitad del siglo XX versa sobre la posibilidad de que una computadora pueda resolver o no, un problema (como conocemos a la computadora actual, es decir una máquina determinista). A aquellos para los cuales la afirmación es cierta se les conoce como problemas resolubles; a los que no pueden ser resueltos por una computadora se les llama problemas no resolubles.

A la clase que engloba a todos los problemas que son solubles en un tiempo polinomial le llamaremos clase P .

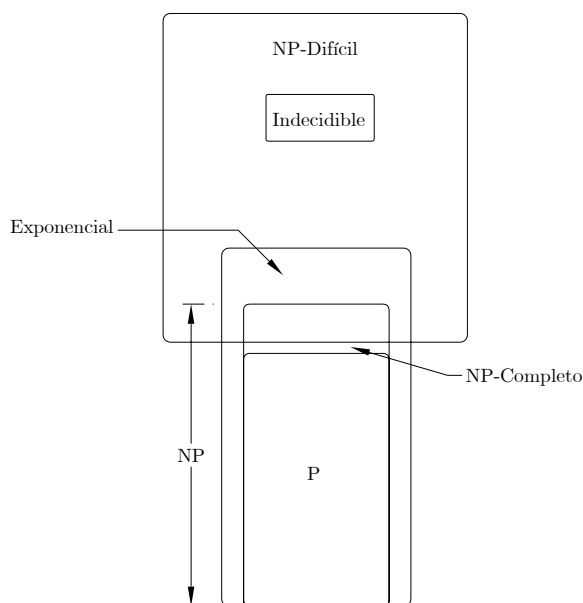


Figura 2.2 Jerarquía de Complejidad

Un algoritmo *no determinista* es aquel en el que cada estado puede transitar a varios estados diferentes de manera simultánea y que no se puede predecir en un principio. Llamaremos NP a la clase que engloba a los problemas tales que se resuelven a través de un algoritmo no determinista en un tiempo polinomial.

Un problema se dice *polinomialmente transformable* en otro si existe una función f tal que en tiempo polinomial transforma los casos de un problema en el otro incluyendo las soluciones. Un problema se dice ser *NP-completo* si pertenece a la clase NP y todos los problemas de la clase NP son polinomialmente transformables a él. Un problema se dice que es *NP-difícil* si cumple con que todos los problemas de la clase NP son polinomialmente transformables a él pero él no necesariamente pertenece a la clase NP .

2.1.3 Heurísticas

Una heurística es una técnica para aproximar la solución a un problema de optimización para el cual no existen métodos eficientes conocidos, ya sea porque el espacio de búsqueda es muy grande y la búsqueda exhaustiva es imposible, o porque el modelo del problema no se adapta a ninguna de las técnicas existentes (para las cuales sí se tienen algoritmos que nos llevan a la solución precisa). Es decir, las heurísticas se usan para lidiar con problemas cuya complejidad es tal, que el uso de algoritmos deterministas tiene un costo computacional prohibitivo. Una heurística busca aproximarse de manera intuitiva pero ordenada a la mejor solución, aunque no garantiza llegar al óptimo; para cada problema se puede construir una heurística especial que dé mejores resultados que otras, ya sea en tiempo o en proximidad al óptimo. Se ha comprobado empíricamente que para cierto tipo de problemas existen heurísticas que funcionan muy bien. Sin embargo, no existe la heurística que, para cualquier problema, sea más eficiente que todas las demás [Wolpert 97].

Para problemas de gráficas (por ejemplo hallar el corte máximo de una gráfica), el espacio de búsqueda es precisamente el conjunto de cortes posibles, el cual coincide con el conjunto potencia del conjunto de los vértices de la gráfica. En este caso hacer una búsqueda exhaustiva de la solución es imposible para gráficas con muchos nodos ya que crece de manera exponencial¹. En estos casos se justifica el uso de una heurística de

¹ La cardinalidad del conjunto potencia de un conjunto con n elementos (nodos de la gráfica) es 2^n

búsqueda local o de “recocido simulado” [Kirkpatrick 83] en la cual el tiempo de cálculo es muy aceptable y la solución aproximada es buena.

Las heurísticas no son adecuadas para todo tipo de problemas y son particularmente inadecuadas para problemas cuyo modelo se ajusta a técnicas ya muy estudiadas que nos arrojan soluciones suficientemente simples, como es el caso de los Programas Lineales; en éstos, el Método Simplex llega al óptimo de manera eficiente usando un método algorítmico de tiempo polinomial. Este tipo de técnica nos garantiza además, de manera determinista, que el óptimo (de existir) será alcanzado. Si es muy importante asegurar que, efectivamente, se alcanza el óptimo, las heurísticas no son recomendables.

2.1.4 Dificultades y complicaciones

Como hemos mencionado, existen muchos métodos y estudios dentro de la optimización lineal, la Investigación de Operaciones y la investigación en heurísticas que nos dan herramientas específicas para hallar las mejores soluciones con respecto a diferentes categorías de problemas. Sin embargo existen problemas que poseen características especiales que los hacen difíciles de tratar con los métodos clásicos.

La primera complicación que puede tener un problema de optimización es el hecho de que las funciones a optimizar no posean continuidad, dado que si buscamos el máximo o mínimo de una función continua, existen ya métodos precisos que encuentran los valores óptimos.




Figura 2.3 Ejemplo de función continua y no continua

Otra característica que dificulta el uso de métodos clásicos se produce cuando la región factible es no convexa. Por ejemplo, puede demostrarse mediante un poco de topología de conjuntos que en regiones factibles convexas las imágenes bajo funciones

lineales deben tener sus valores máximos y mínimos en la frontera; sin embargo la ausencia de convexidad nos limita y excluye de una gran cantidad de técnicas para optimizar basadas en este hecho.




Figura 2.4 Ejemplo de conjunto convexo y no convexo

Algunas técnicas clásicas se basan en el estudio de la concavidad de las imágenes bajo funciones objetivo, en otras es necesario que las funciones a optimizar sean diferenciables; en el caso de funciones no diferenciables el repositorio de técnicas factibles a utilizar se reduce una vez más. Más aún, gran cantidad de problemas presentan poca o nula información acerca de su región factible. A veces las regiones no sólo son no convexas sino no conexas, lo cual deja el problema fuera del alcance de muchas de las heurísticas de búsqueda local, debido a que no podrían salir de óptimos locales si cayesen en uno.

El [Conjunto de Cantor](#) (figura 2.5) es un ejemplo de regiones no continuas, cuya gráfica representa una función no diferenciable y es difícil de caracterizar matemáticamente.



Figura 2.5 Algunas etapas del conjunto de Cantor

Junto con las características descritas anteriormente, puede citarse que algunos problemas cuentan con funciones objetivo que son difíciles de evaluar por un humano, por lo que se requiere el uso de computadoras. Ésta y las anteriores complicaciones hacen de los problemas que las poseen buenos candidatos para la aplicación de algoritmos evolutivos, puesto que para estas técnicas nada de lo anterior acarrea dificultad. Es por eso que cuando ningún método conocido se aproxima razonablemente el óptimo, vale la pena intentar usar una técnica evolutiva.

En particular si utilizamos técnicas evolutivas en problemas con un alto costo computacional para la evaluación de las funciones de aptitud, debemos tener en cuenta que en cada generación es indispensable evaluar a cada uno de los individuos de la población. Es precisamente en estos casos, cuando la elección de una versión paralela del algoritmo evolutivo es una buena opción [Cantú-Paz 00].

2.2 Técnicas evolutivas

El término computación evolutiva o algoritmos evolutivos, realmente engloba una serie de técnicas inspiradas biológicamente (en los principios de la teoría Neo-Darwiniana de la evolución natural). En términos generales, para simular el proceso evolutivo en una computadora se requiere:

- Codificar las estructuras que se replicarán.
- Operaciones que afecten a los “individuos”.
- Una función de aptitud.
- Un mecanismo de selección.

Aunque hoy en día es cada vez más difícil distinguir las diferencias entre los distintos tipos de algoritmos evolutivos existentes, por razones sobre todo históricas, suele hablarse de tres paradigmas principales:

- Programación Evolutiva
- Estrategias Evolutivas
- Algoritmos Genéticos

Cada uno de estos paradigmas se originó de manera independiente y con motivaciones muy distintas. Aunque esta tesis se concentrará en el tercero (los *algoritmos genéticos*), revisaremos rápidamente, y de manera muy general, los otros dos paradigmas.

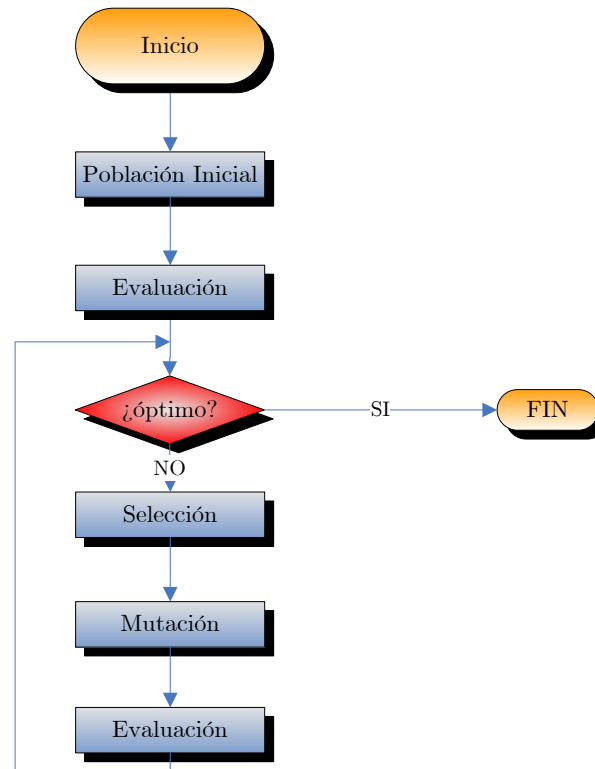


Figura 2.6 Estructura de un algoritmo evolutivo típico

Una técnica evolutiva es un algoritmo probabilista que converge hacia una solución factible y cuasi-óptima del problema tras una serie de ejecuciones o iteraciones. Este algoritmo trabaja sobre una población de individuos en cada ejecución, de forma que cada individuo representa una solución potencial del problema a resolver siendo codificado como una estructura de datos más o menos compleja. Cada solución es evaluada en cada iteración para obtener una medida de su optimalidad. A continuación, se forma una nueva población escogiendo a los mejores individuos según su optimalidad basada en la definición de una función de aptitud (función objetivo). Para producir nuevas soluciones e introducir diversidad en el espacio de búsqueda, algunos miembros de la nueva población se ven sometidos a determinadas transformaciones en su estructura por medio de los llamados operadores genéticos. Este proceso se repite tantas veces como iteraciones o *generaciones* (por analogía con los procesos naturales) se hayan definido, de forma que la calidad de las soluciones va mejorando iteración a iteración. En la figura 2.6 se puede apreciar un diagrama de flujo de un algoritmo evolutivo típico.

Otra característica común a todas las técnicas evolutivas es la independencia entre el método de búsqueda y la naturaleza de la función objetivo, así como su flexibilidad en el modelado. Las técnicas convencionales de optimización tales como la programación lineal entera-mixta, la programación dinámica, los métodos de punto interior o las técnicas de descomposición como la *relajación lagrangiana* o la *descomposición de Benders* requieren que la función objetivo y las restricciones reúnan una serie de características de diferenciabilidad, convexidad, linealidad o independencia del tiempo. Sin embargo, la gran ventaja de las técnicas evolutivas radica en el hecho de que la evaluación de la calidad de un individuo no condiciona la búsqueda de ese individuo. Es decir, cualquier problema, aunque no pueda ser resuelto por ninguna técnica convencional de forma directa, es resoluble por una técnica evolutiva.

Las diferencias que presentan los distintos programas evolutivos residen en un nivel más bajo: tipos de operadores genéticos empleados, número de individuos en la población, codificación empleada, etc. La elección de una u otra técnica para resolver un determinado problema depende de la complejidad en la adaptación de las características propias de cada técnica a la naturaleza del problema a resolver. Es decir, una representación natural de las soluciones del problema junto con un grupo de operadores genéticos compatibles con la naturaleza del problema son las cualidades determinantes para que una técnica evolutiva concreta sea elegida para resolver el problema en cuestión.

2.2.1 Programación evolutiva

Lawrence J. Fogel propuso en los años sesenta una técnica denominada “programación evolutiva”, en la cual la inteligencia se ve como un comportamiento adaptativo [Fogel 66] y [Fogel 99].

La programación evolutiva enfatiza los nexos de comportamiento entre padres e hijos, en vez de buscar emular operadores genéticos específicos (como en el caso de los algoritmos genéticos).

2.2.1.1 Estructura algorítmica

El algoritmo básico de la programación evolutiva es el siguiente:

- Generar aleatoriamente una población inicial.

- Se aplica mutación.
- Se calcula la aptitud de cada hijo y se usa un proceso de selección mediante torneo (normalmente estocástico) para determinar cuáles serán las soluciones que se retendrán.

La programación evolutiva es una abstracción de la evolución al nivel de las especies, por lo que no se requiere el uso de un operador de recombinación (diferentes especies no se pueden cruzar entre sí). Asimismo, usa selección probabilística.

2.2.1.2 Ejemplo

Un ejemplo típico de programación evolutiva es el que se indica en la figura 2.7. La tabla de transiciones de este autómata es la siguiente:

Estado Actual	C	B	C	A	A	B
Símbolo de Entrada	0	1	1	1	0	1
Estado Siguiente	B	C	A	A	B	C
Símbolo de Salida	b	A	C	B	B	A

Tabla 2.1 Tabla de transición de un autómata

En este autómata pueden ahora aplicarse cinco diferentes tipos de mutaciones: cambiar un símbolo de salida, cambiar una transición, agregar un estado, borrar un estado y cambiar el estado inicial. El objetivo es hacer que el autómata reconozca un cierto conjunto de entradas (o sea, una cierta expresión regular) sin equivocarse ni una sola vez.




Figura 2.7 Autómata finito de 3 estados. Estado inicial C

2.2.1.3 Aplicaciones

Algunas de las aplicaciones exitosas en las que se ha utilizado la programación evolutiva han sido:

- 🍏 Predicción
- 🍏 Generalización
- 🍏 Juegos
- 🍏 Control automático
- 🍏 Problema del viajero
- 🍏 Planeamiento de rutas
- 🍏 Diseño y entrenamiento de redes neuronales
- 🍏 Reconocimiento de patrones

2.2.2 Estrategias evolutivas

Las estrategias evolutivas fueron desarrolladas en 1964 en Alemania para resolver problemas hidrodinámicos de alto grado de complejidad por un grupo de estudiantes de ingeniería encabezado por Ingo Rechenberg [Bäck 96].

2.2.2.1 Estructura algorítmica

La versión original (1+1)-EE usaba un solo padre y con él se generaba un solo hijo. Este hijo se mantenía si era mejor que el padre, o de lo contrario se eliminaba (a este tipo de selección se le llama extintiva, porque los peores individuos obtienen una probabilidad cero de ser seleccionados).

En la (1+1)-EE, un individuo nuevo es generado usando:

$$\bar{x}^{t+1} = \bar{x}^t + N(0, \bar{\sigma})$$

donde t se refiere a la generación (o iteración) en la que nos encontramos, y $N(0, \bar{\sigma})$ es un vector de números Gaussianos independientes con una media de cero y desviaciones estándar $\bar{\sigma}$.

2.2.2.2 Ejemplo

Supongamos que queremos optimizar:

$$f(x_1, x_2) = 100(x_1^2 - x_2)^2 + (1 - x_1)^2$$

donde: $2,048 \leq x_1, x_2 \leq 2,048$

Ahora, supongamos que nuestra población consiste en el siguiente individuo (generado de forma aleatoria):

$$(\bar{x}^t, \bar{\sigma}) = (-1, 1), (1, 1)$$

Supongamos también que las mutaciones producidas son las siguientes:

$$x_1^{t+1} = x_1^t + N(0, 1) = -1 + 0.61 = 0.39$$

$$x_2^{t+1} = x_2^t + N(0, 1) = 1 + 0.57 = 1.57$$

Ahora, comparamos al padre con el hijo:

Padre	$f(x_t) = f(-1,1) = 4$
Hijo	$f(x_{t+1}) = f(-0.39,1.57) = 201.42$

Dado que: $201.42 > 4$, el hijo reemplazará al padre en la siguiente generación.

Rechenberg [Rechenberg 73] introdujo el concepto de población, al proponer una estrategia evolutiva llamada $(\mu+1)$ -EE, en la cual hay μ padres y se genera un solo hijo, el cual puede reemplazar al peor padre de la población (selección extintiva).

Schwefel [Schwefel 77],[Schwefel 81] introdujo el uso de múltiples hijos en las denominadas $(\mu+\lambda)$ -EEs y (μ,λ) -EEs. La notación se refiere al mecanismo de selección utilizado:

- 🍏 En el primer caso, los μ mejores individuos obtenidos de la unión de padres e hijos sobreviven.
- 🍏 En el segundo caso, sólo los μ mejores hijos de la siguiente generación sobreviven.

2.2.2.3 Convergencia

Rechenberg [Rechenberg 73] formuló una regla para ajustar la desviación estándar de forma determinística durante el proceso evolutivo de tal manera que el procedimiento convergiera hacia el óptimo.

Esta regla se conoce como la “regla del éxito 1/5”, y en palabras dice:

“La razón entre mutaciones exitosas y el total de mutaciones debe ser 1/5. Si es mayor, entonces debe incrementarse la desviación estándar. Si es menor, entonces debe decrementarse”.

Formalmente:

$$\sigma(t) = \begin{cases} \sigma(t-n)/c & \text{si } p_s > 1/5 \\ \sigma(t-n) \times c & \text{si } p_s < 1/5 \\ \sigma(t-n) & \text{si } p_s = 1/5 \end{cases}$$

donde n es el número de dimensiones, t es la generación, p_s es la frecuencia relativa de mutaciones exitosas medida sobre intervalos de, por ejemplo, $10n$ individuos, y $c = 0.087$ (este valor fue derivado teóricamente por Schwefel [Schwefel 81]).

$\sigma(t)$ se ajusta cada n mutaciones.

Thomas Bäck [Bäck 96] derivó una regla de éxito $1/7$ para las (μ, λ) -EEs.

2.2.2.4 Auto-adaptación

En las estrategias evolutivas se evoluciona no sólo a las variables del problema, sino también a los parámetros mismos de la técnica (es decir, las desviaciones estándar). A esto se le llama “auto-adaptación”.

Los operadores de recombinación de las estrategias evolutivas pueden ser:

- ♣ **Sexuales:** el operador actúa sobre 2 individuos elegidos aleatoriamente de la población de padres.
- ♣ **Panmíticos:** se elige un solo padre al azar, y se mantiene fijo mientras se elige al azar un segundo padre (de entre toda la población) para cada componente de sus vectores.

Las estrategias evolutivas simulan el proceso evolutivo al nivel de los individuos, por lo que la recombinación es posible. Asimismo, usan normalmente selección determinística.

2.2.2.5 Aplicaciones

Algunas aplicaciones de las estrategias evolutivas son:

- ♣ Problemas de rutas y redes
- ♣ Bioquímica
- ♣ Óptica
- ♣ Diseño en ingeniería
- ♣ Magnetismo

2.2.3 Algoritmos genéticos

Los comienzos de los algoritmos genéticos se encuentran a principios de la década de los 50, cuando varios biólogos usaron computadores para la simulación de sistemas biológicos [Goldberg 89]. Sin embargo, el trabajo desarrollado a finales de los 60 y principios de los 70 en la Universidad de Michigan bajo la dirección de John Holland [Holland 75] condujo a lo que hoy se conoce como *algoritmos genéticos*.

Un algoritmo genético es una técnica estocástica de optimización cuyo método de búsqueda imita algunos fenómenos naturales tales como la herencia genética y la lucha por la supervivencia.

Al igual que el resto de técnicas evolutivas, un algoritmo genético mantiene un conjunto (población) de representaciones codificadas de soluciones del problema a resolver (individuos). Cada uno de estos individuos se evalúa en términos de algún parámetro de optimalidad. En función de esta medida, los mejores individuos son seleccionados para ser padres de la siguiente generación (población de la próxima generación del algoritmo). Estos mejores individuos son alterados por medio de algún operador genético (cruce, mutación, elitismo, etc.) con el fin de obtener cada vez una mejora en la medida de calidad.

La principal diferencia de los algoritmos genéticos con respecto al resto de técnicas evolutivas se encuentra en la codificación de las soluciones y en la relevancia del operador cruce frente al operador mutación. El operador cruce obtiene nuevos individuos (individuos hijos) mediante la combinación de dos individuos de la población actual (individuos padres).

El operador mutación obtiene un individuo nuevo mediante la alteración aleatoria de la estructura del individuo original.

Debido a que esta técnica es la base sobre la que se han obtenido los resultados de esta tesis, se dedicará un capítulo, más adelante, mucho más extenso donde se hablará de los principales paradigmas de la misma.

2.2.3.1 Estructura algorítmica

El algoritmo genético enfatiza la importancia de la cruce sexual (operador principal) sobre el de la mutación (operador secundario), y usa selección probabilística.

El algoritmo básico es el siguiente:

- 🍏 Generar (aleatoriamente) una población inicial.
- 🍏 Calcular aptitud de cada individuo.
- 🍏 Seleccionar (probabilísticamente) en base a aptitud.
- 🍏 Aplicar operadores genéticos (cruza y mutación) para generar la siguiente población.
- 🍏 Ciclar hasta que cierta condición se satisfaga.

La representación tradicional es la binaria, tal y como se ejemplifica en la figura 2.8.




Figura 2.8 Codificación binaria en algoritmos genéticos

A la cadena binaria se le llama “cromosoma”. A cada posición de la cadena se le denomina “gene” y al valor dentro de esta posición se le llama “alelo”.

Para poder aplicar el algoritmo genético se requiere de los 5 componentes básicos siguientes:

- 🍏 Una representación de las soluciones potenciales del problema.
- 🍏 Una forma de crear una población inicial de posibles soluciones (normalmente un proceso aleatorio).
- 🍏 Una función de evaluación que juegue el papel del ambiente, clasificando las soluciones en términos de su “aptitud”.
- 🍏 Operadores genéticos que alteren la composición de los hijos que se producirán para las siguientes generaciones.
- 🍏 Valores para los diferentes parámetros que utiliza el algoritmo genético (tamaño de la población, probabilidad de cruza, probabilidad de mutación, número máximo de generaciones, etc.)

2.2.3.2 Aplicaciones

Algunas aplicaciones de los AGs son las siguientes:

- 🍏 Optimización (estructural, de topologías, numérica, combinatoria, etc.)
- 🍏 Aprendizaje de máquinas (sistemas clasificadores)
- 🍏 Bases de datos (optimización de consultas)
- 🍏 Reconocimiento de patrones (por ejemplo, imágenes)
- 🍏 Generación de gramáticas (regulares, libres de contexto, etc.)
- 🍏 Planeamiento de movimientos en robots
- 🍏 Predicción

2.2.4 Diferencias, ventajas e inconvenientes de las técnicas evolutivas respecto de las tradicionales

A pesar de la extensa utilización en muy diversas disciplinas, es interesante analizar qué aportan las técnicas evolutivas respecto de las técnicas tradicionales así como discutir acerca de su bondad y de sus deficiencias.

En primer lugar habría que enumerar varias diferencias que vale la pena destacar entre los algoritmos evolutivos y las técnicas tradicionales de búsqueda y optimización según [Buckles 86] y [Goldberg 89]:

- 🍏 Las técnicas evolutivas usan una población de soluciones potenciales en vez de un solo individuo, lo cual las hace menos sensibles a quedar atrapadas en mínimos/máximos locales.
- 🍏 Las técnicas evolutivas no necesitan conocimiento específico sobre el problema que intentan resolver.
- 🍏 Las técnicas evolutivas usan operadores probabilísticos, mientras las técnicas tradicionales utilizan operadores determinísticos.

- Aunque las técnicas evolutivas son estocásticas, el hecho de que usen operadores probabilísticos no significa que operen de manera análoga a una simple búsqueda aleatoria.

Por otro lado, y basándonos en lo anterior, se pueden derivar una serie de ventajas que presenta el uso de técnicas evolutivas para resolver problemas de búsqueda y optimización [Goldberg 89] y [Fogel 95]:

- Simplicidad Conceptual.
- Amplia aplicabilidad.
- Superioridad frente a las técnicas tradicionales en muchos problemas del mundo real.
- Tienen el potencial para incorporar conocimiento sobre el dominio y para mezclarse o apoyarse, con otras técnicas de búsqueda/optimización.
- Pueden explotar fácilmente las arquitecturas en paralelo.
- Son robustas a los cambios dinámicos.
- Generalmente pueden auto-adaptar sus parámetros.
- Capaces de resolver problemas para los cuales no se conoce solución alguna.

Al igual que cualquier técnica o metodología novedosa, es importante no sólo analizar sus virtudes principales sino también hacer hincapié en los defectos o puntos débiles que pueden presentar este tipo de técnicas, sobre todo para problemas ampliamente tratados y con soluciones conocidas y efectivas.

Los algoritmos evolutivos fueron muy criticados en sus orígenes (años sesenta), y todavía siguen siendo blanco de ataques por parte de ciertos investigadores relacionados con el campo de la *Inteligencia Artificial (IA)* simbólica [Fogel 99, Fogel 95]. Se creía, por ejemplo, que una simple búsqueda aleatoria podía superarlas. De hecho, algunos investigadores lograron mostrar dicha situación en algunas de las primeras aplicaciones de la computación evolutiva en los años sesenta, aunque tal circunstancia se debió más bien a limitaciones en la capacidad de cómputo y fallos en los modelos matemáticos adoptados en aquella época.

La programación automática fue considerada también como una “moda pasajera” en IA y el enfoque evolutivo fue visto como “un intento más” por lograr algo que lucía imposible. Sin embargo, los resultados obtenidos en los últimos años con programación genética [Koza 03, Koza 99, Koza 94, Koza 92] hacen ver que el poder de la computación evolutiva en el campo de la programación automática es mayor del que se creía en los 1960s.

Actualmente, todavía muchas personas creen que un AG funciona igual que una técnica “escalando la colina” que comienza de varios puntos. Se ha demostrado que esto no es cierto, aunque el tema sigue siendo objeto de acalorados debates.

Las técnicas sub-simbólicas (redes neuronales y computación evolutiva) gozan de gran popularidad entre la comunidad científica en general, excepto por algunos especialistas de IA clásica que las consideran “mal fundamentadas” e “inestables”.

2.3 Algoritmos genéticos

Según se introdujo anteriormente, un algoritmo genético es una técnica estocástica de optimización cuyo método de búsqueda imita algunos fenómenos naturales tales como la herencia genética y la lucha por la supervivencia.

Al igual que el resto de técnicas evolutivas, un algoritmo genético mantiene un conjunto (población) de representaciones codificadas de soluciones del problema a resolver (individuos). Cada uno de estos individuos se evalúa en términos de algún parámetro de optimalidad. En función de esta medida, los mejores individuos son seleccionados para ser padres de la siguiente generación (población de la próxima generación del algoritmo). Estos mejores individuos son alterados por medio de algún operador genético (cruce, mutación, elitismo, etc.) con el fin de obtener cada vez una mejora en la medida de calidad.

Como puede apreciarse, las técnicas evolutivas se nutren de un vocabulario procedente de la biología y la genética. Bajo esta observación, se define todo un conjunto de aspectos y conceptos que tienen una relación unívoca con cada uno de los parámetros empleados en ambos campos: el algorítmico y el de la biogenética.

Denominamos **cromosoma** a una estructura de datos que contiene una cadena de parámetros de diseño o genes. Esta estructura de datos puede almacenarse, por ejemplo, como una cadena de bits o un array de enteros (ver figura 2.9).




Figura 2.9 Ejemplo de cromosoma con codificación binaria.

Se llama **gen** a un trozo de cromosoma que suele codificar el valor de un solo parámetro (ver figura 2.10).




Figura 2.10 Ejemplo de gen dentro de un cromosoma

Se denomina **genotipo** a la codificación (por ejemplo, binaria) de los parámetros que representan una solución del problema a resolverse (ver figura 2.9).

Se denomina **fenotipo** a la decodificación del cromosoma. Es decir, a los valores obtenidos al pasar de la representación (binaria) a la usada por la función objetivo (ver figura 2.11).




Figura 2.11 Ejemplo de Fenotipo

Se denomina **individuo** a un solo miembro de la población de soluciones potenciales de un problema. Cada individuo contiene un cromosoma (o de manera más general, un genoma) que representa una solución posible al problema a resolverse.

Se denomina **aptitud** al valor que se asigna a cada individuo y que indica lo bueno que es éste con respecto a los demás para la solución de un problema.

Se denomina **alelo** a cada valor posible que puede adquirir una cierta posición genética. Si se usa representación binaria, un alelo puede valer 0 ó 1.

Llamamos **generación** a una iteración de la medida de aptitud y a la creación de una nueva población por medio de operadores de reproducción.

Una población puede subdividirse en grupos a los que se denomina subpoblaciones.

En el caso de optimización de tensiones utilizando transformadores con tomas, cada gen proporciona la información relativa al estado de la toma de un transformador cualquiera. En función de la posición que ocupe dentro del cromosoma, se tratará de un transformador u otro, siendo el alelo sería el valor del estado de la toma (para representación entera, puede variar en un rango preestablecido). El cromosoma o genotipo es el conjunto de genes que representa una solución del problema. El fenotipo de ese conjunto de genes es el conjunto de tomas de los transformadores de la red, es decir, la secuencia de posiciones que deben adoptarse en los transformadores para llevar a la red al óptimo.

Un algoritmo genético representa una búsqueda a través de un espacio de soluciones potenciales. Una búsqueda de este tipo requiere establecer un balance entre dos objetivos opuestos: explotar la información proporcionada por las mejores soluciones encontradas y explorar el espacio de búsqueda. La técnica de búsqueda “miope” es un ejemplo de estrategia que explota las mejores soluciones encontradas. La búsqueda aleatoria es, por el contrario, un ejemplo de técnica orientada a explorar el espacio de soluciones sin hacer uso de la información de las mejores soluciones halladas. Los algoritmos genéticos son un tipo de algoritmos de búsqueda de propósito general que llevan a cabo un compromiso entre estos dos objetivos.

Los algoritmos genéticos están orientados a la resolución de problemas que no son resolubles mediante técnicas de optimización convencionales. Las principales características de estos problemas son su carácter no lineal, combinatorio, no convexo, no diferenciable, de gran dimensión, entero-mixto, con gran número de restricciones, etc. Los algoritmos genéticos pertenecen a la clase de algoritmos probabilistas pero, a diferencia de los algoritmos aleatorios, combinan elementos de búsqueda conducida y estocástica. Debido a esto, los algoritmos genéticos son más eficaces que las técnicas de búsqueda conducida.

Otra propiedad importante es que mantienen un conjunto de soluciones potenciales en lugar de obtener un único punto del espacio de búsqueda. A diferencia de lo que ocurre con las técnicas de búsqueda miope o con el recocido simulado (*simulated annealing*) [van Laarhoven 87], los algoritmos genéticos llevan a cabo una búsqueda multi-direccional manteniendo una población de soluciones potenciales del problema. La población experimenta una evolución simulada: en cada generación los individuos “buenos” tienden a reproducirse, mientras que los individuos “malos” desaparecen. Para

distinguir entre las distintas soluciones se usa una función de medida de la calidad basada en la función objetivo del problema a resolver.

Los algoritmos genéticos se diferencian de las técnicas de optimización convencionales en cuatro aspectos:

1. Los algoritmos genéticos emplean información de la función objetivo (evaluación de una función determinada usando la estructura codificada de cada solución) para guiar la búsqueda, en lugar de sus derivadas primeras y/o segundas, o cualquier otra información auxiliar.
2. Para realizar la búsqueda, los algoritmos genéticos usan una codificación de las variables que sirven para calcular la función objetivo, en lugar de hacer uso de las propias variables.
3. Los algoritmos genéticos analizan simultáneamente muchos puntos en el espacio de búsqueda, no un único punto.
4. Los algoritmos genéticos utilizan reglas probabilistas para pasar de un conjunto de soluciones (población) al siguiente.

La estructura de un algoritmo genético simple es idéntica a la de cualquier técnica evolutiva (véase figura 2.6). Durante cada iteración o generación, el algoritmo genético mantiene una población de soluciones. Cada solución se evalúa para obtener una medida de su calidad. A continuación, se crea una nueva población mediante la selección aleatoria de los mejores individuos. Algunos miembros de la nueva población experimentan alteraciones aleatorias en su estructura por medio de operadores como el cruce o la mutación. El objetivo de estas alteraciones es la obtención de nuevos individuos, de forma que la exploración del espacio de búsqueda sea lo más exhaustiva posible. Los operadores selección, cruce y mutación serán descritos posteriormente.

Los principales elementos que componen un algoritmo genético son pues los siguientes:

- Representación genética o codificación de las soluciones potenciales del problema a resolver.
- Creación de la población inicial de soluciones.
- Determinación de la función de evaluación para medir la calidad de las distintas soluciones.

- Uso de operadores genéticos para alterar la composición de los individuos.
- Establecimiento de valores de los parámetros que intervienen en todo algoritmo genético (tamaño de la población, probabilidades de aplicación de cada uno de los operadores, etc.).
- Tratamiento de las restricciones del problema.

A continuación se detalla cada uno de estos elementos fundamentales en el funcionamiento de un algoritmo genético.

2.3.1 Representación

La técnica de representación o codificación es el mecanismo por el que las soluciones del problema a resolver se representan para su manipulación durante el proceso evolutivo. Como se mencionó anteriormente, una codificación adecuada es un punto clave a la hora de implantar un algoritmo genético. La elección de una representación u otra dependerá básicamente del problema a resolver. Sin embargo, para cada problema habrá un abanico de posibles representaciones y la elección de la más adecuada permitirá una mejor adaptación del algoritmo al problema.

La codificación más usada es la binaria, aunque también se emplean con frecuencia la codificación por medio de números reales y enteros. La codificación binaria ha sido tradicionalmente empleada para prácticamente todos los problemas a los que se ha aplicado la técnica de algoritmos genéticos. Consiste en convertir cada variable que interviene en el problema en su equivalente binario (ceros y unos). Estas variables binarias se yuxtaponen para dar lugar al individuo que va a representar cada solución del problema. A partir de esta codificación se ha generado gran parte del fundamento matemático que existe para explicar el funcionamiento de los algoritmos genéticos (“*teorema de los esquemas*”).

La codificación mediante números reales o enteros ha surgido posteriormente debido a que la mayoría de los problemas de ingeniería a los que se han aplicado los algoritmos genéticos cuentan con variables de este tipo. El empleo de codificación binaria genera problemas [Ronald 97], como lo siguientes:

- **Epístasis:** el valor de un bit puede suprimir las contribuciones de aptitud de otros bits en el genotipo.

- **Representación natural:** algunos problemas (como el del viajero) se prestan de manera natural para la utilización de representaciones de mayor cardinalidad que la binaria (por ejemplo, el problema del viajero se presta de manera natural para el uso de permutaciones de enteros decimales).
- **Soluciones ilegales:** los operadores genéticos utilizados pueden producir con frecuencia (e incluso todo el tiempo) soluciones ilegales si se usa una representación binaria.

Además al codificar estas variables como binarias se pierde parte de la información, debido a que hay que elegir un número finito de posiciones decimales. La codificación mediante números reales o enteros consiste simplemente en yuxtaponer cada una de las variables del problema dando lugar a cadenas de variables que representan las soluciones potenciales del problema a resolver.

Hay otros tipos de representaciones específicas que no se usan de forma general. Su elección depende del tipo de problema de que se trate y los operadores genéticos deberán adaptarse al tipo de codificación elegida.

A modo de ejemplo se presenta un escenario de resolución. Supóngase que se quiere minimizar la siguiente función:

$$f(x_1, x_2) = 3x_1 + 5x_2 \quad (2.1)$$

donde x_1 y x_2 son las variables del problema.

Además pueden existir unos límites en las variables que vienen expresados por las siguientes restricciones:

$$20 \leq x_1 \leq 100 \quad (2.2)$$

$$50 \leq x_2 \leq 80 \quad (2.3)$$

$$x_1 + x_2 = 90 \quad (2.4)$$

La solución óptima de este problema es:

$$x_1^* = 40, x_2^* = 50, f^* = 370$$

Se considerará cromosoma o individuo a la yuxtaposición de las cadenas que representan a cada variable. Para la representación binaria de cada variable, se va a suponer una precisión de 4 posiciones decimales. El dominio de la variable x_1 tiene una

longitud igual a 80. El requisito de precisión obliga a que el rango [20,100] debe ser dividido en, al menos 80×10.000 intervalos de igual tamaño. Esto significa que se necesitan 20 bits para representar la primera parte del cromosoma ya que:

$$2^{19} < 80.000 \leq 2^{20}$$

Para la variable x_2 el rango [50,80] debe ser dividido en, al menos 30×10.000 intervalos de igual tamaño para cumplir con la precisión requerida. Esto implica que se necesitan 19 bits para representar la segunda parte de cada individuo:

$$2^{18} < 30.000 \leq 2^{19}$$

La longitud total de un cromosoma es 39 bits, los primeros 20 para representar a x_1 y los 19 restantes para codificar x_2 . Supóngase el siguiente individuo:

(00000000000010000100|1000000000000000111)

Este individuo representa la siguiente solución:

(20,001|65,0004)

El valor de la función objetivo para esta solución es:

$$f = 3 \times 20,001 + 5 \times 65,0004 = 385,032$$

En la representación por medio de números reales cada cromosoma se codifica mediante un vector de números reales, de la misma longitud que el vector solución, en este caso, dos. Cada elemento lleva implícito los límites establecidos por las restricciones (2.2) y (2.3). La precisión de esta codificación depende de la máquina sobre la que se ejecuta el algoritmo, pero es generalmente mucho mejor que la de la representación binaria. Naturalmente, la precisión de la codificación binaria se puede siempre hacer igual a la de la representación real mediante la introducción de más bits, pero a costa de una reducción considerable de la velocidad del algoritmo.

Con esta codificación la solución anterior se representa de esta forma:

(20,0100|65,0004)

Esta representación no tiene el inconveniente de establecer una precisión mínima y tampoco requiere de un proceso de decodificación.

2.3.2 Población Inicial

Una vez decidido el esquema de representación, el primer paso en la estructura del algoritmo genético es crear una población inicial. Habitualmente, esto se consigue generando una distribución aleatoria de individuos uniformemente repartida en el rango de búsqueda de nuestras variables. Por ejemplo, para una población binaria de N_{ind} individuos cuyos cromosomas tienen una longitud (L_{ind}) en bits, se debería producir una distribución aleatoria uniforme de $N_{ind} \times L_{ind}$ números en el del conjunto $\{0,1\}$.

Algunos investigadores [Bramlette 91] han obtenido otros procedimientos donde se producen inicializaciones aleatorias para cada individuo y se escogen aquellos con mejor rendimiento o prestación para la población inicial.

Además de la inicialización aleatoria, otros autores [Grefenstette 87] han propuesto, como semillas para la población inicial, individuos que se saben están cerca de la solución óptima. Esta aproximación es, por supuesto, aplicable solamente si se conoce de antemano la naturaleza del problema o si el algoritmo genético se usa en conjunción con sistemas expertos.

En nuestro caso, la elección de la población inicial puede parecer que deba responder a criterios no aleatorios, ya que las tomas de los transformadores así como las tensiones de un sistema eléctrico en explotación normal, es decir, en estado seguro o sin contingencias graves, están centradas (con desviaciones no muy elevadas) en los valores nominales, esto es, toma 0 para transformadores y tensión 1,00 (en p.u.). Pues bien, tras diferentes pruebas y variaciones, se ha comprobado (como se verá más adelante) que la convergencia del algoritmo es mejor en el caso de poblaciones aleatorias que poblaciones “dirigidas” o “vecinas” que se suponen están más cerca del valor óptimo.

2.3.3 Función objetivo y aptitud

La función objetivo se usa para proporcionar una medida de cómo se han “comportado” los individuos en el dominio del problema. Para el caso de minimización, los individuos más aptos tendrán el valor numérico más bajo de la función objetivo asociada. Esta medida (en bruto) de la aptitud es, realmente, un estado intermedio a la hora de determinar el comportamiento relativo de los individuos de un algoritmo genético. Existe otra función, denominada *función de aptitud o evaluación*, que se usa

normalmente para transformar la función objetivo en una medida de la aptitud relativa [De Jong 75].

En los problemas de optimización la función de evaluación ha de estar relacionada con la función objetivo de estos problemas. De esta forma, si el problema es de minimización la función de evaluación empleada por el algoritmo genético debe estar relacionada con la inversa de la función objetivo, de tal manera que las soluciones con función objetivo baja tendrán una medida de calidad elevada. Para problemas de maximización, la función de evaluación será una función proporcionalmente relacionada con la función objetivo.

Los algoritmos genéticos que emplean estas funciones de evaluación directamente ligadas con la función objetivo deben ser capaces de llevar a cabo un compromiso entre la exploración del espacio de búsqueda y la explotación de los mejores individuos. Para ello, la elección de una medida de la calidad adecuada es fundamental, pues, por un lado, debe proporcionar valores que permitan diferenciar entre individuos buenos y malos; pero, al mismo tiempo, debe permitir la coexistencia de ambos tipos de individuos para que el espacio de búsqueda no quede muy restringido.

Matemáticamente podemos expresar la función de aptitud según

$$F(x) = g(f(x)) \quad (2.5)$$

donde f es la función objetivo, g es una operación de transformación de la función objetivo en valores no negativos y F es la aptitud resultante. Esta transformación es siempre necesaria cuando la función objetivo es de minimización ya que los valores más bajos corresponderán con individuos más aptos. En muchas ocasiones, los valores de la función de aptitud o evaluación, se corresponden con el número de descendientes que se espera de un individuo pueda producir en la siguiente generación. Una transformación que se usa con frecuencia, es la que asigna una aptitud proporcional [Goldberg 89]. La aptitud de un individuo, $F(x_i)$, se calcula como el cociente entre el valor de la función objetivo para el individuo, $f(x_i)$, y el valor de población entera

$$F(x_i) = \frac{f(x_i)}{\sum_{i=1}^{N_{ind}} f(x_i)} \quad (2.6)$$

donde N_{ind} es el tamaño de la población y x_i es valor fenotípico del individuo i . En tanto que la asignación de aptitud asegura que cada individuo tiene una probabilidad de

reproducirse de acuerdo a dicha aptitud, hay que tener en cuenta que esto falla cuando se trabaja con valores negativos de la función objetivo.

Para evitar este inconveniente, se realiza una transformación lineal con anterioridad a la asignación de aptitud, la cual introduce una compensación en la función objetivo

$$F(x) = af(x) + b \quad (2.7)$$

donde a es un factor de escala positivo si se está maximizando o negativo si se está minimizando. El elemento de compensación, b , se usa para asegurar que los valores de aptitud no son negativos.

El escalado lineal y la compensación descrita anteriormente es, sin embargo, susceptible de converger rápidamente. Más adelante se detallará el algoritmo de selección que escoge individuos para reproducirse según su aptitud relativa. Si se usa el escalado lineal, el número de descendientes esperado es aproximadamente proporcional al rendimiento de esos individuos. Como no existen restricciones en el rendimiento de cada individuo para una generación dada, los individuos con alta aptitud pueden dominar la reproducción en las etapas iniciales y provocar una rápida convergencia hacia posibles óptimos locales. Igualmente, si existe una pequeña desviación en la población, entonces el escalado proporciona sólo un pequeño sesgo en pos de los individuos con mejor aptitud.

Algunos autores como [Baker 85] han sugerido que limitando el grado de reproducción, de forma que ningún individuo genera un número de descendientes excesivo, se puede prevenir la convergencia prematura. Bajo esta premisa, a los individuos se les asigna una aptitud de acuerdo con el lugar que ocupan en la población más que con su rendimiento original. Se utiliza una variable, max , que determina el sesgo, también llamado *presión selectiva*, hacia los individuos de mayor aptitud, mientras que la aptitud del resto se determina siguiendo las siguientes reglas

$$\begin{aligned} min &= 2.0 - max \\ inc &= 2.0 \times \frac{max - 1.0}{N_{ind}} \\ low &= inc / 2.0 \end{aligned}$$

donde min es la cota inferior, inc es la diferencia entre aptitudes de individuos vecinos y low es el número de evaluaciones esperado (número de veces seleccionado) del individuo menos apto. De esta forma, se puede calcular la aptitud de la población a través de la siguiente expresión

$$F(x_i) = 2 - max + 2(max - 1) \frac{x_i - 1}{N_{ind} - 1} \quad (2.8)$$

donde x_i es la posición del individuo i en la población ordenada.

Esta situación se puede complicar aún más utilizando otro tipo de funciones que aporten no-linealidad al problema. Por ejemplo, algunos autores [Whitley 89] han propuesto utilizar

$$F(x_i) = \frac{N_{ind} X^{x_i - 1}}{\sum_{i=1}^{N_{ind}} X(i)} \quad (2.9)$$

donde X es igual a la raíz del polinomio

$$0 = (max - 1) \times X^{N_{ind} - 1} + max \times X^{N_{ind} - 2} + \dots + max \times X + max \quad (2.10)$$

2.3.4 Selección

Se llama selección al proceso mediante el cual se determina el número de veces que un individuo concreto es elegido para reproducirse y, por lo tanto, el número de descendientes que un individuo producirá. El proceso de selección puede verse como dos subprocesos encadenados

- a) Determinación del número de apareamientos que un individuo espera recibir
- b) Conversión del número esperado de apareamientos en un número discreto de descendientes.

El punto primero tiene que ver con la transformación de los valores originales de aptitud en valores reales de probabilidad o expectativa de reproducirse de un individuo, que ya ha sido tratado en el punto 2.3.3 donde se habla de asignación de aptitud. El segundo punto tiene que ver con la probabilidad de selección de un individuo para reproducirse basándose en la aptitud relativa de un individuo respecto de otro y que se conoce como *muestreo*.

Según presenta Baker [Baker 87], se pueden establecer tres parámetros que caracterizan la eficacia y precisión del algoritmo de selección

- **Sesgo.** Se define como la diferencia absoluta entre la probabilidad real y la probabilidad esperada de selección a un individuo. El sesgo óptimo es cero y

se consigue cuando la probabilidad de selección de un individuo coincide con el número esperado de apareamientos.

- **Amplitud.** Se define como el conjunto de posibles valores que puede tomar el número real de apareamientos de un individuo. Se define la amplitud mínima como la menor amplitud que permite un sesgo nulo.
- **Complejidad computacional o eficiencia.** Establece la relación existente entre el tiempo empleado por el algoritmo de muestreo y los parámetros del algoritmo (tamaño de la población, longitud de los individuos, etc.). Es deseable que la complejidad de esta fase sea lo más próxima posible a una función lineal del número de individuos que forman la población, que es la complejidad óptima. La función $O(n)$ es la complejidad computacional y n representa el tamaño de la población.

Las técnicas de selección usadas en algoritmos genéticos pueden clasificarse en tres grandes grupos:

- Selección proporcional
- Selección mediante torneo
- Selección de estado uniforme

2.3.4.1 Selección proporcional

Este nombre describe a un grupo de esquemas de selección originalmente propuestos por Holland [Holland 75] en los cuales se eligen individuos de acuerdo a su contribución de aptitud con respecto al total de la población.

Se suelen considerar 4 grandes grupos dentro de las técnicas de selección proporcional [Goldberg 90]:

1. Muestreo Estocástico o “La Ruleta”
2. Sobrante Estocástico
3. Universal Estocástica
4. Muestreo Determinístico

Es posible incluso hablar de otras técnicas que son clasificadas dentro de la selección proporcional, pero que presentan ciertos aspectos singulares, como la selección de Boltzman o la selección por posición o Jerarquías.

Muestreo Estocástico o Ruleta

Esta técnica, también denominada muestreo estocástico con reemplazamiento, fue propuesta por De Jong [De Jong 75], y ha sido el método más comúnmente usado desde los orígenes de los algoritmos genéticos. El algoritmo es simple, pero ineficiente (su complejidad es $O(n^2)$). Asimismo, presenta el problema de que el individuo menos apto puede ser seleccionado más de una vez.

Los individuos son situados de forma contigua formando segmentos angulares de un círculo, de tal forma que la longitud de cada segmento es igual a la aptitud relativa de cada individuo con respecto a la del resto. A la vez, se genera un número aleatorio (entre 0 y 1), de manera que aquel individuo que es abarcado por el número aleatorio, queda seleccionado. El proceso se repite hasta que se obtiene el número de individuos deseado (población de emparejamiento). Esta técnica es análoga a una ruleta donde cada trozo es proporcional en tamaño a la aptitud del individuo (véase figura 2.12). En este ejemplo se dispone de una población de 6 individuos que han sido situados, convenientemente, según su aptitud, como parte de una ruleta. El tamaño de cada individuo es proporcional a su aptitud. En esta situación, se generan tantos números aleatorios entre 0 y 1 como individuos vayan a ser seleccionadas para el apareamiento. En este caso se han seleccionado 5 individuos, por lo tanto 5 números aleatorios se han generado (p. ej. 0.57, 0.91, 0.69, 0.12 y 0.32).

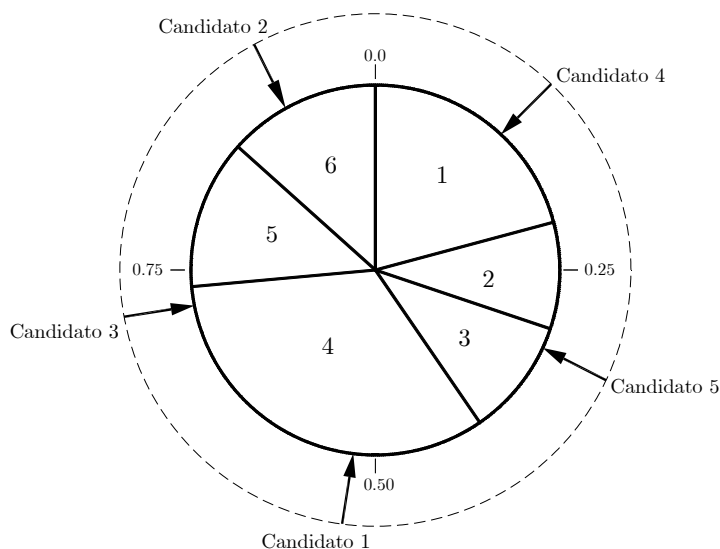


Figura 2.12 Procedimiento de selección en el método de la Ruleta

Los candidatos a aparearse han sido: 1, 3, 4, 4 y 6. De esta forma se obtiene la población de apareamiento.

Individuo	Aptitud	Prob. Selección	Valor esperado
1	3.2	0.205	1.23
2	1.2	0.076	0.45
3	1.3	0.083	0.50
4	5.4	0.346	2.08
5	2.2	0.141	0.85
6	2.3	0.147	0.89

Tabla 2.2 Probabilidades de selección y número esperado de individuos

Es importante reseñar que este algoritmo de selección proporciona un sesgo cero pero no garantiza una mínima amplitud y además tiene, potencialmente, amplitud ilimitada, es decir, un individuo con tamaño mayor que cero, puede ser elegido todas las veces.

Para evitar estos aspectos negativos se puede utilizar una variación conocida como *muestreo estocástico con reemplazamiento parcial*, que consiste en ir reduciendo el tamaño de segmento de un individuo cada vez que es seleccionado, de forma que si se convierte en negativo, su tamaño pasa a ser 0. Esto proporciona una cota superior para la amplitud, aunque la cota inferior puede ser cero y el sesgo es mayor que la ruleta original.

Sobrante estocástico

Propuesta por Booker [Booker 82] y Brindle [Brindle 81] como una alternativa para aproximarse más a los valores esperados de los individuos, definidos como la relación entre la aptitud del individuo y la aptitud media del conjunto.

La idea principal es asignar, determinísticamente, las partes enteras de los valores esperados para cada individuo y luego usar otro esquema (proporcional) para la parte fraccionaria.

El sobrante estocástico reduce los problemas de la ruleta, pero puede causar convergencia prematura al introducir una mayor presión de selección.

Hay 2 variantes principales:

- **Con reemplazo:** Todos los individuos reciben un número mínimo de descendientes igual a la parte entera del número esperado de individuos. Por lo tanto, se proporciona un límite inferior de la amplitud igual al valor esperado. La parte decimal del valor esperado se reparte mediante una ruleta con reemplazo. El

sesgo es nulo pero no hay límite superior de la amplitud. Cualquier individuo con una parte decimal del valor esperado superior a cero puede obtener todos los descendientes durante la asignación basada en la parte decimal. En la tabla siguiente se puede apreciar la distribución para un caso cualquiera.

Individuo	Aptitud	Prob. selección	Valor esperado	Número mín.	Prob. fracc.
1	3.2	0.205	1.23	1	0.23
2	1.2	0.076	0.45	0	0.45
3	1.3	0.083	0.50	0	0.50
4	5.4	0.346	2.08	2	0.08
5	2.2	0.141	0.85	0	0.85
6	2.3	0.147	0.89	0	0.89

Tabla 2.3 Probabilidad de selección y número esperado o de individuos (con reemplazo)

- **Sin reemplazo:** Al igual que en el método anterior, se asigna a cada individuo un número de individuos igual a su parte entera, mientras que para la parte decimal se usa la ruleta. La diferencia es que la probabilidad de selección de una fracción que ya ha sido seleccionada pasa a ser 0. Así se evita que los individuos tengan múltiples descendientes durante la fase decimal. Este método produce amplitud mínima tradicional.

Individuo	Aptitud	Prob. selección	Valor esperado	Número mín.	Número máx.
1	3.2	0.205	1.23	1	2
2	1.2	0.076	0.45	0	1
3	1.3	0.083	0.50	0	1
4	5.4	0.346	2.08	2	3
5	2.2	0.141	0.85	0	1
6	2.3	0.147	0.89	0	1

Tabla 2.4 Probabilidad de selección y número esperado o de individuos (sin reemplazo)

Universal estocástica

El muestreo estocástico universal fue introducido por Baker [Baker 87] con el objetivo de minimizar la mala distribución de los individuos en la población en función de sus valores esperados. El funcionamiento es similar a una ruleta clásica con la salvedad de que en vez de existir un solo puntero, en este caso se generan N punteros igualmente espaciados, donde N es el número de selecciones requeridas. La población se reordena aleatoriamente y se genera un número aleatorio en el rango $[0 \ 1/N]$. Los individuos serán

controle la presión de selección. Se usa un valor alto de temperatura al principio, lo cual hace que la presión de selección sea baja. Con el paso de las generaciones, la temperatura disminuye, lo que aumenta la presión de selección. De esta manera se incita a un comportamiento exploratorio en las primeras generaciones y se acota a uno más explotatorio hacia el final del proceso evolutivo.

Típicamente, se usa la siguiente expresión para calcular el valor esperado de un individuo

$$Valesp(i,t) = \frac{e^{\frac{f_i}{T}}}{\left\langle e^{\frac{f_i}{T}} \right\rangle_t} \quad (2.11)$$

Donde T es la temperatura y $\langle \rangle_t$ denota el promedio de la población en la generación t .

2.3.4.2 Selección mediante torneo

Los métodos de selección proporcional antes descritos requieren de dos pasos a través de toda la población en cada generación:

1. Calcular la aptitud media (y si se usa escalamiento sigma, la desviación estándar).
2. Calcular el valor esperado de cada individuo.

El uso de jerarquías requiere que se ordene toda la población (una operación cuyo costo puede volverse significativo en poblaciones grandes).

La selección mediante torneo es similar a la de jerarquías en términos de la presión de selección, pero es computacionalmente más adecuada para implementarse en paralelo.

Esta técnica fue propuesta por Wetzel [Wetzel 83] y estudiada en la tesis doctoral de Brindle [Brindle 81].

La idea básica del método es seleccionar con base en comparaciones directas de los individuos.

Hay 2 versiones de la selección mediante torneo:

- Determinística
- Probabilística

El algoritmo de la versión determinística es el siguiente:

- Barajar los individuos de la población.
- Escoger un número p de individuos (típicamente 2).
- Compararlos con base en su aptitud.
- El ganador del “torneo” es el individuo más apto.
- Debe barajarse la población un total de p veces para seleccionar N padres (donde N es el tamaño de la población).

Para nuestro ejemplo, si partimos de los datos

Individuo	Aptitud	Orden
1	3.2	(1)
2	1.2	(2)
3	1.3	(3)
4	5.4	(4)
5	2.2	(5)
6	2.3	(6)

se obtendría el siguiente torneo

Torneo 1	
Barajar #1	Ganador
(5)	(5)
(3)	
(4)	(4)
(1)	
(6)	(6)
(2)	

Torneo 2	
Barajar #1	Ganador
(1)	(1)
(6)	
(3)	(5)
(5)	
(2)	(4)
(4)	

Los ganadores del torneo serán los elementos (5) y (1), (4) y (5), (6) y (4).

El algoritmo de la versión probabilística es idéntico al anterior, excepto por el paso en que se escoge al ganador. En vez de seleccionar siempre al individuo con aptitud más alta, se aplica el operador $prob(p)^2$ y si el resultado es cierto, se selecciona al más apto. De lo contrario, se selecciona al menos apto.

El valor de p permanece fijo a lo largo de todo el proceso evolutivo y se escoge en el siguiente rango:

$$0.5 < p \leq 1$$

Observe que si $p=1$, la técnica se reduce a la versión determinística.

En resumen, la selección por torneo presenta una serie de características como son:

- La versión determinística garantiza que el mejor individuo será seleccionado p veces (tamaño del torneo).
- La complejidad del algoritmo es $O(n)$
- La técnica es eficiente y fácil de implementar.
- No requiere escalamiento de la función de aptitud (usa comparaciones directas).
- Puede introducir una presión de selección muy alta (en la versión determinística) porque a los individuos menos aptos no se les da oportunidad de sobrevivir.

2.3.4.3 Selección de estado uniforme

Esta técnica fue propuesta por Whitley [Whitley 89] y se usa en AG's no generacionales, en los cuales sólo unos cuantos individuos son reemplazados en cada generación (los menos aptos).

² $Prob(p)$ indica que es VERDADERO con probabilidad p .

Esta técnica suele usarse cuando se evolucionan sistemas basados en reglas (p.ej., sistemas clasificadores) en los que el aprendizaje es incremental.

En general, la técnica resulta útil cuando los miembros de la población resuelven colectivamente (y no de manera individual) un problema.

Asimismo, los AG's generacionales se usan cuando es importante "recordar" lo que se ha aprendido antes.

El algoritmo de la selección de estado uniforme es el siguiente:

- Llamaremos G a la población original de un AG.
- Seleccionar R individuos $1 \leq R < M$ de entre los más aptos. Por ejemplo, $R = 2$.
- Efectuar cruce y mutación a los R individuos seleccionados. Llamaremos H a los hijos.
- Elegir al mejor individuo en H (o a los μ mejores).
- Reemplazar los μ peores individuos de G por los μ mejores individuos de H .

No es muy habitual que se utilice esta técnica debido fundamentalmente a que emplea un mecanismo muy especializado en la selección. Además, los AG's no generacionales suelen ser poco comunes en aplicaciones de optimización.

2.3.4.4 Otras técnicas

Además de las técnicas aquí analizadas, existen otras muchas técnicas especializadas que abordan el problema de la selección desde diferentes perspectivas. Debido a su amplitud, no se entrará más en detalle aunque se pueden consultar las referencias [Dumitrescu 00], [Kuo 93], [Michalewicz 92], [Hillis 90], [Angeline 93], [Sebald 94] y [Bäck 91].

2.3.5 Cruce o Recombinación

En los sistemas biológicos, la cruce es un proceso complejo que ocurre entre parejas de cromosomas. Estos cromosomas se alinean, luego se fraccionan en ciertas partes y posteriormente intercambian fragmentos entre sí.

En computación evolutiva se simula la recombinación intercambiando segmentos de cadenas lineales de longitud fija (cromosomas).

Puede abordarse el estudio del operador cruce desde una doble perspectiva: la idea y el mecanismo [Jones 95]. La idea ya ha sido expuesta: esperar que los bloques constructivos de dos individuos se combinen en un descendiente, dando lugar a un individuo más apto que los progenitores. El mecanismo es el proceso por el que se lleva a la práctica la idea, la forma de implementar el cruce.

Existe una gran variedad de mecanismos, y a ellos se ha dedicado una gran cantidad de literatura, [Holland 75], [Syswerda 89], [Michalewicz 92]. Desde la forma original y más simple (el cruce monopunto para cadenas binarias), los mecanismos de cruce han evolucionado buscando, en unos casos una mayor eficiencia, y en otros, adaptarse al tipo de codificación o al problema a resolver. A continuación se exponen algunos de los mecanismos de cruce más habituales.

2.3.5.1 Cruce de un punto

Es el mecanismo más sencillo y el empleado en cualquier algoritmo genético básico. En esta técnica, seleccionadas dos cadenas a y b de la población, de longitud l , que actuarán como progenitores, se escoge de manera aleatoria un escalar $k \in [1, l)$. Este valor es el denominado punto de cruce. Conocido éste, se generan dos soluciones “hijas” formadas de la siguiente manera: la primera poseerá los k primeros genes de a y el resto de b , la otra solución hija se formará de manera inversa: con los k primeros genes de b y los restantes de a . El ejemplo de la figura 2.14 muestra un cruce de un punto para soluciones de tamaño 8. El punto aleatoriamente elegido de cruce es el 5.

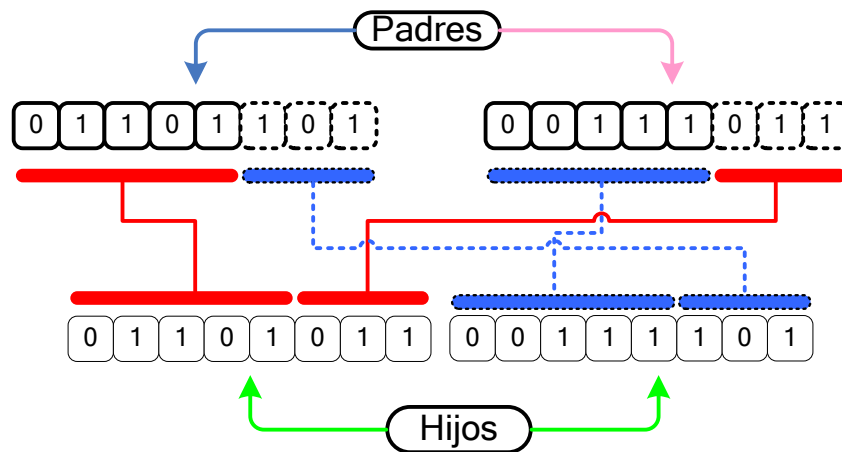


Figura 2.14 Cruce de un punto o monopunto

Como verá más adelante, el funcionamiento de este tipo de cruce es coherente con la hipótesis de los bloques constructivos (ver Apéndice B), dado que permite una alta conservación de los esquemas. Al mantener en la descendencia elementos consecutivos de los padres, se mantienen los esquemas de poca longitud. Sin embargo, esquemas de longitud elevada suponen un grave problema para este tipo de cruce. Sea cual sea el punto de cruce seleccionado, este esquema resultará roto y será imposible de transmitir a la descendencia. Así pues, existirán características de los padres que será imposible transmitir a la descendencia. Para solucionar este inconveniente se desarrolló el cruce de dos puntos o bipunto.

2.3.5.2 Cruce de dos puntos

En esta técnica, seleccionadas dos cadenas a y b de la población, de longitud l , que actuarán como progenitores, se escogen de manera aleatoria dos escalares k_1 y k_2 cumpliendo que $1 \leq k_1 < k_2 \leq l$.

Conocidos los dos puntos de cruce, se generan dos soluciones “hijas” combinando los genes de a y b . El primer descendiente poseerá los k_1 primeros genes de a , los k_1+1 a k_2 genes siguientes de b , y los restantes, de k_2+1 a l serán de nuevo los genes correspondientes de a . El segundo descendiente se forma de manera análoga pero a la inversa.

Puede comprobarse que el esquema representado en la figura 2.15 es ahora heredable por la descendencia. Sin embargo, es posible localizar ahora combinaciones de genes que no podrían ser transmitidos a la descendencia mediante un cruce bipunto. Esto da lugar a generalizar este proceso en los cruces multipunto.

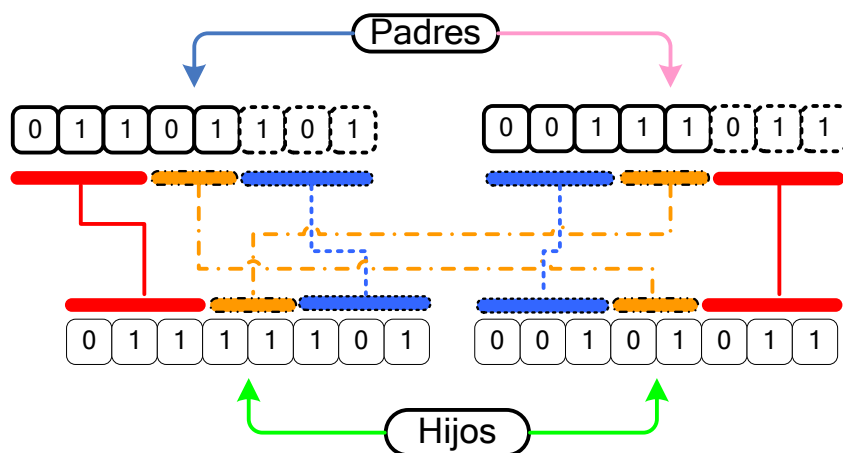


Figura 2.15 Cruce de dos puntos o bipunto

2.3.5.3 Cruce multipunto

Esta técnica consiste en la generalización de los cruces antes mencionados. Se escogen ahora t puntos de cruce para obtener la descendencia por combinación alternada de los genes de los progenitores. El cruce monopunto y el bipunto son cruces multipunto con $t = 1$ y $t = 2$.

La mejora en la capacidad de proceso de los esquemas que puede proporcionar el aumentar el valor de t , se contrarresta con el aumento del tiempo de cálculo necesario para generar la descendencia. Además, De Jong, ya en 1975 (como se indica en [Goldberg 89]) concluyó tras una serie de experimentos, que introducir un número excesivo de puntos de corte reduce la eficacia del algoritmo, al producir la ruptura de la mayor parte de los esquemas. Elevar el valor de t supone realizar una búsqueda más exploratoria que explotadora.

2.3.5.4 Cruce uniforme

El cruce uniforme se lleva a cabo generando una máscara de cruce. Esto no es más que una cadena de la misma longitud que las que se pretende cruzar, poblada aleatoriamente de ceros y unos. La generación de la descendencia es guiada por esa máscara. Uno de los hijos adoptará el valor de los genes del progenitor a en las posiciones en las que la máscara contenga un uno, y los de b en aquellas posiciones en las que en la máscara haya un cero (figura 2.16). El segundo hijo adoptará en cada posición los valores del progenitor contrario al del primer hijo.

El cruce uniforme realiza el intercambio de genes más que de grupos de genes, lo cual parece contradecir la hipótesis de los bloques constructivos. Lo que se realiza es el intercambio de atributos específicos independientemente de la posición que ocupen en la cadena. Esto puede resultar deseable en determinados tipos de problemas, y compensar la destrucción de esquemas que provoca su empleo.

Como se indicó anteriormente, determinados experimentos han concluido que el cruce uniforme ofrece mejores resultados que el cruce monopunto en determinadas tipologías de problemas [Syswerda 89], sin embargo su uso debe adoptarse con precaución y cuando haya motivos fundados para hacerlo.

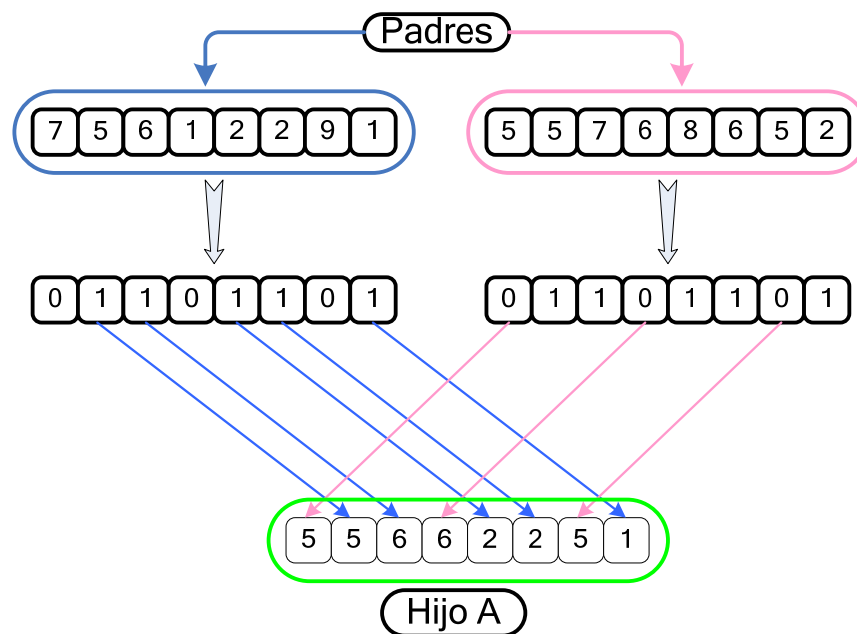


Figura 2.16 Cruce uniforme

2.3.5.5 Mecanismos adicionales a los operadores de cruce

Los diferentes tipos de cruces expuestos pueden modificarse introduciendo mecanismos que permitan aumentar su rendimiento.

Puede considerarse la cadena cromosómica como una estructura anular, en la que el primer y el último gen resultan adyacentes. Otros sistemas desordenan aleatoriamente las posiciones de los genes de ambos progenitores antes de realizar el cruce, volviendo a ordenarlos realizado éste; este procedimiento es denominado cruce con barajado. Prohibir

la aplicación de la mutación sobre los individuos generados por los cruces es otra alternativa denominada cruce solitario.

Un proceso más elaborado es el cruce con adaptación. En estos, la asignación de los puntos de cruce no se realiza de manera aleatoria, sino que sigue un proceso evolutivo análogo al del propio algoritmo. Los puntos de cruce que generan buena descendencia prosperan, los que no, desaparecen.

2.3.5.6 Comparaciones de los diferentes tipos de cruce

Eshelman en 1989 [Eshelman 89], realizó un exhaustivo trabajo de comparación entre diferentes tipologías de cruce, tanto teórica como experimentalmente. Se analizaron las desviaciones posicionales y distributivas de los cruces monopunto, bipunto, multipunto y uniforme entre otros. No fue posible extraer una conclusión respecto a qué técnica superaba en eficiencia a las demás. Las diferencias más grandes apreciadas entre los diferentes tipos de cruces no superaban el 20%.

Como ya se ha indicado, De Jong [Goldberg 89] fue muy crítico con los cruces multipunto, proponiendo el bipunto como el más eficiente. No obstante, cuando la población ha convergido mucho, este tipo de cruce pierde su capacidad para incentivar la exploración del entorno del espacio de soluciones, dado que los segmentos procedentes de los progenitores tienen una alta probabilidad de ser parecidos. El mismo autor propuso una modificación al cruce bipunto en la que, si los segmentos a cruzar para generar la descendencia son parecidos, se escogen dos nuevos puntos de cruce.

Posteriormente, el mismo De Jong y sus colaboradores [De Jong 91], concluyen que el cruce bipunto tiene un buen comportamiento para tamaños de población grande, pero que para tamaños de población pequeños, el efecto de ruptura de esquemas producido por el cruce uniforme resulta beneficioso.

Parece pues, que no es posible afirmar taxativamente qué tipo de cruce es mejor. Simplemente se puede realizar alguna recomendación en función del tipo de problema a resolver. Sin embargo, dados los resultados de Eshelman, no parece que la elección del tipo de cruce sea una decisión crítica a la hora de implementar el algoritmo; no afectará a la eficacia aunque puede que sí afecte a la eficiencia del mismo.

2.3.6 Mutación

El operador mutación altera de forma aleatoria uno o más genes de un cromosoma según una determinada probabilidad de mutación. Para una representación binaria de soluciones, la mutación consiste en cambiar el valor del elemento seleccionado aleatoriamente de 0 a 1 o viceversa. Si, por ejemplo, para el individuo de la figura 2.17 el elemento que ocupa la posición 4 es elegido para ser mutado, su valor pasa de 0 a 1.

Con este operador se introduce diversidad en la población y se recupera posible material genético perdido debido al efecto de la selección y del cruce.

Tradicionalmente, el papel desempeñado por la mutación en el desarrollo de los algoritmos genéticos ha sido secundario frente al operador cruce. Sin embargo, recientes trabajos [Fogel 06] indican que no se puede asegurar que algoritmos genéticos basados fundamentalmente en un operador mutación (con una probabilidad de ocurrencia mayor) en detrimento del cruce, obtengan peores resultados que los algoritmos genéticos convencionales. En otras palabras, el operador cruce puede ser entendido como un operador de mutación masiva.




Figura 2.17 Mutación de un cromosoma binario

2.3.7 Elitismo

Se denomina “*élite de la población*” al individuo o grupo de individuos que destacan sobre el resto por su aptitud. Dado que el procedimiento de selección habitualmente empleado por los algoritmos genéticos implica cierto grado de aleatoriedad, no es posible garantizar que la élite sobreviva a la siguiente generación, y ni siquiera que sea seleccionada como reproductora. Así pues, es posible que las características deseables presentes en la élite desaparezcan de la población. Para evitar esto, las estrategias

elitistas vinculan el tiempo de supervivencia de los individuos con su valor, como solución al problema planteado.

El empleo de estrategias elitistas implica la selección del mejor o los mejores individuos de la población, y su introducción de manera directa en la siguiente generación. Posteriormente, la selección de los criadores se realiza sobre los restantes miembros de la población y, a partir de estos, se genera el resto de la nueva generación.

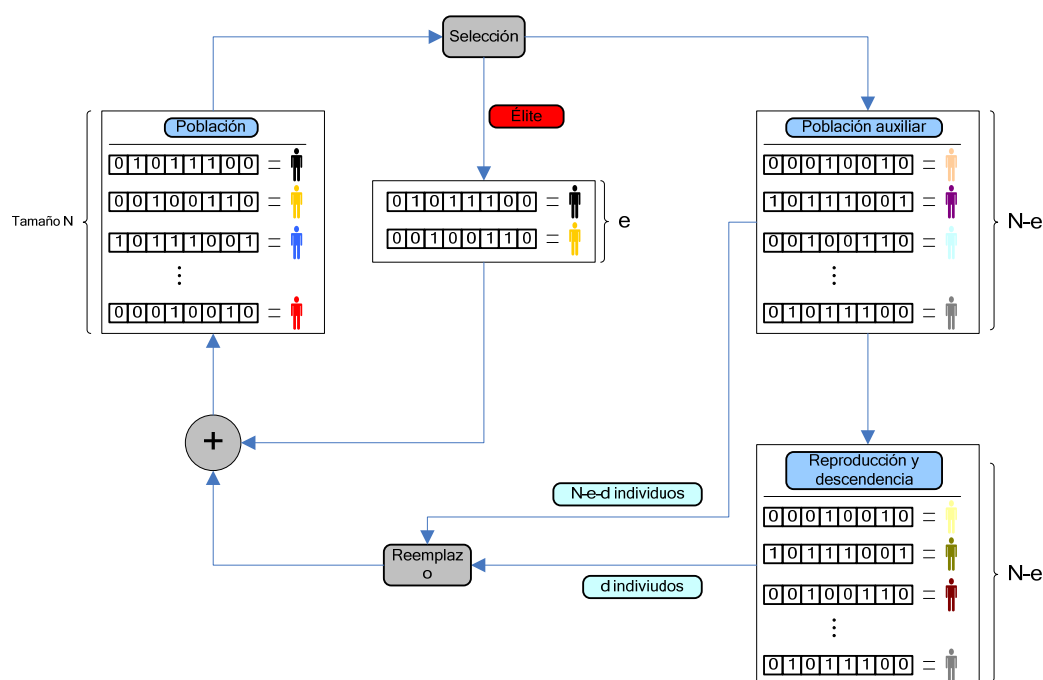


Figura 2.18 Esquema de la aplicación de una estrategia elitista.

El empleo de estrategias elitistas permite una exploración más profusa del espacio de soluciones en el entorno de la élite, pudiendo compararse con una intensificación local de la búsqueda, es decir, tienen tendencia a hacer la búsqueda más explotadora que exploradora.

Su empleo mejora la convergencia del algoritmo, asegurando ésta teóricamente bajo ciertas condiciones muy generales. En caso de funciones de evaluación fuertemente multimodales (con muchos óptimos locales) su eficacia disminuye aumentando el riesgo de convergencia prematura.

El tamaño de la élite es un parámetro fundamental en la obtención de buenos resultados con esta estrategia. Es habitual emplear un tamaño de 1 ó 2 individuos élite

por cada 50 individuos en la población; su empleo en poblaciones pequeñas puede dar como resultado la convergencia prematura debido a la rápida disminución de la diversidad. Es recomendable, además, que las probabilidades de cruzamiento y mutación sean suficientemente grandes para evitar dicha convergencia prematura.

El uso de estrategias elitistas se considera imprescindible por ejemplo, cuando se emplean los algoritmos genéticos para la optimización de funciones en las que se pretende encontrar un óptimo global [De Jong 93].

2.3.8 Manejo de restricciones e individuos no factibles

La solución de un problema general de programación matemática no lineal consiste en encontrar los valores de las variables del problema de forma que se cumplan todas las restricciones y el valor de la función objetivo sea óptimo. No hay ningún método que sea capaz de obtener el óptimo global de este problema de forma general. Tan sólo si la función objetivo y las restricciones cumplen una serie de condiciones, el óptimo puede ser hallado. Se han desarrollado multitud de algoritmos de resolución basados en métodos directos (gradiente, Newton, cuasi-Newton, direcciones conjugadas) o en métodos de descomposición (relajación Lagrangiana, descomposición de Benders). Estos métodos son métodos de optimización local, dependen de la existencia de derivadas y no son lo suficientemente robustos para problemas discontinuos y no convexos. Por todo esto se puede afirmar que aún no se ha encontrado ninguna técnica que sea capaz de resolver de forma general problemas de optimización no lineales, particularmente si incluyen variables enteras.

Los algoritmos genéticos son técnicas estocásticas de búsqueda basadas en heurísticos que se pueden aplicar de forma general a la resolución de este tipo de problemas. Los algoritmos genéticos no necesitan información sobre derivadas, ni requieren ninguna propiedad de convexidad o continuidad en el espacio de búsqueda, ya que esta técnica aísla el proceso de búsqueda de soluciones de la naturaleza de las variables, función objetivo y/o restricciones. Sin embargo, la mayor dificultad al aplicar algoritmos genéticos a problemas con restricciones es la falta de una metodología general para el tratamiento de las mismas.

En la literatura técnica se pueden encontrar varias formas de tratar las restricciones [Siedlecki 89, Michalewicz 91, Powell 93, Schoenauer 93, Smith 93] o, lo que es lo mismo,

de trabajar con procedimientos que originan soluciones infactibles. El óptimo de un problema con restricciones puede estar en la frontera que divide un espacio factible de otro infactible, por lo que al algoritmo genético le es difícil encontrar este punto. Entre los métodos más usados se encuentran

- **Técnica de penalización.** El método se basa en resolver el problema sin tener en cuenta las restricciones y posteriormente se penaliza la función objetivo según el grado de no-cumplimiento de dichas restricciones. [Siedlecki 89, Michalewicz 91, Powell 93, Smith 93, Richardson 89, Kazarlis 96].
- **Técnica de reparación.** El método consiste en alterar la estructura de una solución para que cumpla las restricciones impuestas. Conllevan una carga computacional elevada y pueden desaprovechar la información genética de los individuos infactibles [Smith 93].
- **Técnica para operadores específicos.** Esta técnica introduce estructuras de datos más complejas adaptadas al problema, de manera que aseguran que las restricciones se cumplan de manera implícita.
- **Técnica para restricciones lineales (GENOCOP).** Si el problema tiene restricciones lineales, se pueden transformar en restricciones de desigualdad, las cuales forma un conjunto convexo. Esto asegura que combinaciones de las soluciones actuales, sólo pueden proporcionar soluciones factibles en el espacio de búsqueda [Michalewicz 92, Michalewicz 91].

2.4 Algoritmos Multi-objetivo

Tal y como se ha visto en anteriores apartados, un proceso de optimización consiste en encontrar la solución óptima de entre un conjunto finito de soluciones alternativas. En un contexto mono-objetivo la calidad de una determinada solución viene dada directamente por el valor de aptitud en la función objetivo, pero en un contexto multi-objetivo no existe un óptimo global único, sino varios que optimizan algunos de los objetivos del problema (pero no todos a la vez).

En este apartado se describen los conceptos necesarios para tratar problemas multi-objetivo haciendo uso de optimización basada en frentes de Pareto. Además, se ofrece una breve descripción de las principales técnicas heurísticas multi-objetivo usadas por la comunidad científica, clasificándolas en función de si están basadas en computación

evolutiva, en búsqueda local, o combinan aspectos de diferentes técnicas (técnicas híbridas).

2.4.1 Introducción a la optimización multi-objetivo basada en frentes de Pareto

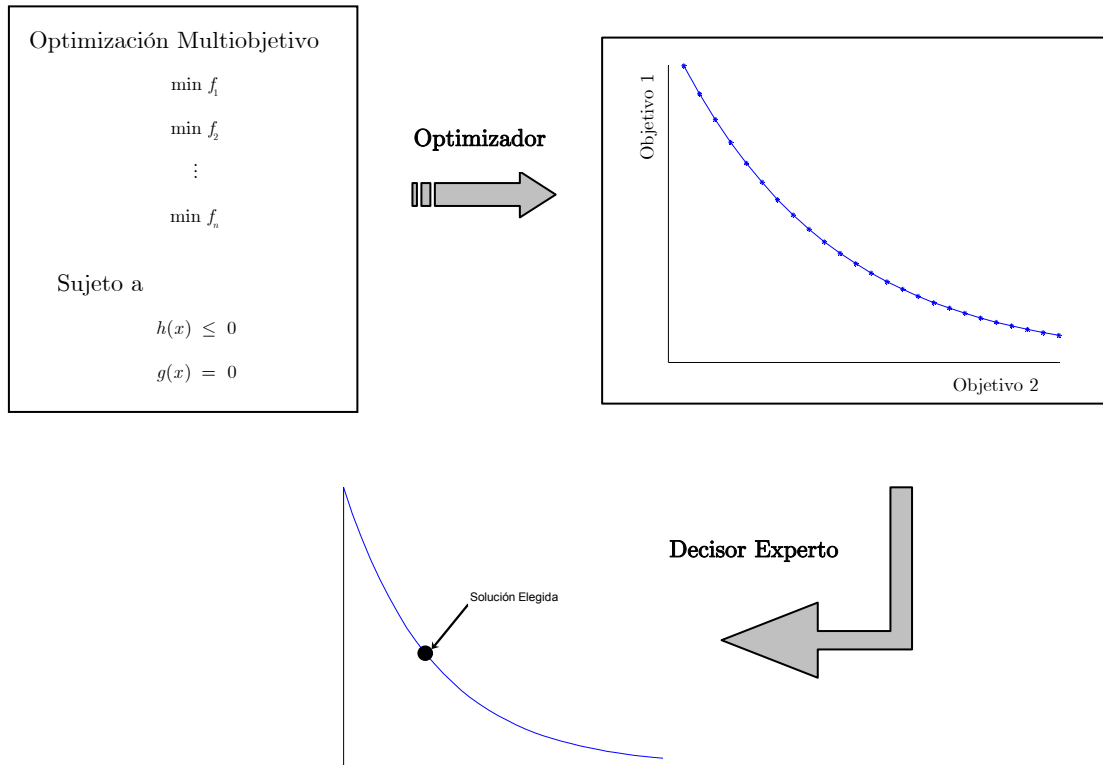
La mayoría de los problemas de optimización reales suelen tener varios óptimos (máximos o mínimos), siendo uno de ellos el óptimo global, mientras que el resto son óptimos locales en el sentido de que es posible definir una vecindad alrededor de ellos en la cual son óptimos globales [Horst 00]. Sin embargo, en muchos casos todos los óptimos absolutos tienen la misma importancia, bien por tener el mismo valor numérico, bien porque no se pueda establecer un criterio que permita decidir cuál de ellos es mejor. Esto sucede en los denominados problemas de optimización multi-objetivo (MOPs) [Coello 00].

Imagínese el caso de un comerciante que tiene que visitar un número concreto de ciudades, y que necesita minimizar, al mismo tiempo, el combustible y el tiempo empleado. A menor tiempo, se empleará mayor combustible y, viceversa, a mayor tiempo, se empleará menor combustible. Ambos presentan la misma importancia por lo que habrá que encontrar diversas soluciones que cubran todo el abanico de posibilidades. Por ejemplo, si se emplean 2 días y 50 litros de combustible, siempre será mejor que emplear 2,5 días y 55 litros. Pero si se emplean 2 días y 45 litros o 2,5 días y 47 litros, no habrá forma de determinar qué solución es la mejor.

Los problemas en los que se obtienen múltiples soluciones de forma que ninguna de ellas se pueda probar mejor que otras suelen tratarse mediante técnicas multi-objetivo específicas, destacando las conocidas como técnicas de optimización basadas en frentes de Pareto [Goldberg 89, Coello 00]. Dicho concepto, que se describe formalmente con posterioridad, trata de encontrar todas las soluciones pertenecientes al conocido como frente Pareto-óptimo. Dicho frente se puede definir como el conjunto de soluciones que no pueden ser mejoradas en todos los objetivos o igualadas en unos y mejorada en otros por ninguna otra solución que también cumpla las restricciones del problema.

Cabe indicar que la utilización de técnicas heurísticas para resolver este tipo de problemas resulta incluso más conveniente al incrementarse la complejidad con respecto a las formulaciones mono-objetivo. Así pues, dichas meta-heurísticas multi-objetivo buscan encontrar el conjunto de soluciones Pareto-óptimas o un conjunto representativo de éste,

de forma que el usuario pueda realizar consideraciones de más alto nivel para elegir una o varias de ellas, tal y como se describe en la siguiente figura.



Definición 2.1. La optimización multi-objetivo (MOO)

Es el proceso de búsqueda de una o más soluciones que satisfagan de forma simultánea todas las restricciones, y optimicen una determinada función que relaciona el espacio de decisión al que pertenecen las soluciones con el espacio objetivo. Para un problema con $K \geq 2$ objetivos, el proceso de optimización consiste en minimizar o maximizar la función objetivo f :

$$\max/\min f_k(s) \quad \forall k \in [1, K]$$

Cada vector de decisión o solución s representa las cualidades numéricas para un problema de optimización multi-objetivo. A diferencia del caso mono-objetivo, en el contexto multi-objetivo la función objetivo f transforma los vectores de decisión desde el espacio de búsqueda hacia un espacio objetivo de K dimensiones $\mathbb{Z} \in \mathbb{R}^k$, $z = f(s)$ donde $f(s) = f\{f_1(s), f_2(s), \dots, f_k(s)\}$ $z \in \mathbb{Z}, s \in F$.

Dado un MOP con $K \geq 2$ objetivos, en lugar de retornar un valor escalar a cada solución, se establecen relaciones parciales de acuerdo a las relaciones de Pareto-dominancia, tal y como se detalla a continuación.

Definición 2.2. Relaciones de Pareto-dominancia

Sean s y s' dos vectores de decisión (soluciones). Las relaciones de dominancia entre vectores de decisión para un problema de minimización son:

s domina a s' ($s \prec s'$) si y solo si $\forall k \in [1, K] \exists k' \in [1, K] : f_k(s) \leq f_k(s') \wedge f_{k'}(s) \neq f_{k'}(s')$

s, s' son indiferentes o incomparables ($s \sim s'$) si y solo si $s \not\prec s' \wedge s' \not\prec s$

Definición 2.3. Solución Pareto-óptima

Una solución s se denomina *Pareto-óptima* si y solo si $\nexists s' \subseteq F$ tal que $s' \prec s$. Todas las soluciones Pareto-óptimas definen el conjunto Pareto-óptimo.

Definición 2.4. Solución no dominada

Una solución $s \subseteq F$ es no dominada con respecto al conjunto $S' \subseteq F$ si y solo si $\nexists s' \subseteq S'$, tal que $s' \prec s$.

Definición 2.5. Conjunto no dominado

Dado un conjunto de soluciones S , tal que $S \subseteq F$, la función $ND(S)$ devuelve el conjunto de soluciones no-dominadas de S : $ND(S) = \{ \forall s \subseteq S \nexists s' \subseteq S : s' \prec s \}$.

Las soluciones Pareto-óptimas no pueden ser mejoradas en ningún objetivo sin causar degradación en al menos otro objetivo, por lo cual se consideran como óptimos globales. No obstante, análogamente a los problemas de optimización de un solo objetivo, existen óptimos locales que son conjuntos no dominados en ciertas áreas locales. La figura 2.19 muestra un ejemplo de dominancia entre soluciones. En la figura 2.19a se puede observar (marcas sólidas) un conjunto de soluciones no dominadas. En la figura 2.19b se muestra la relación entre soluciones. Si se toma la solución de referencia s , puede

observarse como hay soluciones que dominan a s , otras que son dominadas por s , y otras que son incomparables.

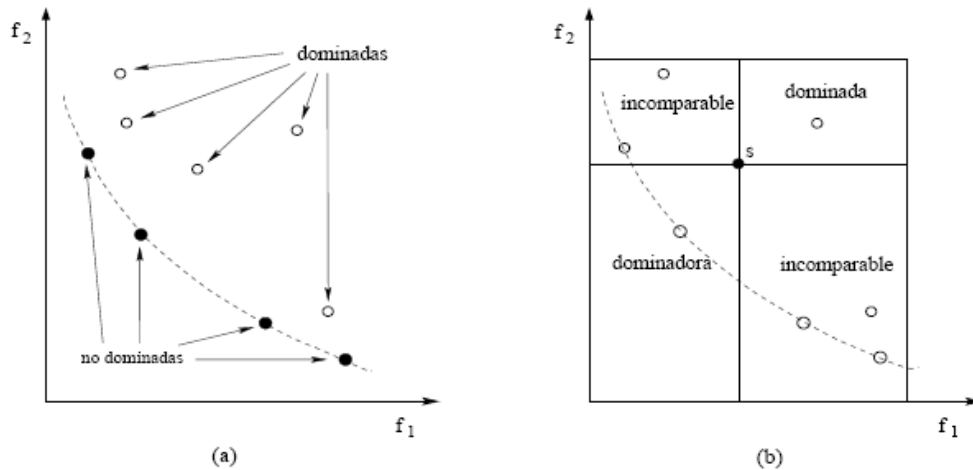


Figura 2.19 Relación de pareto-dominancia

A la hora de implementar un algoritmo multi-objetivo se deben considerar los siguientes objetivos de diseño:

- Se debe minimizar la distancia entre las soluciones no dominadas encontradas por el algoritmo y la frontera de Pareto
- Las soluciones encontradas deben de representar la totalidad de la región Pareto-óptima
- La distribución de las soluciones encontradas a lo largo de la región Pareto-óptima debería ser lo más uniforme posible.

Por todo ello, a la hora de evaluar el comportamiento de cualquier algoritmo, resulta necesario hacer uso de medidas adecuadas para evaluar cada uno de los aspectos anteriormente descritos, de forma que las conclusiones obtenidas sean robustas. En secciones posteriores se analizarán algunas de las métricas de rendimiento utilizadas en este contexto.

En la formulación mono-objetivo la métrica que determina la calidad de las soluciones viene dada directamente por el objetivo a optimizar. Sin embargo, en el caso multi-objetivo es necesario establecer criterios específicos para determinar la calidad de los frentes de soluciones obtenidos considerando los objetivos a optimizar. Diferentes autores [Kalyanmoy 01, Van Veldhuizen 03] han analizado diversas métricas de

rendimiento para problemas multi-objetivo, estableciendo dos grandes categorías de métricas.

- En la primera categoría se incluyen aquellas métricas que determinan la proximidad de las soluciones al frente Pareto-óptimo. Dentro de esta categoría se incluyen la métrica del ratio de error, cobertura de frentes, distancia generacional, etc. Todas esas métricas inicialmente propuestas para problemas bi-objetivo pueden adaptarse fácilmente a problemas con más objetivos.
- En la segunda categoría, se encuentran aquellas métricas que permiten establecer la diversidad del frente de soluciones obtenido. El inconveniente de estas métricas es que las medidas de dispersión no pueden aplicarse directamente a problemas con tres o más objetivos, debido a que un conjunto de soluciones con una buena métrica de espaciado no significa necesariamente una buena distribución de soluciones en todo el frente Pareto-óptimo. Otra alternativa es la métrica de la dispersión máxima, que mide la distancia euclídea entre soluciones extremas, aunque no revela la distribución de las soluciones intermedias.

Zitzler et al. [Zitzler 99] aplicaron la métrica de cobertura de conjuntos junto con la métrica del área del espacio cubierto (también llamada hiper-volumen o medida de Lebesgue) en el problema de la mochila con 2, 3 y 4 objetivos. A partir de dicho trabajo han sido muchos los autores que han considerado el uso conjunto de estas métricas para evaluar la calidad de los frentes obtenidos en problemas multi-objetivo.

2.4.2 Técnicas heurísticas de optimización multi-objetivo

Actualmente, en la literatura se pueden encontrar aproximadamente medio centenar de meta-heurísticas multi-objetivo. Sin embargo, muchas de ellas están limitadas a frentes de Pareto con ciertas características (p.ej., espacios convexos) y suelen requerir un punto inicial de búsqueda. Dichas técnicas de optimización se pueden agrupar en tres grandes categorías: algoritmos evolutivos multi-objetivo (*Multi-objective Evolutionary Algorithms*, MOEAs), algoritmos multi-objetivo basados en búsqueda local (*Multi-Objective Local Search Algorithms*, MOLSAs), y meta-heurísticas híbridas multi-objetivo (*hybrid MOMHs*, hMOMHs).

2.4.2.1 Algoritmos evolutivos multi-objetivo

Dentro de las técnicas meta-heurísticas mejor situadas para explorar el frente Pareto-óptimo en MOPs se encuentran los algoritmos evolutivos (EAs). Debido a su inherente paralelismo y a su capacidad para explotar las similitudes de las soluciones mediante recombinación, los EAs son capaces de aproximar el frente de Pareto en una sola ejecución. El potencial de los algoritmos evolutivos para resolver MOPs se remonta a la tesis doctoral de Rosenberg [Rosenberg 67], en la cual se sugería el uso de algoritmos genéticos en este dominio. Sin embargo, el primer intento real por extender un algoritmo evolutivo a problemas multi-objetivo es el Vector Evaluated Genetic Algorithm (VEGA) [Schaffer 85].

Históricamente podemos considerar que han existido dos generaciones de algoritmos evolutivos multi-objetivo:

- **Primera generación:** Formada por algoritmos relativamente simples que hacían uso de enfoques rudimentarios, como funciones agregativas lineales, así como otras más complejas, como funciones de jerarquización de Pareto y nichos.
- **Segunda generación.** Se introduce el concepto de elitismo, que consiste en un mecanismo empleado para asegurar que los individuos con mejores valores de aptitud pasarán directamente a la siguiente generación, evitando de esta forma el ruido provocado por los operadores genéticos. Las dos formas principales de implementar el elitismo son la selección $(\mu + \lambda)$, y el uso de poblaciones secundarias. Los algoritmos de segunda generación enfatizan la eficiencia computacional.

En la última década se ha puesto de manifiesto, experimentalmente, el efecto beneficioso de introducir el elitismo en el diseño de los MOEAs [Zitzler 00]. Sin embargo, los EAs, sobre todo si se utilizan procedimientos elitistas de selección en cada generación, tienden a converger a una única solución óptima del espacio de búsqueda. Por lo tanto, para resolver problemas de optimización multi-modal [Kumar 03] hay que introducir alguna estrategia para mantener la diversidad de soluciones en la población. Se han propuesto diferentes estrategias para conseguir este propósito, destacando entre otros los métodos de nichos (*niching methods*), métodos de repartición de aptitud (*fitness sharing*), métodos de densidad (*crowding*), métodos de borrado (*clearing*), etc [Sareni 98].

En los siguientes apartados se verán algunos de los más importantes métodos para preservar la diversidad.

Estrategia basada en funciones de agregación

Una de las primeras estrategias que se propusieron para lidiar con varios objetivos consistía en combinarlos mediante una función de suma de pesos [Coello 00, Hajela 92]. Al proceso de combinar objetivos en una sola función se le denomina normalmente función de agregación y se ha utilizado en diversas ocasiones con relativo éxito en problemas en los cuales el comportamiento de las funciones objetivo se conoce adecuadamente. Este método consiste en sumar todas las funciones objetivo usando diferentes pesos para cada una de ellas. Esto significa que el problema con objetivos múltiples se transforma en un problema de optimización simple de la forma

$$\min \sum_{i=1}^N w_i \cdot f_i(s) \quad \text{donde} \quad \sum_{i=1}^N w_i = 1$$

donde w_i representa la importancia relativa del i -ésimo objetivo.

Esta técnica es muy eficiente desde el punto de vista de recursos de cómputo, y puede usarse para generar una solución que sirva como un punto inicial para otras técnicas. Puesto que los resultados obtenidos usando esta función pueden variar significativamente en función de los pesos, y puesto que se sabe normalmente muy poco acerca de la forma más adecuada de seleccionar dichos coeficientes, se sugiere resolver el mismo problema usando diferentes valores de w_i . Debe advertirse que los pesos no reflejan proporcionalmente la importancia relativa de los objetivos, sino que son sólo factores que, al ser modificados, permiten localizar puntos diferentes en el frente de Pareto, por lo que el diseñador todavía tiene que afrontar la decisión de tener que elegir la solución más apropiada en base a su intuición. Para que los métodos numéricos puedan usarse para buscar el mínimo de la expresión, esta localización de puntos depende no sólo de w_i , sino también de las unidades en las que se expresen las funciones. El principal problema es cómo determinar los pesos apropiados cuando no tenemos suficiente información acerca del problema. En este caso, cualquier punto óptimo obtenido sería una función de los coeficientes usados para combinar los objetivos. La mayor parte de los investigadores usan una simple combinación lineal de objetivos y posteriormente generan la superficie de compromiso mediante la variación de los pesos [Czyzak 98].

Non-dominated Sorting in Generic Algorithm (NSGA)

Srinivas y Deb [Srinivas 94] propusieron en 1994 el algoritmo genético de ordenación no dominada (*Non-dominated Sorting in Genetic Algorithm*, NSGA). Su funcionamiento se basa en el uso de varias capas de clasificación de los individuos. Antes de efectuar la selección, la población es jerarquizada en base a la no dominación, de forma que todos los individuos no dominados se clasifican en una misma categoría con un valor arbitrario de aptitud.

Para mantener la diversidad de la población, se lleva a cabo un reparto de aptitud entre estos individuos clasificados usando los valores arbitrarios de aptitud previamente definidos. Posteriormente, este grupo de individuos clasificados se ignora, y se evalúa otra capa de individuos no dominados. Este proceso se repite hasta que todos los individuos de la población están clasificados. Esta técnica utiliza selección proporcional, en concreto la variante denominada *Stochastic Remainder*. Puesto que los individuos en el primer frente tienen el máximo valor de aptitud, siempre obtienen más copias que el resto de la población, lo que conlleva a una rápida convergencia de la población hacia las regiones no dominadas. El reparto de aptitud ayuda a distribuir los individuos sobre esta región. La eficiencia de NSGA yace en la forma en que los objetivos múltiples de un problema se reducen a una función de aptitud arbitraria usando un procedimiento de ordenamiento basado en no dominancia. La asignación de aptitud se lleva a cabo en base a los valores de los parámetros en lugar de considerar los valores de las funciones objetivo, con lo cual se persigue asegurar que se lleve a cabo una mejor distribución de los individuos, así como permitir que existan múltiples soluciones equivalentes.

Strength Pareto Evolutionary Algorithm (SPEA)

Propuesto por Zitzler y Thiele, el algoritmo evolutivo de fuerza de Pareto (*Strength Pareto Evolutionary Algorithm*, SPEA) [Zitzler 99] se incluye dentro de los MOEAs de segunda generación. Los MOEAs de segunda generación destacan por el uso del elitismo, bien mediante una estrategia de selección ($\mu + \lambda$) o por el uso una población secundaria [Zitzler 01]. Al igual que otras técnicas de optimización multi-objetivo de la época, SPEA utiliza el concepto de dominancia de Pareto para asignar la función de aptitud a los individuos, almacena las soluciones no dominadas externamente (elitismo), y utiliza un método de clustering para reducir el número de soluciones no dominadas almacenadas en el conjunto externo sin destruir las características del frente. En particular, SPEA resultaba innovador por los siguientes aspectos:

- Combina los aspectos anteriores en un único algoritmo.
- La aptitud de un individuo viene determinada únicamente por las soluciones almacenadas en el conjunto externo siendo irrelevante el hecho de que un miembro de la población domine a otro.
- Todas las soluciones del conjunto externo participan en el proceso de selección.
- Incluye un nuevo método de nichos para preservar la diversidad de la población, el cual no requiere ningún parámetro de distancia.

SPEA resultó ser un algoritmo muy influyente ya que, además de incluir los aspectos detallados anteriormente, mejoraba el rendimiento de los utilizados hasta la época, en gran medida gracias a que era el único método que hacía uso explícito del concepto de elitismo (mediante el uso del archivo externo). Sin embargo, también presentaba sus principales debilidades, entre las que destacaba el hecho de que a la hora de realizar la asignación de aptitud, aquellos individuos que eran dominados por los mismos miembros del archivo tenían el mismo valor de aptitud. Esto significa que en el caso en el que el archivo contenga un solo individuo, todos los miembros de la población tienen el mismo ranking, independientemente de si se dominan entre ellos o no. Como consecuencia, la presión selectiva se ve rebajada sustancialmente, y en este caso particular, SPEA puede llegar a comportarse como un algoritmo de búsqueda aleatorio.

Strength Pareto Evolutionary Algorithm II (SPEA-II)

Poco tiempo después de la presentación de SPEA, y con el objetivo de superar las limitaciones que algoritmos posteriores pusieron de manifiesto, Zitzler et al. presentaron SPEA2 [Zitzler 01]. Las principales aportaciones de SPEA2 respecto a SPEA se pueden resumir a continuación:

- Utilización de un sistema de asignación de aptitud mejorado que tiene en cuenta, para cada individuo, el número de soluciones que este domina y el número por las que es dominado.
- Se presenta una nueva técnica de estimación de densidad por el vecino más cercano que permite una guía más precisa por el espacio de búsqueda.
- Se hace uso de un nuevo sistema de truncamiento del archivo que garantiza la preservación de las soluciones extremas.

Non-dominated Sorting in Generic Algorithm II (NSGA-II)

Al igual que SPEA fue mejorado por SPEA2, el método NSGA II superó al antiguo procedimiento. Pese a que en su momento NSGA obtuvo gran reconocimiento y fue objeto de multitud de comparativas y referencias, este método tenía varias debilidades, entre las que destacaban:

- Alto coste computacional del procedimiento de clasificación de las soluciones no dominadas; el coste del algoritmo de clasificación de NSGA era muy elevado en términos computacionales para tamaños de población grandes.
- Falta de elitismo: los resultados obtenidos denotaron que el elitismo puede acelerar el rendimiento de los AG significativamente, además de evitar la pérdida de buenas soluciones por efectos aleatorios.
- Necesidad de especificar un parámetro de sharing (*share*). Los mecanismos tradicionales para mantener la diversidad de la población se habían centrado en el mecanismo de reparto de aptitud. El principal problema del mismo, como se indicó en su momento, radica en la necesidad de especificar el parámetro *share*.

Por esta razón Deb et al. propusieron NSGA-II [Deb 02], el cual ha conseguido resultados muy buenos en numerosos estudios con diferentes problemas de test y métricas de rendimiento. En NSGA-II se propone un nuevo método de comparación *crowded* que resuelve los puntos débiles de NSGA. Se puede decir que NSGA-II utiliza reparto de aptitud. Ahora bien, cuando al añadir frentes rebasamos el tamaño máximo permitido, se eliminan las soluciones peor diversificadas del último frente. Entonces, desde este punto de vista estamos realizando un procedimiento de aclarado, el cual está supeditado a la relación de dominancia como se extrae de la definición del operador de comparación. En conclusión, al igual que SPEA presentaba un funcionamiento híbrido entre *fitness-sharing* y *crowding*, NSGA-II utiliza como mecanismo de *niching* una combinación de *fitness-sharing* y *clearing*.

Pareto-Envelope Based Algorithm (PESA)

Corne et al. [Corne 00] propusieron un algoritmo de selección basado en Pareto (*Pareto-envelope Based Selection Algorithm*, PESA) que combinaba aspectos de PAES [Knowles 99], y SPEA [Zitzler 99]. Esta aproximación utiliza una pequeña población interna y un gran archivo externo (o población secundaria) donde se almacena la

población. Con el objetivo de mantener la diversidad, PESA usa la estrategia de almacenamiento de malla adaptativa (o hiper-malla) que utiliza PAES, en combinación con el uso en el procedimiento de crowding para establecer la selección de individuos, persiguiendo que las soluciones se distribuyan uniformemente en la hiper-malla. Este mismo procedimiento se utiliza para decidir qué soluciones se introducen en el archivo externo de población [Knowles 03].

Pareto-Envelope Based Algorithm II (PESA-II)

Tras analizar algunas posibles mejoras sobre PESA, Corne et al. propusieron PESAI [Corne 01]. Esta mejora incluía, entre otros aspectos, una adaptación de la estrategia de selección basada en la hiper-malla, conocida como estrategia basada en region (*region-based strategy*). En dicha estrategia, la unidad mínima de selección es un hiper-cubo que contiene más de un individuo. El procedimiento consiste en seleccionar una región de la hiper-malla, posteriormente seleccionar un individuo de ella, haciendo uso de alguno de los procedimientos de selección existentes. El resto del procedimiento es muy similar a PESA.

2.4.2.2 Algoritmos multi-objetivo basados en la búsqueda local

Multi-Objective Simulated Annealing de Ulungu (UMOSA)

Ulungu [E.L. Ulungu 99] presentó un algoritmo multi-objetivo basado en enfriamiento simulado (*Ulungu Multi-Objective Simulated Annealing*, UMOSA) que utilizaba funciones escalares durante el proceso de búsqueda, de forma que se llevaban a cabo diferentes ejecuciones con diferentes pesos en cada objetivo. De esta forma en algunas ejecuciones se consideran más importantes ciertos objetivos que otros, haciendo uso de un parámetro σ_k , que de forma similar a las funciones de agregación, guía el proceso de búsqueda. Al finalizar todas las ejecuciones, se unen las soluciones no dominadas obtenidas tras cada una de ellas. El uso de un conjunto lo suficientemente diverso de pesos permite guiar el proceso de búsqueda en varias direcciones, en función del objetivo que se desea minimizar.

Multi-Objective Simulated Annealing de Czyzak (PSA)

Según se ha podido apreciar, UMOSA hace uso de una sola solución durante el proceso de búsqueda. Sin embargo, otros autores han planteado algoritmos basados en

enfriamiento simulado que hacen uso de poblaciones. En concreto, Czyzak y Jaszkievicz presentaron el método de enfriamiento simulado de Pareto (en inglés *Pareto Simulated Annealing*, PSA) [Czyzak 98]. PSA utiliza una población principal y un archivo externo donde se almacenan las mejores soluciones encontradas en dicha población principal. Además, PSA controla dinámicamente los pesos de la función objetivo, con lo que se intenta distribuir las soluciones a lo largo de los diferentes objetivos de forma homogénea.

Hansen's Multi-Objective Tabu Search (MOTS)

Al igual que el enfriamiento simulado, la búsqueda tabú también ha sido utilizada en el contexto multi-objetivo, destacando la búsqueda tabú multi-objetivo (en inglés *Multi-Objective Tabu Search*, MOTS) [Hansen 97]. MOTS es una técnica poblacional, cuyas soluciones son mejoradas mediante el uso de un criterio de aceptación basado en TS. En MOTS, los pesos de cada objetivo son adaptados de forma dinámica, al igual que en PSA. Aunque los experimentos evalúan la variación en la calidad de las soluciones de acuerdo a la longitud de la lista tabú, no se ofrece comparativa con otros métodos

The Pareto Archived Evolution Strategy (PAES)

La estrategia de evolución con archivo de Pareto (*Pareto Archived Evolution Strategy*, PAES) [Knowles 99] fue otra técnica de búsqueda que ofrecía, entre otras, las siguientes características básicas:

- Uso de un solo punto para la búsqueda local.
- Selección basada en ranking/dominancia de Pareto.
- Número limitado de soluciones no dominadas.
- Uso de un archivo externo para almacenar soluciones no dominadas basadas en una malla de regiones (hiper-malla).
- Número de parámetros reducido.

Debido a la simpleza del planteamiento, en la práctica se pueden presentar algunos condicionantes que deben ser resueltos. En particular, destaca el hecho de que utilizar una sola solución durante el proceso de búsqueda puede resultar escaso a la hora de encontrar un conjunto extenso de soluciones no dominadas cuando el tamaño del problema es elevado.

2.4.2.3 Algoritmos híbridos multi-objetivo

La hibridación de meta-heurísticas permite la cooperación de métodos teniendo características complementarias. La hibridación presenta una serie de ventajas, tales como su habilidad para obtener soluciones próximas al óptimo de Pareto, principalmente cuando hay un gran número de óptimos locales. El interés en el diseño e implementación de meta-heurísticas híbridas se ha incrementado de forma importante en los últimos años [Talbi 02]. Sin embargo, la mayoría de estos estudios se han centrado en técnicas mono-objetivo, mientras que en el ámbito multi-objetivo constituye un área de investigación aún muy abierta. A continuación se describen, brevemente, algunas meta-heurísticas híbridas para optimización multi-objetivo (hMOMHs) encontradas en la literatura.

La búsqueda local genética multi-objetivo (*Multi-Objective Genetic Local Search*, MOGLS) [ISH98] es un algoritmo genético para optimización multi-objetivo que adicionalmente aplica búsqueda local en cada individuo de la población haciendo uso de una función objetivo de suma de pesos. Los resultados obtenidos por MOGLS en problemas de planificación de tareas resultaron muy satisfactorios [ISH98].

Knowles y Corne extendieron PAES haciendo uso de algoritmos meméticos, obteniendo como resultado el PAES memético (*memetic-PAES*, M-PAES) [Knowles 00]. M-PAES hace uso de una población de soluciones y un operador de cruce que es utilizado para recombinar soluciones encontradas por PAES. Al igual que en PAES, las soluciones prometedoras en la búsqueda se almacenan en un archivo externo de soluciones no dominadas (*ND*). Los resultados obtenidos en el problema de la mochila [Knowles 00] denotaron el buen comportamiento de M-PAES con respecto a SPEA [Zitzler 99].

Xiaolin et al. [Xiaolin 03] combinaron la programación cuadrática secuencial (*Sequential Quadratic Programming*, SQP) con SPEA y NSGA-II. Esta hibridación permite una mejora en la calidad de las soluciones en diferentes funciones matemáticas de prueba. Además, esta estrategia híbrida permite incrementar la diversidad de las soluciones obtenidas.

Otra hMOMH recientemente propuesta es la búsqueda genética tabú (*Genetic Tabu Search*, GTS) [Barichard 03]. GTS es un método híbrido que combina la naturaleza global de los algoritmos genéticos con la naturaleza local de la búsqueda tabú. Los resultados obtenidos en el problema de la mochila demostraron que GTS igualaba y mejoraba los resultados obtenidos por NSGA y MOGLS.

Capítulo 3

Optimización de tensiones

En este capítulo se realiza un repaso del estado actual de la optimización de tensiones en redes eléctricas. Se analizan los métodos vigentes para la regulación de tensión en los transformadores, así como las propuestas tradicionales de mejora en los mismos. Por último, se detallan las nuevas técnicas propuestas para realizar un mejor control y, por tanto, una mejor optimización de las tensiones del sistema.

3.1 Estado del arte

Debido a la necesidad de resolver de forma precisa el problema de la optimización de tensiones en redes de distribución, a la flexibilidad en el modelado que presentan los algoritmos evolutivos y a la facilidad con que se pueden implementar, en los últimos años han surgido ciertos trabajos científicos relacionados con dichos algoritmos.

En este apartado se hace un recorrido por las contribuciones más relevantes que han aparecido en la literatura técnica sobre algoritmos evolutivos aplicados a la optimización de tensiones en redes eléctricas. Como se podrá apreciar, todos estos trabajos destacan

como principales virtudes de la técnica, su flexibilidad de modelado y la capacidad de obtener un conjunto de soluciones cuasi-óptimas. Sin embargo, en ninguno de ellos se hace un análisis a fondo de las posibilidades que brinda el manejo coordinado de las tomas de los transformadores en entornos de distribución.

Un detalle importante es que hay pocas publicaciones relevantes en estos últimos años referidas a la aplicación de algoritmos genéticos a redes eléctricas. Fundamentalmente, las técnicas utilizadas siguen siendo aquellas basadas en estándares clásicos como programación dinámica, lineal, etc. Por mor de una mayor simplicidad no se entrará en una relación exhaustiva de las mismas, aunque si se mencionarán aquellas que hacen uso de técnicas evolutivas y las que no.

Por otro lado, y como análisis inicial, también se hace un breve recorrido por los métodos actuales de corrección de tensiones en subestaciones eléctricas y que están basados en métodos del siglo pasado y por tanto, algo obsoletos, teniendo en cuenta los medios computacionales existentes hoy en día.

3.1.1 Sistemas reguladores de tensión de uso cotidiano

Para conocer los sistemas de regulación actualmente en funcionamiento se ha recopilado material tanto de diferentes fabricantes como de empresas distribuidoras de energía eléctrica.

En primer lugar se comentan dos documentos editados por Hidroeléctrica Española S. A., que permiten conocer, desde el punto de vista de la empresa distribuidora, las características fundamentales de los reguladores de tensión, tanto en vacío como en carga, que la citada empresa tiene instalados en su red de distribución.

El primero trabajo, [Hidroeléctrica Española 82], contiene una breve descripción del principio teórico de la regulación de tensión por medio de cambios en la relación de transformación de los transformadores (variación del número de espiras efectivas en las tres fases simultáneamente).

Igualmente, también describe los tipos de reguladores de tensión que se usan actualmente en la red, divididos en dos grandes grupos:

- Reguladores en vacío, cuya utilización precisa la desconexión del transformador.

- Reguladores bajo carga, que permiten la variación de la relación de transformación sin necesidad de interrumpir el servicio.

Generalmente, la forma de regulación en los transformadores AT/MT que alimentan a una red de distribución suele ser la de regulación de tensión bajo carga, mientras que normalmente la regulación en los transformadores MT/BT que alimentan a las subredes de baja tensión suele realizarse con reguladores en vacío.

A continuación, tras una breve descripción de los reguladores en vacío, el documento detalla las características de los reguladores bajo carga, especialmente los que utilizan el sistema Jansen.

Finalmente, incluye una explicación del funcionamiento de los reguladores bajo carga, en sus tres modalidades: funcionamiento automático, funcionamiento manual y funcionamiento de emergencia. De las tres modalidades, la más empleada es la del funcionamiento automático, donde las variaciones de tensión en el secundario del transformador se controlan por medio de un relé regulador.

El relé regulador puede ser de fundamento electromagnético o electrónico. El relé actúa en función de la tensión e intensidad de salida del transformador y de los siguientes parámetros:

- **Grado de saturación** del núcleo del transformador.
- **Grado de insensibilidad** admisible.
- **Variación de tensión** admisible en una red antes de que el relé regulador ordene al transformador el cambio de tomas.
- **Tiempo de retardo**, que es el tiempo que la tensión de la red debe permanecer fuera de la banda de insensibilidad para que el relé regulador actúe.
- **Compundaje**, que es el valor de la tensión con el que se corrige el valor de la tensión de consigna para compensar la caída de tensión que se produce desde el punto de regulación hasta el punto en el que se conecta la carga. Dicha tensión es proporcional a la intensidad de salida del transformador.

Además, la mayoría de los reguladores suelen llevar otros dispositivos opcionales, para realizar diversas funciones complementarias. Dichos dispositivos son:

- El sistema de paro por subtensión que evita que los descensos de tensión abruptos debidos a la desconexión del transformador, produzcan órdenes de variación de tomas.
- El sistema de retroceso rápido, el cual elimina el tiempo de retardo cuando la tensión de salida sobrepasa un cierto nivel prefijado.
- El sistema de conmutación rápida que permite cambiar rápidamente de tomas y que se emplea en el caso de puesta en servicio del transformador.

Para su funcionamiento, el relé regulador debe estar conectado a cuatro circuitos exteriores de alimentación:

- El circuito de tensión imagen (suministra una tensión proporcional a la tensión de salida del transformador de potencia).
- El circuito de intensidad imagen (suministra una intensidad proporcional a la intensidad de salida del transformador de potencia).
- El circuito de tensión auxiliar (suministra la tensión necesaria para el funcionamiento del relé regulador).
- El circuito de utilización (circuito a través del cual se transmiten las ordenes de subir o bajar al motor de cambio de tomas).

El segundo documento de Hidroeléctrica [Pozas 95], tiene una estructura similar al anterior, pero introduce un diagrama de flujo del algoritmo general del control de la regulación automática de tensión, donde se puede comprobar el sucesivo funcionamiento de los diferentes dispositivos y sistemas que están incluidos en el regulador. También aparece en el documento un ejemplo numérico del cálculo de los ajustes del regulador. Finalmente, se trata, sucintamente, el problema que se plantea con el uso de diferentes transformadores funcionando en paralelo, especialmente cuando no tienen las mismas características.

Para complementar la información también se ha acudido a algunos fabricantes, documentos [ABB 05, ABB 05, Reinhausen 06], cuya documentación ha permitido conocer las características constructivas, y rangos de funcionamiento habitual de los reguladores de tensión bajo carga.

Se ha constatado la innovación tecnológica que ha supuesto el empleo de cambiadores de tomas con conmutación en vacío. Esta propuesta permite que el

dispositivo tenga una vida útil mucho mayor que los típicos cambiadores en aceite, provocando un ciclo de mantenimiento mucho mas largo y, por consiguiente, relegando a un segundo plano el tradicional y usual inconveniente, consistente en la limitación en cuanto al número de veces que puede cambiarse la toma de un transformador sin que se dañe el propio cambiador de tomas en la operación normal dentro de un sistema eléctrico.

Una vez conocido el sistema de regulación, se resume a continuación cómo se realiza en la actualidad, en un sistema típico, dicha regulación por medio del regulador bajo carga del transformador AT/MT, en las redes de distribución.

De forma general, en la actualidad se regula la tensión suponiendo un comportamiento homotético de las cargas en la red de distribución, es decir, se supone que todas las cargas evolucionan de igual forma a lo largo del tiempo, (por ello, sólo es necesario medir las potencias suministradas por el transformador AT/MT). La fórmula utilizada es:

$$V_b(t) = k_1 P(t) + k_2 Q(t) + k_3 \quad (4.1)$$

donde: $V_b(t)$ es la tensión en el secundario del transformador AT/MT.

$P(t)$ es la potencia activa suministrada por el transformador.

$Q(t)$ es la potencia reactiva suministrada por el transformador.

k_1, k_2 y k_3 son constantes dependientes de las características de la red.

En el caso, bastante habitual, de suponer que el factor de potencia de la red se mantiene constante a lo largo de la red de distribución, la fórmula se reduce a:

$$V_b(t) = k'_1 P(t) + k_3 \quad (4.2)$$

donde k'_1 es una constante dependiente de las características de la red.

Las constantes k_1, k_2, k_3 y k'_1 son parámetros a introducir en el regulador. Su cálculo se hace de diferentes formas en los distintos documentos consultados. Por ejemplo en

[Pélissier 71] se plantea un método para obtener los coeficientes por medio de un cálculo de optimización económica, mientras que en [Sarinelli 86] se plantea un método utilizado en Francia por la empresa EDF basado en un simple cálculo de regresión lineal a partir de los valores obtenidos en un determinado período de tiempo.

Una vez conocida la tensión necesaria en barras del secundario del transformador, el cálculo de la relación de transformación es una sencilla operación, con la que, a partir de la tensión en el primario, se calcula la relación de transformación que sería necesaria para obtener la tensión del secundario requerida, teniendo en cuenta la caída de tensión interna.

El método es enormemente simple en su utilización (resuelve el problema con muy pocos datos), sin embargo, deja de ser adecuado cuando el comportamiento de las cargas de la red se aleja del homotético, previamente supuesto. El comportamiento no homotético se produce en una gran cantidad de casos, especialmente cuando la red de distribución alimenta a usuarios de distintas características, situación que cada vez ocurre más frecuentemente en las redes de distribución, debido, entre otros factores, al aumento del tamaño de las poblaciones, que en muchos casos absorben a zonas industriales situadas anteriormente aisladas.

El comportamiento general de las cargas y, sobre todo, su interrelación en función de la ubicación concreta en la red, está cada día más cerca de ser un dato conocido y cierto gracias a los modernos sistemas de medida. Es frecuente que las compañías eléctricas instalen a los nuevos usuarios sofisticados sistemas de medida de energía eléctrica basados en la electrónica de potencia, los cuales permiten conocer, prácticamente, cualquier dato del nodo en cuestión. Además, estos dispositivos suelen añadir algún elemento que ofrece conectividad con el centro de datos de dicha compañía, por lo que valores como potencia activa, potencia reactiva, intensidad y tensión pueden ser conocidos con precisión en cualquier momento. Por otro lado, los gobiernos en su afán de fomentar los buenos hábitos energéticos y los compromisos de ahorro y eficiencia energética están introduciendo medidas legislativas encaminadas a sustituir los sistemas de medida tradicionales por otros que permitan un mayor control estadístico y de utilización en los puntos de consumo.

Todo lo anterior, conduce hacia escenarios de planificación donde los datos de demanda pueden ser conocidos “*online*”, facilitando los procesos de análisis y estudio en tiempo real. Como se apreciará más adelante, este factor es clave para entender la

viabilidad de la propuesta de tesis, en cuanto a la utilización de bases de datos de consumos nodales conocidos y en tiempo real.

3.1.2 Propuestas tradicionales para mejora de la regulación de tensión

3.1.2.1 Propuestas de tipo económico

[Carpinelli 92]

Algunos autores utilizan la fórmula introducida por Ailleret [Ailleret 56] como base para obtener una expresión para el cálculo del perjuicio económico, en el conjunto de cargas de una red de distribución radial, tanto en MT como en BT, durante un determinado período de tiempo, debido a las desviaciones de la tensión respecto a su valor nominal.

A partir de dicha expresión, e introduciendo los parámetros de las líneas como medio de establecer las caídas de tensión en MT, obtienen una función que permite calcular el perjuicio económico, en función de la regulación del transformador AT/MT que alimenta la red de distribución en estudio, y de la toma en vacío de cada transformador MT/BT que alimenta a cada línea BT seleccionada.

Con todo lo anterior, estos autores definen el perjuicio económico que producen las desviaciones de la tensión respecto a la tensión nominal, en un determinado nudo de consumo k , a partir de la siguiente fórmula:

$$j_k = \alpha_k P_k \left[\frac{V_k - V_{k,r}}{V_{k,r}} \right]^2 \Delta t \quad (4.3)$$

donde:

j_k : Perjuicio económico que produce la desviación de la tensión en el nudo k con respecto a su tensión nominal durante el intervalo Δt .

α_k : Coeficiente de coste del perjuicio en la carga conectada en el nudo k .

P_k : Potencia absorbida por el nudo k .

V_k : Tensión en el nudo k .

$V_{k,r}$: Tensión nominal en el nudo k .

Para el conjunto de todas las cargas conectadas a una red de distribución arborescente, los autores obtienen una expresión del perjuicio económico total, J , debido a las desviaciones de la tensión, en los diferentes nudos de la red, con respecto a sus correspondientes tensiones nominales,

$$J = \int_{\tau} \sum_{k=1}^N \frac{\alpha_k P_k(t)}{V_{k,r}^2} \left[\frac{1}{\bar{a}_k} \left[V_{MV}(t) - \frac{\sum_{j=1}^N (R_{kj} P_j(t) + X_{kj} Q_j(t))}{V_{MV,r}} \right] - V_{k,r} \right]^2 dt \quad (4.4)$$

donde:

$V_{MV}(t)$: Tensión a la salida del transformador AT/MT y, por lo tanto, de forma indirecta a partir de la tensión a la entrada del citado transformador, su regulación.

$V_{MV,r}$: Tensión nominal a la salida del transformador AT/MT.

\bar{a}_k : Relación de transformación real en el transformador MT/BT conectado al nudo k .

$Q_j(t)$: Potencia reactiva consumida en el nudo j .

R_{kj} : Elemento de la matriz \hat{R} definida como $[\hat{R}] = [A]^t D(R_i)[A]$, siendo A una matriz cuyos elementos a_{ij} valen 1 si la carga suministrada en el nudo j atraviesa la rama i , valiendo 0 en caso contrario. La matriz $D(R_i)$ es una matriz diagonal cuyos elementos son las resistencias de las ramas.

X_{kj} : Elemento de la matriz \hat{X} definida como $[\hat{X}] = [A]^t D(X_i)[A]$, la matriz $D(X_i)$ es una matriz diagonal cuyos elementos son las reactancias de las ramas.

N : Número de nudos.

La forma de seleccionar los valores de $V_{MV}(t)$ y \bar{a}_k , propuesta por los autores es optimizar la función del perjuicio económico, (4.4), respecto a las diversas variables de regulación, $V_{MV}(t)$ y \bar{a}_k , obteniendo, como resultado, la posición óptima que debe

adoptar el regulador bajo carga, del transformador AT/MT, y las tomas de vacío a seleccionar en cada uno de los transformadores MT/BT.

Debido a que los autores no han encontrado un algoritmo de resolución analítica que pueda resolver conjuntamente las dos optimizaciones, proponen un sistema iterativo de dos etapas, desarrollado por ellos. En una primera, para unas tomas en vacío de cada uno de los transformadores MT/BT fijas, se calcula el valor de la tensión a la salida del transformador AT/MT que minimiza el perjuicio económico debido a las variaciones lentas de la tensión.

En la segunda etapa, para el valor fijo de la citada tensión de cabecera obtenido en la etapa anterior, se calculan las tomas de vacío de cada transformador que minimizan el perjuicio económico. Para la resolución de la segunda etapa se consideran las restricciones debidas tanto a las posibilidades de regulación de los transformadores MT/ BT, como de tensiones admisibles en la red.

El proceso se repite sucesivamente, utilizando en cada paso los resultados de la etapa anterior, hasta alcanzar la solución final, con una precisión determinada.

Sin embargo, una vez llegado a este punto, los autores utilizan únicamente como variables de entrada al algoritmo las potencia activa y reactiva suministradas por el transformador AT/MT, que alimenta a la red de distribución, suponiendo un comportamiento homotético de la carga, y utilizando expresiones del tipo:

$$V_{MV}(t) = EP(t) + FQ(t) + G \quad (4.5)$$

idéntica a (4.1), desarrollando un complejo sistema de cálculo de las constantes E, F y G.

Por lo tanto, la solución final que obtienen los autores, es un cálculo conjunto de todas las variables de regulación, pero manteniendo la estructura clásica, consistente en utilizar únicamente medidas en cabecera de la red de distribución.

[Curcio 91]

Pese a la diferencia en fechas de publicación, realmente es continuación del artículo anterior, pero en él los autores abandonan definitivamente la hipótesis de utilizar únicamente los valores de las variables en cabecera de la red, y por tanto introducen por primera vez la posibilidad de considerar cargas no homotéticas.

El sistema que se propone para regular la tensión se caracteriza por trabajar en tiempo real, y por tener en cuenta el reparto efectivo de la potencia suministrada por el

transformador AT/MT, entre los diversos nudos de consumo en la red de distribución alimentada a través de éste. Para ello, será necesario realizar continuamente medidas de determinadas variables, en un número adecuado de nudos.

El criterio que se utiliza para regular la tensión es minimizar el perjuicio económico causado por las desviaciones lentas de la tensión respecto a su valor nominal, definido a partir de la fórmula de Ailleret, sustituyendo en el factor de importancia del consumidor, la energía consumida por la potencia consumida, dando por ello un sentido más instantáneo del cálculo.

Del mismo modo, es necesario tener en cuenta las restricciones propias del problema, tanto por las características físicas del regulador de tensión, como por los valores alcanzables por la tensión en los nudos de la red regulada.

Para poder utilizar en tiempo real la fórmula de Ailleret, se necesitará conocer en cada instante los valores de la potencia activa y la tensión en todos los nudos del sistema. Por lo tanto, se deberá obtener a través de medidas, realizadas en tiempo real, dichos valores en todos los nudos, en los que las variables no sean homotéticas, en todo momento, a las de un nudo aguas arriba en la red.

En el caso de un grupo de nudos con comportamiento homotético los valores se obtienen rápidamente en función de las medidas realizadas en uno solo de los nudos del grupo y de las constantes de homotecia entre ellos.

Con estas consideraciones, el perjuicio económico, $d(t)$, producido por las desviaciones de la tensión respecto a la nominal, queda de la siguiente forma:

$$d(t) = \sum_{i=1}^N \frac{\alpha_i(t) P_i(t)}{V_{i,n}^2} \left[\frac{V_{MV}(t)}{\bar{a}_i} - \Delta V_{0,i}(t) - V_{i,n} \right]^2 \quad (4.6)$$

donde:

$\alpha_i(t)$: Coeficiente de coste en el nudo i , que permite cuantificar el perjuicio económico (los autores no indican cómo establecer sus valores).

$P_i(t)$: Potencia activa consumida en el nudo i .

$V_{i,n}$: Tensión nominal en el nudo i .

$V_{MV}(t)$: Tensión en barras de media tensión del transformador AT/MT.

\bar{a}_i : Coeficiente cuyo valor es la relación de transformación de los transformadores MT/BT, supuesta fija, para los nudos de baja tensión alimentados por dichos transformadores, e igual a la unidad para los nudos de media tensión.

$\Delta V_{0,i}(t)$: Caída de tensión entre las barras del transformador de cabecera de la red de distribución y el nudo i de consumo.

El problema que se plantea es obtener el valor óptimo de la variable $V_{MV}(t)$, que minimiza el perjuicio económico. La resolución del citado problema consiste simplemente en derivar la ecuación anterior (4.6) respecto a la variable buscada $V_{MV}(t)$, e igualando a cero el resultado, despejar ésta.

La solución así obtenida, es la correspondiente al caso de que no existan restricciones sobre el valor de la tensión en barras de media tensión del transformador AT/MT.

Sin embargo, las restricciones existen, por lo que se debe ajustar la solución obtenida a dichas restricciones, tanto las debidas al funcionamiento del regulador (valores discretos posibles de la relación de transformación), como las debidas a los límites de las tensiones que pueden existir en la red, por motivos reglamentarios o por condicionantes físicos.

El ajuste se realiza tomando los dos valores de tensión de cabecera posibles, que determinan un intervalo en el que está incluido el valor calculado. A continuación, se determina el perjuicio económico producido por cada uno de ellos, seleccionando aquel que produzca menor perjuicio.

En el desarrollo matemático realizado por los autores, se observan varios supuestos simplificadores, como que la caída de tensión entre las barras de media tensión del transformador AT/MT y los nudos de carga no depende de la propia tensión en barras, lo cual sólo es cierto en el caso de suponer que la intensidad es constante en la red de distribución. Dicha simplificación, en principio, parece excesivamente amplia. También se supone que la caída de tensión en el transformador AT/MT es independiente de la variación de la relación de transformación del transformador.

Sin embargo, la sistemática aplicada en el artículo, salvo por los problemas indicados en el párrafo anterior, parece adecuada y es necesario realizar un estudio más detallado del error cometido al realizar las simplificaciones anteriores.

Por otra parte, se desprecian, a la hora de calcular el perjuicio económico, factores como el rendimiento de la propia red, su duración, etc., con lo que el perjuicio económico se reduce a un solo término de entre los que lo componen.

[Testa 93]

Este artículo es el tercero del mismo grupo de trabajo, y por lo tanto es continuación de los desarrollos realizados en los dos anteriores.

Se plantea aquí, el problema de la regulación de tensión en una red de distribución, con una regulación periódica de los variadores de tomas en vacío de cada uno de los transformadores MT/BT que configuran la red, y la actuación del regulador automático bajo carga del transformador AT/MT, gobernado por un sistema de mando como el desarrollado en [Curcio 91].

Para ello es necesario el uso de un sistema que, a partir de las medidas que se realizan, pueda hacer una estimación de las potencias demandadas en cada nudo de la red de distribución, durante el período que transcurrirá entre dos posibles regulaciones de los diversos transformadores MT/BT conectados a ella.

Para la resolución del problema, los autores utilizan el mismo algoritmo diseñado en [Carpinelli 92], intentando eliminar la hipótesis de homotecia que se incluían en él.

Para poder realizarlo, se utiliza un algoritmo iterativo de dos etapas, cuyo fin es obtener las regulaciones óptimas, tanto del transformador AT/MT como de todos los transformadores MT/BT que constituyen la red de distribución, que permiten minimizar el perjuicio económico producido por las desviaciones de las tensiones en los nudos respecto a sus correspondientes tensiones nominales.

En la primera etapa, se consideran constantes las relaciones de transformación de los transformadores MT/BT, y se minimiza la expresión del perjuicio económico, (4.6), respecto a la variable tensión en las barras MT del transformador AT/MT, el proceso es idéntico al presentado en [Curcio 91].

En dicho desarrollo, se introducen las mismas simplificaciones que se realizan en aquél, con lo que el resultado obtenido adolece de los mismos inconvenientes.

La segunda etapa del algoritmo consiste en considerar la tensión en barras MT del transformador AT/MT como constante e igual al valor obtenido en la etapa anterior, y a continuación, con este valor fijo, minimizar la función del perjuicio económico (4.6), con respecto a las relaciones de transformación de los diferentes transformadores MT/BT que conforman la red de distribución.

Las relaciones de transformación se calculan, cada una de ellas, de forma independiente, resolviendo el problema de minimizar el perjuicio económico debido a la variación de cada una de dichas variables.

Finalmente, los valores obtenidos en el proceso anterior, con la suposición de que las variables pueden tomar cualquier valor, deberán ser transformados a sus valores posibles física o reglamentariamente, con la incorporación de las restricciones, tanto de los reguladores como de las tensiones alcanzables en la red alimentada por cada transformador, utilizando el mismo sistema que en el artículo anterior se empleaba para la relación de transformación del transformador AT/MT.

El algoritmo se completa repitiendo las dos etapas alternativamente, utilizando en cada etapa como valor de las variables, que se consideran constantes, el obtenido en la etapa anterior, hasta obtener la precisión deseada.

Este método anterior está mucho más ajustado a la realidad que el actualmente utilizado por las compañías de distribución de energía eléctrica, pues permite actuar en función del reparto real de las potencias consumidas entre los diferentes puntos de la red. Sin embargo, no se plantea como implementar dicho método propuesto.

Por otra parte, como en cualquier método que precise modificar las regulaciones de los transformadores MT/BT, la aplicación del método anterior supone la realización de cambios en las tomas en vacío de los transformadores MT/BT, en periodos de tiempo fijos, lo cual deberá realizarse tras cortes en el suministro de las líneas alimentadas desde el transformador. Tal proceso no siempre será posible realizarlo de forma sencilla y económica, pero además producirá un coste económico a consecuencia del corte, que no está incluido en la expresión del perjuicio económico.

[Carbone 95, Sorrentino 94, Cesario 94]

Continuando con el conjunto de artículos que se está comentando, se encuentran una serie de artículos sobre la implementación del método propuesto para la regulación de tensión en un sistema de distribución automática. El primero de ellos es un resumen de los resultados obtenidos en los otros dos.

De los dos últimos trabajos, el de [Sorrentino 94] se refiere al sistema de comunicación preciso para la utilización del citado método de regulación en el sistema de distribución automática, mientras que el de [Cesario 94] se encuentra centrado en el desarrollo del hardware necesario para su implementación.

En ninguno de los dos trabajos se introducen modificaciones sobre el desarrollo matemático anteriormente descrito. El sistema propuesto está formado por unas unidades periféricas situadas en los nudos de medida, que permiten elaborar la medida y trasladarla a la unidad central situada en cabecera de la red, unidad de control, que es la que suministra las ordenes adecuadas para la regulación de tensión óptima. Como se puede deducir de lo anterior, el sistema propuesto sólo es útil para la regulación del transformador AT/MT.

[Daeseok 95]

En el artículo publicado en 1995, se plantea el caso de la regulación de tensión cuando existen elementos conectados a la red que pueden suministrar energía a ésta.

El autor toma como objetivo mantener la tensión en todos los puntos de la red dentro de un intervalo alrededor de la tensión nominal de $\pm 6\%$.

Para conseguir el objetivo anterior, el método que propone se basa en el uso de un conductor ideal patrón, que representa las características totales de un conductor, de forma que una línea arborescente quede reducida a una línea sin ramas laterales, implementando en cada nudo del conductor patrón el efecto de las ramificaciones que parten de él en las líneas reales.

Sin embargo, el autor considera complicada la determinación de los valores para la definición del conductor debido a la presencia del compensador de caídas de tensión de las líneas en el transformador de cabecera de la red.

La dificultad aparece por las variaciones aleatorias de las cargas, las diferentes configuraciones de las líneas conectadas a cabecera de la red y la incertidumbre producida por los sistemas de generación repartidos a lo largo de la red de distribución.

En el artículo se plantea la existencia, entre todos los conductores que parten de cabecera, de uno que sea el peor acondicionado (máxima caída de tensión y mayores fluctuaciones de la tensión). Si en el conductor peor acondicionado se consigue que las tensiones en todos sus nudos se mantengan entre los límites previstos, se puede suponer que las tensiones en todos los nudos del resto de la red de distribución estarán comprendidas entre los citados límites.

Con el fin de conseguir optimizar la tensión en cabecera de la red, el autor se plantea obtener la mejor relación de transformación en el transformador AT/MT, para lo que propone minimizar la siguiente expresión:

$$J(t) = \left[V_{1,\max}(t) - V_1(t) \frac{X_{mtr}}{R_{mtr}} \right]^2 + \left[V_1(t) \frac{X_{mtr}}{R_{mtr}} - V_{1,\min}(t) \right]^2 \quad (4.7)$$

sujeito a:

$$\begin{aligned} V_{1,\max}(t) &= V_{\max} \\ V_{1,\min}(t) &= V_{\min} \frac{V_1(t)}{V_2(t)} \end{aligned} \quad (4.8)$$

donde:

$J(t)$: Función objetivo a minimizar en un intervalo de tiempo.

V_{\max} : Límite superior admisible de tensión.

V_{\min} : Límite inferior admisible de tensión.

$V_1(t)$: Tensión en el primer consumidor.

$V_2(t)$: Tensión en el último consumidor.

$V_{1,\max}(t)$: Valor del límite superior de tensión convertido al primer consumidor (tensión máxima en el primer consumidor para que la tensión en todos los nudos quede por debajo del límite superior admisible de tensión).

$V_{1,\min}(t)$: Valor del límite inferior de tensión convertido al último consumidor (tensión mínima en el primer consumidor para que la tensión en todos los nudos quede por encima del límite inferior admisible de tensión).

R_{mtr} : Relación de transformación nominal del transformador.

X_{mtr} : Relación de transformación óptima del transformador (variable frente a la que se minimiza la función objetivo).

Cuando minimizamos la expresión (4.7) se obtiene:

$$X_{mtr} = R_{mtr} \frac{V_{1,\max}(t) + V_{1,\min}(t)}{2V_1(t)} \quad (4.9)$$

De forma similar, se plantean varias expresiones para el caso de existir reguladores de tensión intercalados en serie, especialmente en las líneas que por su larga longitud o elevada carga deban compensar adicionalmente las caídas de tensión que se producen a lo largo de ellas.

El autor no explica la forma de obtener los conductores patrones, por lo que no es posible aplicar el método propuesto de forma simple.

La idea propuesta de reducir el problema de una red de distribución, compuesta por varias líneas conectadas a un transformador AT/MT, al estudio de una sola de ellas, la peor acondicionada, resulta interesante. Sin embargo, para poder aceptar el hecho de reducir el control de una red a una sola línea, es necesario que la carga conectada en dicha línea sea importante en relación con la carga total conectada a la red.

En el caso en que no se cumpla la condición anterior, pueden existir desviaciones elevadas de tensión en líneas muy cargadas. Aunque las desviaciones no superen los límites reglamentarios, la calidad de tensión será muy inferior.

En los ejemplos mostrados en el artículo no vemos que se cumpla la citada condición, sin embargo, según el autor, el método presenta claras ventajas con respecto al método actualmente en uso.

3.1.2.2 Otras propuestas de tipo no económico

[Hidroeléctrica Española 62]

En este documento se estudia el problema de la regulación de tensión desde el lado puramente técnico y de la empresa distribuidora.

Los criterios de regulación de tensión óptima presentados son:

- Mantener la tensión de los nudos de consumo entre los límites que fija el Reglamento.
- Utilizar, de la forma más adecuada posible, los recursos de que se dispone tanto en las estaciones AT/MT como en las líneas MT existentes evitando, dentro de lo posible, nuevas construcciones o ampliaciones.

Con el criterio anterior, el aprovechamiento óptimo de la red se consigue cuando, a plena carga, se produce en la red la máxima caída de tensión permitida por el Reglamento.

En el documento se estudian las distintas posibilidades de regulación de tensión que existen en la red de distribución, llegándose a las siguientes conclusiones:

- I. Es inútil utilizar la regulación en los transformadores MT/BT, si no se emplea la regulación en el transformador AT/MT que alimenta la red.

- II. Es necesario introducir la regulación en los transformadores AT/MT, ya que reduce sustancialmente el coste preciso para conseguir alimentar adecuadamente las redes de distribución, especialmente en zonas de poca densidad de consumo.
- III. En zonas de alta densidad de consumo es conveniente, debido al alto coste de las redes de BT con relación a las de MT, reducir cuanto sea posible la caída de tensión en las líneas MT.

También se puede ver en el documento una aplicación al caso de varias líneas de MT, que parten de las mismas barras del transformador AT/MT, con distinta carga conectada en cada una de ellas a lo largo del tiempo.

De esta aplicación se obtiene como conclusión que es conveniente agrupar las líneas que disponen de curvas de carga similares, ya que la regulación de tensión de cada línea depende del comportamiento del conjunto.

[Cortinas Prieto 97]

La Tesis Doctoral de D. Cortinas estudia el problema de la regulación de tensión en las redes públicas de distribución francesas. En ella se hace en primer lugar, una exposición de los sistemas de regulación de tensión utilizados en la actualidad en Francia, que son similares a los utilizados en España.

A continuación el autor realiza un repaso sobre las imprecisiones que presenta el sistema actual para la determinación de la tensión de consigna, como son los errores de medida, los de las características de los reguladores, etc.

Posteriormente se incluyen los distintos criterios de regulación de tensión, separándolos en dos grupos:

- **Criterios implícitos:** son aquellos que no aseguran que la caída de tensión en la red de distribución se encuentre dentro de los límites reglamentarios.
- **Criterios explícitos:** son aquellos cuyo objetivo principal es que la caída de tensión en la red está limitada por los límites reglamentarios.

Dentro del primer grupo el autor cita el método de reducción de errores, mientras que en el segundo grupo incluye los siguientes cuatro criterios:

- el criterio de maximización de la tensión, que obtiene la máxima tensión de salida del transformador AT/MT para que la caída de tensión permanezca entre

los límites reglamentarios, con el fin de utilizar al máximo las características del transformador y de las líneas que forman la red de distribución

- el criterio de minimización de la tensión, que obtiene la mínima tensión de salida del transformador AT/MT para que la caída de tensión permanezca dentro de los límites reglamentarios. Este criterio se utiliza para aplanar las curvas de carga diarias
- el criterio de tensión media en el rango de variación, con diversas variantes en función de la media elegida
- el criterio de minimización de pérdidas, con el fin de reducir las pérdidas de potencia activa en las líneas que forman la red de distribución

Con cada uno de los criterios explícitos anteriores, el autor analiza el comportamiento de los diferentes sistemas de regulación posibles, que son:

- regulación por consigna fija: la tensión a obtener a la salida del transformador AT/MT permanece constante a lo largo del tiempo.
- regulación por compundaje: la tensión de referencia se modifica por medio de un factor proporcional a la intensidad total de salida del transformador AT/MT.
- regulación por compundaje multivariable: la tensión de referencia se modifica por medio de un factor relacionado con las intensidades de cabecera de cada una de las líneas que parten de un mismo transformador A.T./M.T.. Este método está propuesto por el autor y no se encuentra actualmente en funcionamiento.

Finalmente, en esta tesis se indica que la solución ideal sería la implementación de la regulación de tensión en un sistema telecontrolado. Por contra, el autor llega a la conclusión de que con los métodos actuales de telecontrol en redes de distribución y de modelización de cargas en BT, no es posible su realización.

La causa del citado problema es la falta de disponibilidad, actualmente, de modelos de cargas en BT válidos en todo momento.

Para el caso de que la regulación de tensión en los transformadores no sea capaz de mantener la tensión entre los límites reglamentarios, en el documento se plantean dos tipos de soluciones: por una parte, los reforzamientos de la red, y por otra, los medios de regulación en línea (baterías de condensadores en paralelo y reguladores en línea). Estos últimos resultan más económicos, sin embargo, debe realizarse un estudio detallado de su

efecto sobre otros indicadores de calidad de onda y su impacto sobre las transmisiones que se realizan por corrientes portadoras (señales tarifarias y de datos).

De todas formas, parece lógico pensar, que en un corto intervalo de tiempo los problemas que se presentan para la implementación en un sistema telecontrolado sean superados.

La tesis doctoral reseñada es de gran importancia dentro del campo de la regulación de tensión, pues realiza un estudio bastante completo sobre las características de los medios de regulación actualmente utilizados, haciendo hincapié en sus fundamentos físicos y/o matemáticos, que en algunos casos, debido a su largo tiempo de utilización habían sido olvidados.

3.1.3 Uso de técnicas evolutivas

El empleo de técnicas evolutivas, y más concretamente, el uso de algoritmos genéticos, ha estado ligado fundamentalmente a la resolución del problema de optimización que subyace bajo el planeamiento de ubicaciones para compensadores de energía reactiva (SVC, bancos de condensadores, compensadores síncronos, etc). Existe bastante literatura al respecto, aunque no demasiada que haga referencia a la optimización de los cambiadores de tomas en los transformadores.

[Haida 91]

Este artículo es uno de los primeros en los que se empiezan a utilizar los algoritmos genéticos para aplicaciones de optimización en redes eléctricas.

El trabajo se centra en la optimización de tensiones de una red eléctrica actuando sobre los condensadores de dicha red. Para ello utiliza codificación binaria (código gray) para representar la capacidad de las baterías de condensadores y además introduce una función objetivo donde las tensiones de los nodos coexisten con penalizaciones provenientes de las restricciones no cumplidas.

Se realizan dos test de prueba sobre redes de pequeño tamaño. En el segundo de ellos se introduce un efecto de ruido en la función objetivo. Se compara con otras técnicas como el método simplex y búsqueda aleatoria, ofreciendo mejores resultados el algoritmo genético.

[Iba 94]

El trabajo de Iba introduce una nueva perspectiva en la optimización de los flujos de energía reactiva (y también en el perfil de tensiones) con respecto a los trabajos anteriores.

Mediante el empleo de un algoritmo genético simple modificado, se obtienen unos resultados bastante prometedores, aunque poco eficientes desde el punto de vista computacional.

Las novedades que aporta el trabajo consisten, fundamentalmente, en una búsqueda múltiple por el espacio de soluciones para evitar caer en mínimos (o máximos) locales, el uso de múltiples funciones objetivo (sin llegar a ser una tarea multi-objetivo en el sentido de Pareto), el uso de variables enteras en lugar de binarias y el empleo de dos operadores adaptados conocidos como *entrecruzado*, que realiza funciones de cruce entre topologías, y el operador *manipulación*, que está basado en reglas de la Inteligencia Artificial.

Las redes de prueba analizadas son de tamaño realista con 54 y 224 nodos cada una, respectivamente, aunque para redes mayores, el algoritmo consume un excesivo tiempo en su resolución. Se han encontrado soluciones de buena calidad.

[Miranda 94]

En el trabajo de Vladimiro Miranda et al. se vuelve a aplicar la optimización mediante algoritmos genéticos, pero en este caso para planificación óptima multietapa de redes de distribución. Los autores describen un modelo matemático y algorítmico que han desarrollado y experimentado con éxito. El artículo, también presenta ejemplos de aplicación con sistemas de tamaño real. Las ventajas de adoptar esta nueva aproximación se discuten en el contexto de planificación, es decir, en conjunto con la adopción de métodos de decisiones multicriterio.

En esta ocasión se utilizó codificación binaria para los individuos (cromosomas) y se adaptó la función objetivo de modo que se hiciese una evaluación “a posteriori” de la población. Esta función objetivo o “*fitness*” era obtenida en función de otras evaluaciones anteriores que intentaban categorizar a las soluciones en función del grado de cumplimiento de ciertas restricciones.

Lo fundamental de este artículo es que ayudó a afianzar más la técnica evolutiva frente a otras tradicionales y a salvar ciertos obstáculos típicos como la no linealidad del problema o la posibilidad de plantear al operador un esquema multicriterio en el desarrollo de la planificación de la red eléctrica.

[Ramos 04]

El trabajo de Rodrigo Ramos et al. supone la utilización pionera de técnicas multi-objetivo para la optimización en compensación de energía reactiva y seguridad en tensiones.

En dicho artículo se hace una aproximación al problema empleando una variante del algoritmo conocido como “Strength Pareto Evolutionary Algorithm (SPEA)”, al objeto de tratar la compensación de energía reactiva en sistemas eléctricos como un problema multi-objetivo. A la vez que se hace este planteamiento, también se consiguen convertir ecuaciones, tratadas tradicionalmente como restricciones, en nuevas funciones objetivo.

El método propuesto consigue optimizar diferentes parámetros típicos de la operación de sistemas de potencia, como son la cantidad de dinero invertida en dispositivos compensadores de energía reactiva, las pérdidas de energía en líneas de transmisión y distribución, y como una novedad con respecto a otras aproximaciones, se incluye la seguridad en tensiones.

Utilizando esta técnica, se consigue encontrar un conjunto amplio de soluciones, conocido como “*frente de Pareto*”, que permite decidir la mejor solución de entre varias posibilidades y características.

Para validar los resultados obtenidos con la propuesta de este artículo, los autores han comparado su trabajo con un conjunto de herramientas de compensación elaboradas por especialistas usando técnicas tradicionales en ingeniería. También se introduce una serie de métricas sobre cómo establecer los resultados de dicha comparación.

Los resultados obtenidos consiguen emular un buen frente de soluciones (frente de Pareto), bien definido y fácil de obtener y calcular.

[Augugliaro 04]

El artículo de Antonino Augugliaro et al. trata sobre el problema de la regulación de tensiones y la minimización de pérdidas de potencia activa en sistemas de distribución eléctrica de forma automatizada. En él se aporta una nueva visión de conjunto a la hora de formular el problema del control de cambiadores de tomas y bancos de condensadores. En dicha visión se añade la gestión integrada de los interruptores de línea y condensadores de las líneas que, partiendo de la subestación, conforman una gran red mallada de distribución operada de forma radial. Se establece todo lo anterior, al objeto de conseguir una minimización en las pérdidas de potencia y un perfil más plano de tensiones.

Para lograr sus objetivos, los autores se han apoyado en técnicas evolutivas multi-objetivo y en teorías de lógica difusa ("fuzzy").

Los objetivos a tratar son por una parte, las pérdidas de potencia en las líneas de distribución junto a las pérdidas de potencia en los transformadores de AT/MT, siendo despreciadas las pérdidas de los transformadores MT/BT y otros tipos de pérdidas menores, y por otra parte el perfil de tensiones de la red. Ambos objetivos deben ser minimizados. Además de los dos objetivos mencionados, los autores utilizan 2 restricciones basadas en el índice de balanceo de carga y en el número de cambios en los dispositivos actuadores (cambiador de tomas y escalones de las baterías de condensadores).

La resolución del problema se basa en la utilización de un algoritmo evolucionista modificado, donde solamente se utiliza la mutación como operador que evoluciona a la población de individuos.

Los autores han realizado ensayos en una red de 138 nudos AT/MT donde coexistían transformadores con cambiadores de tomas, bancos de transformadores e interruptores de línea al objeto de reconfigurar la red en caso necesario. Dichos ensayos muestran que se pueden lograr escenarios de perfiles más o menos planos en tensión, así como disminuciones de pérdidas de potencia en las líneas, cumpliendo las restricciones operacionales impuestas relativas a la seguridad de los equipos y su vida media esperada.

[Furong 05]

Este artículo propone un algoritmo genético multi-objetivo de codificación entera (IGA *Integer-coded Genetic Algorithm*), aplicado al problema de la planificación de la compensación de potencia reactiva, considerando situaciones de explotación normales y de contingencia. El IGA se usa para resolver, simultáneamente, tanto el problema de emplazamiento (optimización en la instalación de nuevos dispositivos) como la cuestión de operación del sistema (optimización preventiva en los cambiadores de tomas de los transformadores y de las características controladoras de los sistemas de compensación dinámicos).

El objetivo es conseguir un plan de emplazamiento que no viole ninguna restricción operacional o de sistema y que sea óptima en términos de desviación de tensión respecto de la nominal y en términos de los costes en que se incurre debido a la instalación y uso de dispositivos para la compensación de potencia reactiva.

El problema multi-objetivo se resuelve a través del concepto de optimalidad de Pareto. El algoritmo desarrollado se ha comprobado en una red IEEE-30 y en un sistema real reducido.

El algoritmo ha sido comparado con el paquete comercial SCORPION, el cual está basado en planificación mediante Programación Lineal y que usa el operador eléctrico británico en la red de transporte de Inglaterra y Gales.

Este artículo demuestra que el IGA es superior al método de programación lineal que se usa actualmente, tanto en términos de condiciones del sistema como en términos de coste de instalación y utilización, cuando se sitúan dispositivos de compensación dinámicos y fijos; el funcionamiento del sistema es optimizado a través del ajuste de cambio de configuraciones y características controladoras a lo largo de múltiples estados de operación.

3.1.4 Uso de técnicas convencionales

[Bridenbaugh 92]

En este artículo se realiza un estudio para el planeamiento eficaz de la red eléctrica de la compañía Ohio Edison. Mediante un programa de reemplazamiento de bancos de condensadores, se volvió a revisar los requerimientos reales de compensación reactiva para un mejor perfil de tensiones en la red.

Se encontró que la utilización del flujo de carga óptimo (OPF *Optimal Power Flow*) permitía una mejor coordinación de los elementos de control de tensión, concretamente, el uso de los cambiadores de tomas en los transformadores. También se encontró que este tipo de actuaciones además, reducían las pérdidas de potencia activa y reactiva del sistema así como las importaciones de energía reactiva de otros subsistemas.

La operativa utilizada fue la de realizar procesos iterativos iniciales en los que se iban ajustando las tomas de los transformadores para condiciones de carga reducida de forma que, una vez encontrada la solución que mantenía a las tensiones nodales controladas, se procesaba en una segunda etapa las condiciones de carga elevada, donde ya se utilizaban los bancos de condensadores para ajustar el perfil de tensiones. A través de este proceso se conseguían dos cosas: encontrar la ubicación óptima de los bancos de condensadores y ajustar las tomas de los transformadores para hacer lo más plano posible el perfil de tensiones.

La desventaja que tiene este sistema es que necesita de varios procesos iterativos para ajustar los valores (ensayo-error) y además no tiene en cuenta la posibilidad de cambiar dinámicamente las tomas de los transformadores y así poder controlar de forma más efectiva el perfil de tensiones.

[Lu 95]

Este artículo estudia el problema del control de tensión/potencia reactiva en subestaciones de distribución. El propósito de este artículo es despachar o programar convenientemente los condensadores y los cambiadores de tomas de los transformadores en las subestaciones de distribución, en función de la distribución horaria de cargas existente en un trafo principal y la evolución de sus tensiones en el primario, de manera que se minimice el flujo de potencia reactiva que fluye por este transformador, así como la desviación de tensión (respecto de valores deseados) en el secundario.

Se han tenido en cuenta las restricciones de tensión en el secundario del transformador y el máximo número de veces que se puede cambiar la toma del cambiador en un solo día.

Para la resolución del problema se ha utilizado programación dinámica. Para demostrar la utilidad de la aproximación propuesta, se ha mejorado el control de tensión/reactiva en una subestación de distribución dentro del área de Taipei (Taiwan). Se ha encontrado que, con el método propuesto, se puede alcanzar una buena programación para los bancos de condensadores y los cambiadores de tomas bajo carga.

[Son 00]

Este artículo propone un esquema de control coordinado para un SVC (compensador estático de reactiva o *static voltage compensator*) y un ULTC (cambiador de tomas en carga o *under load tap changer*) en subestaciones de distribución para disponer de mayor margen de operación en el SVC de cara a posibles actuaciones en escenarios de emergencia. La idea que subyace bajo esta propuesta es la falta de margen operativo que se puede producir con los actuales sistemas de control a la hora de actuar sobre el SVC. Debido a la importancia de poder actuar en situaciones de emergencia, se hace necesario asegurar ciertos márgenes de maniobra que permitan responder ante eventuales contingencias.

El método propuesto por los autores se basa en un control coordinado entre el cambiador de tomas (ULTC) y el SVC, de forma que, el control primario lo realiza el SVC sobre las tensiones y el cambiador sólo responde ante un determinado nivel de

compensación del SVC, el cual se basa a su vez, en una relación entre la posición del cambiador de tomas y el nivel de compensación proporcionado por el SVC.

De esta forma, el margen operativo del SVC se preserva gracias a la adaptación progresiva del tiempo de retardo del ULTC en función de las condiciones operativas del SVC.

Los autores han obtenido simulaciones numéricas donde observan que el método propuesto incrementa el margen del SVC en combinación con el ULTC, consiguiendo además mejorar la calidad de la tensión en barras de distribución.

Como comentarios al trabajo realizado por los autores, hay que destacar que sólo se tienen en cuenta factores locales de la propia subestación y no se utilizan variables del resto de la red que puedan ayudar contrarrestar los problemas de una posible contingencia, es decir, interactuar no sólo con los actuadores locales (SVC y ULTC) sino también con los de las subestaciones vecinas. Además, no queda claro el criterio de operación a la hora de ajustar el valor del cambiador de tomas en función de las condiciones de trabajo del sistema.

[Kim 05]

Este artículo presenta un esquema de control coordinado basado en redes neuronales artificiales (ANN o *Artificial Neural Network*) para el manejo de cambiadores de tomas en transformadores y STATCOM's (compensadores estáticos). El objetivo del control coordinado es minimizar el número de cambios en la toma del transformador y en la salida del STATCOM, de forma que se obtenga un nivel aceptable de tensión en la barras de la subestación.

En este trabajo se describe como la conjunción de los dos sistemas puede producir un mejor resultado en el margen de trabajo de ambos dispositivos. Teniendo en cuenta las limitaciones del cambiador de tomas, en cuanto a su posibilidad de cambio continuo, se generan reglas de trabajo para que el STATCOM presente la máxima reserva de energía reactiva disponible para realizar el control de nudo eléctrico en cuestión.

Lo novedoso de este sistema consiste en asociar la ley de control del cambiador de tomas a un controlador coordinado que tiene en cuenta la potencia activa y reactiva del nudo a controlar, la posición actual del cambiador de tomas y la salida de potencia reactiva del STATCOM. De esta forma, se consigue evitar oscilaciones en los cambios de toma, siendo asumidas tales actuaciones necesarias por el STATCOM. Una vez que se está llegando a los límites del STATCOM, el cambiador de tomas tiene más probabilidad

de entrar en escena, provocando un aumento del margen del STATCOM para situaciones de emergencia.

La principal desventaja de este estudio, radica en la gran cantidad de computaciones que deben realizarse para entrenar a la red neuronal. Este comportamiento es típico de estos sistemas. Además la solución propuesta requiere del afinamiento de dos parámetros específicos para lidiar con la interacción entre STATCOM y cambiador de tomas y que hacen difícil la coordinación entre los dispositivos.

El modelo propuesto se ha ensayado en una red de pequeño tamaño como la IEEE14 y sólo para elementos en un único nudo.

[Wei 05]

En este artículo se desarrolla un algoritmo que permite encontrar la mejor conmutación de línea y barra de distribución de forma que se mitigue la aparición de sobrecargas y desvíos no permitidos de tensión causados por contingencias del sistema eléctrico.

Este algoritmo está basado en la utilización de técnicas de inversión de matrices vacías y el uso del flujo rápido de cargas desacoplado con límite de iteraciones.

Además, se presenta también, un algoritmo novel para la corrección controlada de tensiones mediante conmutación de “*shunts*”, basado en un nuevo factor de distribución de tensiones que se apoya en el cálculo iterativo de flujos de carga.

Estos dos algoritmos, se integran en uno más global, denominado algoritmo de conmutación correctivo. Las simulaciones en el sistema WECC179 indican que el nuevo algoritmo de conmutación correctiva propuesto en este artículo puede resolver, de forma efectiva, ciertos problemas de sobrecarga en líneas y desviación de tensión en las mismas. El tiempo de computación empleado parece ser satisfactorio.

Capítulo 4

Aplicación de algoritmos genéticos a la optimización de tensiones

En este capítulo se presenta la aplicación de un algoritmo genético a la resolución del problema de optimización de tensiones en redes de distribución eléctrica. Como se ha mencionado en capítulos anteriores, este problema es una cuestión de programación matemática combinatoria, entera, no lineal y de gran dimensión. Estas características hacen que las técnicas convencionales de resolución no sean capaces de garantizar la obtención de la solución óptima a este problema cuando el sistema se hace de tamaño real.

Esta Tesis propone un algoritmo genético que, por medio de heurísticas, obtiene un conjunto de soluciones cercanas al óptimo de este problema. La principal característica del algoritmo genético desarrollado es la capacidad de poder trabajar con las tomas de los transformadores en vez de hacerlo con las tensiones nodales. Esta característica evita que la solución del problema sea la trivial, ya que el fundamento de la optimización buscada consiste en minimizar un índice de calidad, el cual es a su vez directamente proporcional al cuadrado de las tensiones en cada punto de la red y, por tanto, haciendo que una búsqueda del óptimo coincida con un perfil plano de tensiones, es decir, todos los nodos de la red con tensión igual a la nominal.

El algoritmo emplea una alfabetización de tipo entera para no incurrir en infactibilidades, ya que de cualquier otra forma, las poblaciones de trabajo producirían individuos que no serían factibles, es decir, no se corresponderían con las tomas reales de los transformadores. Este extremo pudo ser comprobado al inicio de los trabajos de investigación. En los mismos se comenzó utilizando codificación binaria que luego pasaba a representar número reales, de forma que los resultados obtenidos debían ser depurados para que la solución tuviese sentido, esto es, se correspondiese con alguna de las tomas reales de los transformadores. Este aspecto introducía una pequeña distorsión en la solución final, al no ser el óptimo obtenido matemáticamente.

El empleo de una base entera a la hora de codificar la población permite eliminar ciertos riesgos de estancamiento y acelera la convergencia del proceso.

La capacidad de modelado de esta técnica es muy poco restrictiva y permite describir fácilmente el problema. De esta forma, se pueden modelar todo tipo de no linealidades tanto en el proceso de flujo de cargas (obtención del estado de carga de una red eléctrica) como en las restricciones técnicas inherentes a la red existente (tensiones máximas y mínimas, número de escalones en los transformadores y topología de la red). Además, permite utilizar información de toda la red para la optimización local, cosa que no se puede hacer con los procedimientos típicos de ajuste en los transformadores de distribución.

Para el problema de la optimización de tensiones en redes de distribución, cada generación está formada por un número fijo de individuos obtenidos a partir de los individuos de la generación anterior. La primera generación se puede obtener de forma aleatoria o bien se puede partir de un conjunto predefinido de valores y que tengan valor desde un punto de vista de la aproximación a la solución óptima estimada.

Por otro lado, esta técnica de optimización presenta otra ventaja: debido a su estructura, es paralelizable de forma simple. Aunque dicha labor se sale fuera del objetivo de esta tesis, se plantearán líneas de actuación para poder implementarse en un futuro próximo.

4.1 Estructura y características del algoritmo genético desarrollado

Esta Tesis propone el empleo de un algoritmo genético clásico, conducido mediante heurísticos y que ha sido modificado en su estructura para resolver el problema específico de la optimización de tensiones empleando, exclusivamente, los cambiadores de tomas de los transformadores de distribución. Esta característica permite una búsqueda más eficiente (ya que el espacio a explorar es el conjunto de soluciones factibles) y evita los problemas de convergencia de los algoritmos genéticos basados en penalizaciones.

Es importante hacer notar la relevancia de buscar en un espacio de soluciones factibles, ya que ello mejora notablemente la velocidad del algoritmo así como su convergencia.

El algoritmo propuesto preserva la factibilidad de todos los individuos en todas las generaciones. Ello es posible gracias a la utilización de un esquema de trabajo donde sólo se generan individuos factibles con los que trabajar. Estos individuos se corresponden con las tomas discretas de los cambiadores, estando forzados a adoptar valores estándar de dichos dispositivos.

Inicialmente, en una fase temprana de este trabajo, la filosofía en la elección del espacio de búsqueda fue diferente. Al objeto de diseñar el algoritmo partiendo de las metodologías tradicionales, se emplearon codificaciones que podían producir individuos los cuales no se correspondían con valores reales de los cambiadores, por lo que era necesario realizar una serie de pasos para normalizar dicha situación y que el resultado final, es decir, la posición a adoptar en cada uno de los cambiadores de la red analizada, se correspondiese con posiciones factibles. En este sentido, se trabajó con codificación binaria y con codificación real. Obviamente, esta elección no era óptima en sí misma y se optó por una codificación entera cuyos rangos permitidos coinciden con los valores extremos de los cambiadores de tomas.

La principal ventaja es que no se necesita de un algoritmo de reparación que trabaje sobre un espacio de búsqueda amplio, lleno de soluciones infactibles, sino en espacios de búsqueda acotados (compuestos de soluciones factibles). Por ello, la exploración es más reducida y aumenta la eficiencia del algoritmo.

Como cualquier algoritmo genético, el desarrollado en esta Tesis consta de las fases que se describen en la figura 4.1.

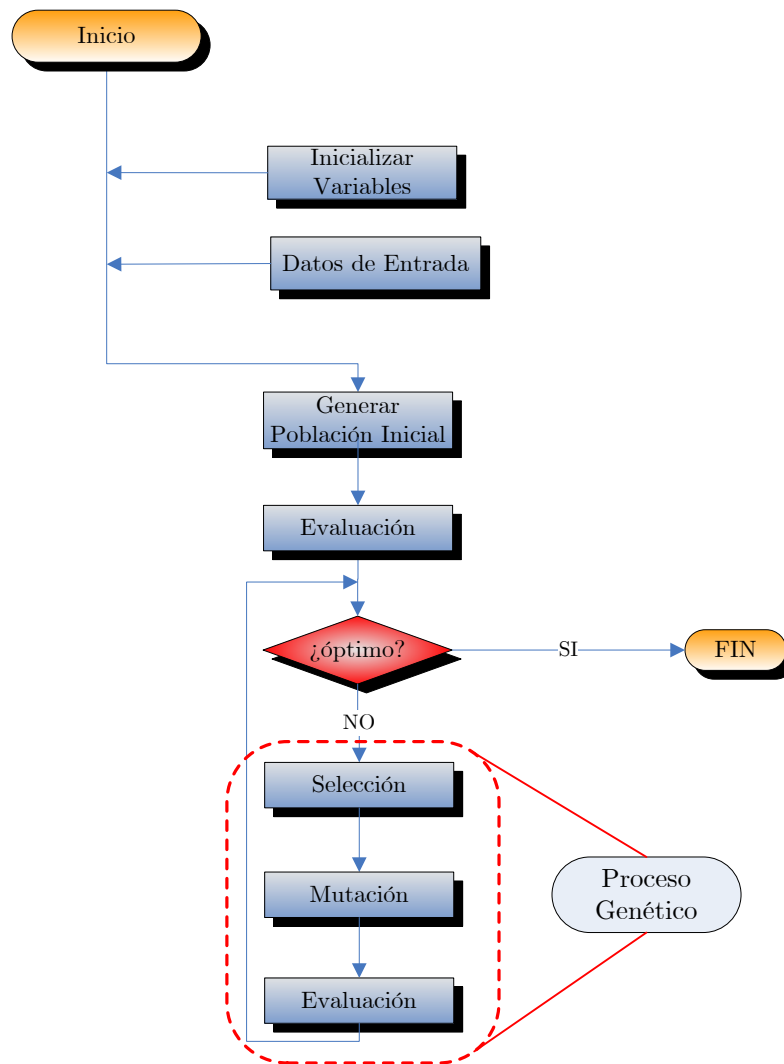


Figura 4.1 Esquema típico de un algoritmo genético secuencial

Las fases desarrolladas, más específicamente, se corresponden con las siguientes:

Fase 1. Inicialización.

Se genera una población inicial de soluciones que se corresponde con un perfil “no plano” en los cambiadores, es decir, todas las tomas no están en su posición base. Todas las soluciones son factibles de inmediato ya que han sido generadas conforme a un patrón de codificación entera y una correspondencia biunívoca con las mencionadas tomas. A continuación, se lee el fichero de datos que contiene la red a tratar (en este caso se han tratado diversas redes como la *ieee14*, *ieee30*, *ieee118*, *rts*, etc) y en el cual se definen las características de todos los nudos, todas las líneas, todos los generadores así como todos los transformadores.

Cabe realizar la observación de que mejora la convergencia del algoritmo cuando se utiliza un perfil “no plano”, es decir, las tomas no están en su nivel de referencia, en los cambiadores de los transformadores. Curiosamente, utilizar una población inicial aleatoria acelera el proceso de obtención del óptimo.

Fase 2. Selección

Se han utilizado diversas técnicas de selección a modo de análisis comparativo. Entre estas técnicas, y como algoritmos más empleados, están “la ruleta” (*Roulette Wheel Selection, RWS*) y “Muestreo Estocástico Universal” (*Stochastic Universal Sampling, SUS*), ambos ya descritos en el apartado 2.3.4.1.

A modo de resumen, estos métodos seleccionan, aleatoriamente, los mejores individuos de la generación anterior para ser padres de la generación en curso. Los mejores individuos son aquellas soluciones que producen un menor índice en calidad de tensión, definido según

$$D = \sum_{i=1}^N \frac{(U_i - U_{ni})^2}{U_{ni}^2} \quad (4.1)$$

donde

D : Índice de Calidad de Tensión o *IDT*

U_i : Tensión en el nudo i .

U_{ni} : Tensión nominal en el nudo i

La probabilidad de selección de cada individuo se calcula en función de su medida de calidad o *fitness*. Esta medida de calidad se realiza en función del método de escalado elegido. Básicamente, en esta Tesis se han elegido dos tipos de escalado: *Asignación de calidad mediante rangos (rank-based fitness assignment)* y *Escalado lineal (scaling)*. Todo lo anterior, con el fin de mejorar la

convergencia del algoritmo ya que así, se evita la aparición de individuos dominantes que produzcan una convergencia prematura, y se aumentan las diferencias entre individuos muy parecidos en términos de medida de calidad para evitar que el proceso de búsqueda sea completamente aleatorio.

Fase 3. Aplicación de operadores genéticos.

La aplicación del operador elitista asegura la supervivencia de una o varias de las mejores soluciones encontradas en cada generación. Este operador se implementa de una forma muy sencilla y práctica: se hacen pasar a la generación siguiente aquellos individuos con mejor *fitness*. Durante los diferentes tests llevados a cabo, se ha ido variando este parámetro, habiendo utilizado un valor de entre el 10% y el 30% de individuos catapultados directamente a posteriores generaciones. Como se ha demostrado en el capítulo 2, este operador es necesario para que haya convergencia asintótica al óptimo.

Una vez se han apartado las mejores soluciones, se emplea el operador cruce, el cual genera una pareja de soluciones hijas a partir de cada pareja de soluciones padres. Se genera un número de soluciones igual al tamaño de la población menos aquellas soluciones elitistas que han pasado directamente a la siguiente generación. Por último, bajo una determinada probabilidad de ocurrencia, se aplica el operador mutación a algunas de las soluciones escogidas aleatoriamente.

Fase 4. Tratamiento de infactibilidades y evaluación

Uno de los puntos fuertes del método elegido estriba en la habilidad innata para no generar soluciones no factibles. Debido a la propia naturaleza de la codificación (que se verá mas adelante), los individuos de la población puede cruzarse entre sí o mutarse y siempre generarán nuevos individuos que pertenecen al espacio de posibles soluciones. Esto presenta una gran ventaja desde el punto de vista computacional ya que es bien sabido los grandes costes en tiempo que acarrearán las reparaciones de infactibilidad [Arroyo 02].

El criterio de convergencia empleado es un número máximo de generaciones, aunque también se puede parar el proceso si la diferencia entre las últimas mejores soluciones encontradas no supera un límite.

4.1.1 Representación

Las dos principales acciones que relacionan a un algoritmo genético con el problema a resolver son: (i) la forma de traducir una solución del problema a un cromosoma o individuo, y (ii) la elección de una función de evaluación que devuelva una medida de la calidad de cada solución en el contexto del problema. El éxito del algoritmo genético depende en gran medida de estos dos aspectos.

La codificación es específica para cada problema, incluso se pueden encontrar diversas formas de representar las soluciones de un mismo problema. El problema tratado en esta Tesis, la calidad de tensión en redes de distribución que se apoyan en las variaciones de los cambiadores de tomas para ajustar dicha tensión, sugirió en un principio que la mejor forma de representación podía ser la binaria. Esto se tradujo en una implementación como la de la figura 4.2. En dicha figura se observa como en la codificación de la toma de un transformador k se utilizan i posiciones para representar una toma cualquiera. Para cubrir todas las tomas de un transformador se debe cumplir que $2^i \geq j$, siendo j el número de tomas que tiene dicho transformador.

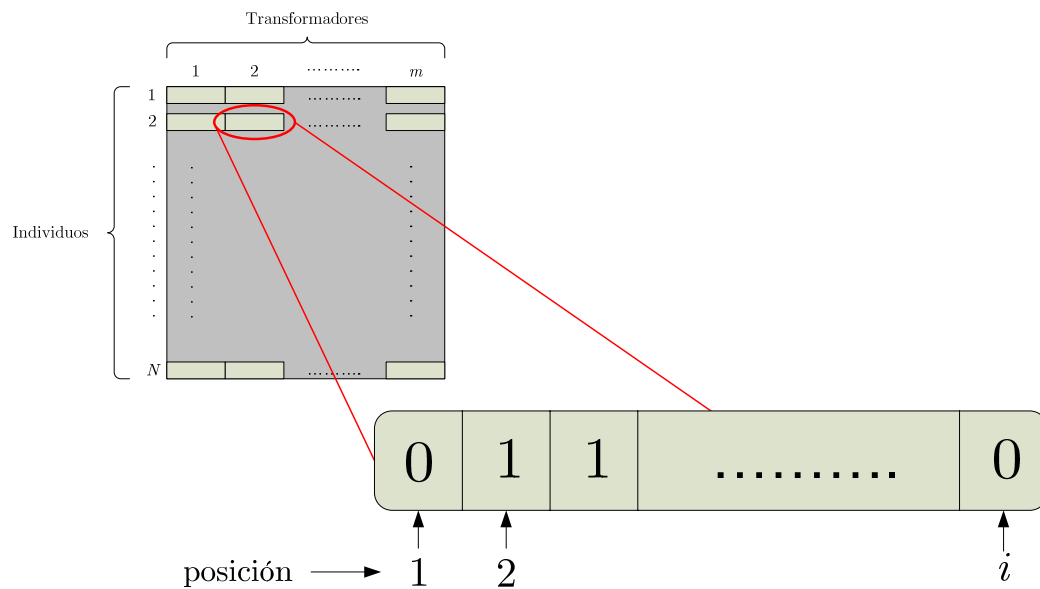


Figura 4.2 Representación de la codificación binaria de las tomas de los transformadores

Claramente, se aprecia el principal inconveniente de esta representación: la aparición de infactibilidades. Puesto que la cantidad de tomas que se pueden representar con i bits es mayor que el número real de tomas de los transformadores, esto hace que haya esquemas que representen a tomas inexistentes. Veámoslo con un ejemplo:

Ejemplo 1

Sea una red de distribución con 4 transformadores trifásicos. Todos los transformadores son iguales y poseen un cambiador de tomas con 5 posiciones (-5%, 2.5%, 0, +2.5%, +5%).

Para representar las tomas con codificación binaria se necesitan 3 bits => $2^3 = 8$ tomas.

Como quiera que los trafos sólo disponen de 5 tomas, existen 3 tomas "ficticias" que deben ser tratadas como infactibles cada vez que aparezcan en el proceso genético como consecuencia de cruces o mutaciones.

Otra posibilidad es utilizar codificación real. En este caso se establece un margen de trabajo que coincide con los márgenes de los cambiadores. Si los cambiadores trabajan entre, digamos $\pm 5\%$, entonces se utiliza un margen de trabajo entre 0.95 y 1.05 (en pu).

Por supuesto, debemos establecer la precisión de trabajo así como el formato en coma flotante para la codificación binaria.

En este caso, se evita la aparición de infactibilidades como en la codificación binaria tradicional, ya que se obliga al algoritmo a trabajar en el margen establecido, pero esto no impide que la solución obtenida deba ser retocada para que pueda ser utilizada por un cambiador real. Téngase en cuenta que, tras encontrar el óptimo, éste puede tener cualquier valor real entre los márgenes de trabajo y no tiene por qué coincidir, precisamente, con las tomas nominales de los cambiadores. Por ejemplo, el algoritmo puede encontrar un óptimo para un trafa dado, en la posición 0.9745, aunque esta posición no exista físicamente.

Todo lo anterior requiere de un proceso de refinamiento en la solución obtenida, de forma que se haga coincidir con alguna de las tomas físicas del transformador. La solución más lógica es redondear a la toma más cercana. En el ejemplo anterior, si el trafa en cuestión, presenta escalones del 2.5%, se debería hacer una normalización de la solución obtenida (0.9745) hacia la toma 0.975.

Resumiendo, la codificación real requiere de procesos de reajustes externos sobre la solución obtenida para que la implementación en casos reales sea efectiva. Estos reajustes

pueden provocar que, en ciertos casos, se elijan tomas que hagan perder el óptimo de la red por las modificaciones de conjunto que originan (es posible que este “redondeo” de tomas afecte a los transformadores cercanos).

Para evitar los inconvenientes de las codificaciones anteriores se ha optado por utilizar una codificación entera. Esta decisión tiene dos grandes implicaciones:

- Acota enormemente el espacio de búsqueda
- Impide que se generen soluciones infactibles

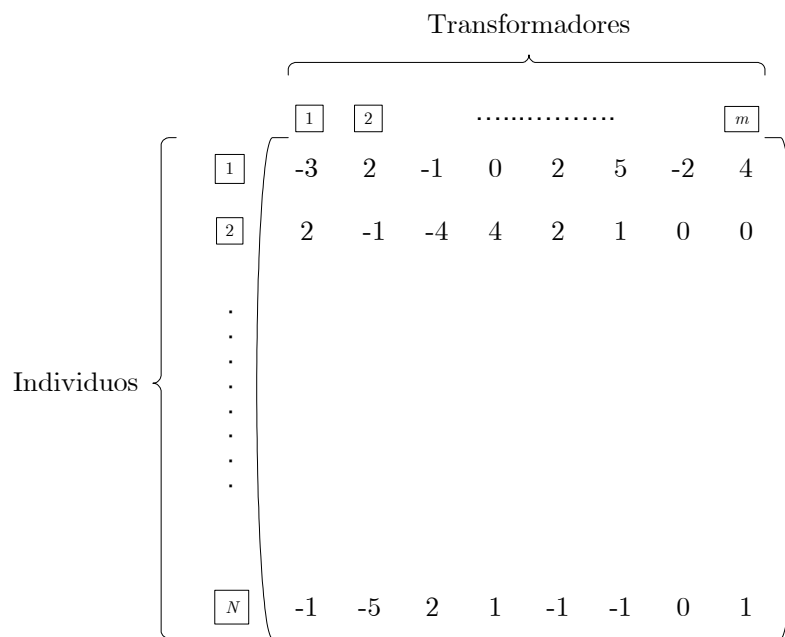


Figura 4.3 Representación de la codificación entera para un población de transformadores

Efectivamente, según se muestra en la figura 4.3, ahora la codificación hace que los elementos sean sólo y exclusivamente aquellos que se corresponden con una toma física en los cambiadores de los transformadores. Suponiendo que se tienen m transformadores con cambiadores de tomas de 11 posiciones, entonces se puede establecer la siguiente relación (suponiendo un escalón igual al 1%):

Toma	Codificación
-5%	-5
-4%	-4
-3%	-3
-2%	-2

-1%	-1
0	0
1%	1
2%	2
3%	3
4%	4
5%	5

Tabla 4.1 Relación entre la toma del cambiador y su representación entera.

De esta manera, teniendo en cuenta el escalón elegido y el número de tomas del cambiador, se puede establecer una representación entera de la solución que refleje fielmente la posición en el propio cambiador de tomas.

Además, es bastante aparente la simplificación que se ha hecho del espacio de búsqueda, limitándolo exclusivamente a los valores físicos de los cambiadores.

4.1.2 Medida de calidad o “*fitness*”

Como se ha indicado anteriormente, la función objetivo que se define en esta Tesis es

$$D = \sum_{i=1}^N \frac{(U_i - U_{ni})^2}{U_{ni}^2} \quad (4.2)$$

de forma que se persigue su minimización.

El valor D provee de una medida acerca de cómo se comportan los individuos en cuestión. En nuestro caso, estos individuos se corresponden con las tomas de los cambiadores en los transformadores. Una vez ajustadas las tomas, la red queda definida y completa desde un punto de vista topológico. Si además tenemos en cuenta que la resolución de la red, mediante algún algoritmo de flujo de cargas, requiere que sean conocidas las potencias activas y reactivas de los nudos PQ y ciertas tensiones en los nudos PV (además de los valores propios de líneas y demás elementos que conforman la red), podemos concluir que el resultado en cuanto a tensiones, corrientes, potencias y demás variables está asociado inequívocamente con el escenario específico existente en los cambiadores de tomas.

Lo anterior, asegura que la utilización de una población de individuos diferente a las variables empleadas en la función objetivo, es viable y conduce a una solución del problema.

Ahora bien, D no se suele utilizar directamente como una medida de la calidad de las soluciones o individuos de una población, por una razón fundamental: en procesos de minimización, los mejores individuos presentan un índice D menor que los peores individuos, por lo que se hace necesario una transformación que tenga en cuenta este inconveniente. Lo típico es realizar una transformación como la siguiente

$$F(D) = g(D)$$

donde g es una función que transforma los valores de D , en otros valores F . A esa transformación se le denomina “*medida de calidad ponderada*” o “*fitness*”.

Se pueden aplicar diferentes tipos de transformación: lineal, no lineal, etc., obteniendo un escalado que representa, a grosso modo, la expectativa de reproducción final que tiene un individuo en una determinada población.

Este índice de calidad o *fitness* se emplea para regular la presión que unos individuos ejercerán sobre la generación siguiente. Los individuos (o soluciones) de menor índice serán elegidos más frecuentemente para ser padres de la siguiente generación aunque, en función del escalado elegido, se podrá hacer de forma más o menos proporcional a su valor en la función objetivo, o podrá ser limitado para no producir una convergencia prematura al ejercer una excesiva presión en la descendencia de futuras generaciones.

Es importante destacar también, que los valores de las tensiones en la función objetivo, D , son valores cercanos a la unidad y por tanto, no negativos. Esto hace la asignación de *fitness* a los individuos sea algo más simple desde un punto de vista algorítmico.

En el trabajo desarrollado se han empleado dos técnicas diferentes para la asignación de *fitness*: escalado lineal y asignación de ranking (lineal y no lineal). Ambas se encuentran detalladas en 2.3.3.

4.1.3 Generación de la población inicial

La inicialización de la población es el proceso por el cual se obtienen los individuos que forman parte de la primera generación de poblaciones. Para garantizar el éxito del algoritmo genético, el tamaño de la población debe ser suficientemente grande para que pueda contener individuos suficientemente distintos, que aseguren la diversidad de la

población inicial. Para fomentar la diversidad de esta primera población, el algoritmo parte de un conjunto de soluciones iniciales generadas aleatoriamente.

Aunque pueda resultar poco lógico, las pruebas realizadas con poblaciones de individuos generados cerca de la toma central, no proporcionaron buenos resultados. La convergencia de los mismos se comprobó más lenta que las poblaciones generadas de forma aleatoria.

La explicación más razonable está en la aplicación del Teorema de los Esquemas: unos buenos bloques constructores iniciales, donde existe diversidad, exploran mejor el espacio de búsqueda que otros muy cercanos, aparentemente, a la solución óptima, aunque muy similares entre sí.

De esta forma, la población inicial se generó utilizando subrutinas que proporcionaron matrices de individuos como la de la figura 4.4.

Chrom =

5	-5	4	0	3	1	-1	2	1	-4	-1	-4	-2	-3
-3	-2	-5	4	5	-1	-2	-3	-5	-1	-2	4	-5	4
1	3	2	4	0	0	4	4	-5	2	-2	-1	2	1
0	-5	-1	2	4	-2	-5	1	-3	4	-1	4	2	1
4	-4	4	3	-4	-1	3	-4	1	-2	-1	3	5	-3
3	-3	0	2	5	-3	5	-3	-5	-3	1	2	1	1
0	-3	2	-2	-3	1	5	1	-1	4	-4	-2	-1	5
-5	1	-1	-2	-3	3	3	1	1	-3	-5	-4	-3	-2
4	-3	-2	-2	4	0	-1	-1	2	3	0	-4	1	2
-1	-3	-3	0	3	2	0	1	2	4	4	-3	3	-1
1	-5	-3	2	-4	-3	-3	-1	-5	-3	5	-1	-1	1
3	3	2	-2	-5	-1	2	-5	-1	-3	-3	4	-5	2
5	-1	-2	4	4	3	-2	-5	-1	-5	-4	0	-1	-1
3	5	0	1	-3	2	5	-2	-2	-5	4	3	3	-1
-4	0	-4	-1	-2	0	2	-5	-4	2	-3	0	3	2
-1	-1	2	2	2	1	-1	-1	2	-3	2	0	5	4
5	4	-1	1	-2	3	3	2	2	4	5	-1	4	-1
5	0	4	-1	0	-5	-3	-4	3	-4	2	-1	-1	-1
-1	-3	4	2	-5	1	-1	-5	0	-4	4	4	1	1
4	2	1	1	5	-5	5	1	1	5	-5	-5	3	1

Figura 4.4 Ejemplo de población aleatoria. Matriz de 20 individuos por 14 transformadores

En la figura anterior, cada fila representa un individuo de la población. Cada individuo está compuesto por tantos elementos (columnas) como variables tenga el problema a tratar, en este caso, tomas del cambiador en el transformador correspondiente. En este ejemplo, tenemos 20 individuos y cada uno de ellos, tiene 14 variables enteras, que se corresponden con la posición de la toma. Además, la variación de la toma puede ir desde la posición -5 hasta la posición +5 en escalones de 1 unidad.

Esto se correspondería en la práctica con un cambiador que tuviese once posiciones (5 por arriba de la nominal y 5 por debajo) con escalones de un 1% y variación de tensión entre +5% y -5%.

Cabe destacar la sencillez que presenta el algoritmo a la hora de crear la población inicial, no siendo necesario realizar ningún proceso adicional de ajuste o reparación de factibilidad en los individuos.

4.1.4 Generación de descendientes

Las soluciones pertenecientes al resto de poblaciones se obtienen mediante la sucesiva aplicación de los operadores genéticos (selección, elitismo, cruce y mutación).

4.1.4.1 Selección

Para obtener la siguiente generación se seleccionan aleatoriamente individuos de la generación actual mediante algoritmos de muestreo, donde las probabilidades de selección de cada individuo son proporcionales a su medida de calidad, tal y como se describe en el apartado 2.3.4.1.

Como se ha puesto de manifiesto anteriormente, en esta Tesis se ha optado por la utilización de dos clases de algoritmos para la selección: *Selección mediante Ruleta* y *Muestreo Estocástico Universal*.

El primero de los dos, es un mecanismo de selección que se corresponde con un algoritmo de muestreo estocástico con reemplazo. Este método de selección tiene dos características fundamentales: (i) su implantación es simple, y (ii) tiene sesgo óptimo, es decir, el número esperado de descendientes asignados a cada individuo coincide con el obtenido a partir de su probabilidad de selección. Sin embargo, presenta el inconveniente de que una buena solución (que proporciona un perfil de tensiones muy plano) puede ser escogida en la misma generación para ser padre varias veces, dando lugar a una convergencia prematura. Para evitar esta desventaja, se ha optado por implementar una variante conocida como *Muestreo Estocástico con Reemplazamiento Parcial*. En esta técnica, cada individuo que ha sido seleccionado para aparearse es redimensionado a la baja, de forma que se disminuye su probabilidad de ser seleccionado en siguientes pasadas. Si, como consecuencia de esta redimensionado, el valor del individuo se hace negativo, entonces se asigna un valor nulo a su *fitness*.

El segundo mecanismo (*SUS* o *Stochastical Universal Sampling*) presenta dos buenas características: (i) tiene sesgo óptimo al igual que el método de la Ruleta y (ii) presenta el mínimo *spread* o menor número de veces que se puede seleccionar a un individuo para aparearse. Esta última característica, asegura una buena diversidad en la población, ya que impide que soluciones buenas puedan copar en exceso la siguiente generación y provocar convergencias prematuras hacia óptimos locales y, por tanto, estancamientos que impidan lograr el óptimo global.

Una última ventaja, que hace del *SUS* un algoritmo muy utilizado, es la sencillez a la hora de su implementación así como su complejidad, que es $O(n)$.

4.1.4.2 Técnicas Elitistas

La naturaleza probabilística del proceso de selección permite que el peor miembro de la población pueda reproducirse y crear individuos con unos bloques constructores no deseables. Igualmente, existe la posibilidad de que el mejor individuo pueda no estar presente en la siguiente generación debido a que no haya sido seleccionado como individuo padre o debido al efecto de los operadores de cruce y mutación.

Como se ha demostrado en la sección 2.3, es necesario incluir en la siguiente generación, algunas de las mejores soluciones encontradas para asegurar que el algoritmo genético converge asintóticamente a la solución óptima del problema.

Siguiendo con las experiencias de otros investigadores, se ha implementado una rutina que introduce elitismo en la búsqueda genética. Concretamente se ha utilizado el denominado *gap generacional*, mediante el cual se especifica un porcentaje determinado de soluciones que pueden pasar directamente a la siguiente generación sin sufrir ningún tipo de modificación.

Variando este parámetro elitista se ha podido observar la evolución del algoritmo para valores elevados y para valores pequeños. Se ha determinado que valores pequeños para el *gap generacional*, esto es, no permitir que las soluciones mejores pasen directamente a la siguiente generación, provocaba un peor desempeño en dicho algoritmo. Por contra, valores elevados provocaban una convergencia prematura y, a veces, el estancamiento en soluciones cuasi-óptimas. En el capítulo de resultados se pueden apreciar las situaciones mencionadas.

4.1.4.3 Cruce

El operador cruce es el más importante a la hora de proporcionar diversidad en la población con el objetivo de encontrar mejores soluciones. Los individuos o soluciones que han sido seleccionados como padres dan lugar a los individuos nuevos para la siguiente generación mediante este operador. Estos individuos nuevos presentan características de ambos progenitores.

Las nuevas soluciones serán típicamente factibles por lo que posteriormente no se deberá emplear ningún tipo de procedimiento de restauración de factibilidad. Esta característica consigue ahorrar una cantidad importante de tiempo durante la computación del algoritmo.

El algoritmo desarrollado en este trabajo ha utilizado diversos operadores de cruce adaptados a las características de las soluciones. Se ha optado por emplear los que, según el criterio del doctorando, mejor funcionaban con la codificación entera del problema. Recuérdese que la estructura de un individuo es la de la figura 2.14. En total, se han implementado tres políticas de cruce.

Tras el cruce o recombinación, cada solución hija contiene una parte de los dos padres. Además, las dos soluciones hijas son complementarias, es decir, que la parte del primer padre que forma, a su vez, parte del primer hijo no forma parte del segundo hijo y lo mismo se aplica para la parte del segundo padre que forma parte del primer hijo.

Estas tres políticas de cruce se diferencian, básicamente, en la manera que tienen de gestionar el material genético para que el resultado final presente una mayor o menor aptitud. Estas políticas de cruce se detallan a continuación.

Cruce de un sólo punto

Las soluciones hijas se obtienen por bipartición aleatoria de las soluciones padres y posterior recombinación de los trozos resultantes de la bipartición. Dada una pareja de soluciones padres, se escoge un número aleatorio, k , entre 1 y $m-1$ (siendo m el número de transformadores o tomas involucradas). Este número indica la zona por donde se parte cada una de las soluciones padres. Por lo tanto, el primer descendiente contendrá una parte de material genético proveniente del primer padre y otra parte proveniente del segundo padre. En este caso, el material genético se corresponderá con el número de tomas de un conjunto de transformadores concreto. El segundo hijo estará formado por el material genético complementario al primer hijo, es decir, aquellos elementos de los

padres que no conformaron el primero hijo, serán ahora, parte del segundo hijo. En la figura 4.5 se puede apreciar esta política de cruce.




Figura 4.5 Cruce de un sólo punto para la codificación entera de tomas

Cruce de dos puntos

Las soluciones hijas se obtienen por una partición aleatoria, pero en este caso por dos puntos en vez de uno. Una vez establecidos los puntos de cruce, se intercambia el material genético entre los padres para dar lugar a las soluciones hijas. En la figura 2.15 se puede apreciar un cruce de dos puntos o bipunto genérico.

Dada una pareja de soluciones padres, se escogen dos números aleatorios, j y k diferentes, entre 1 y $m-1$ (siendo m el número de transformadores o tomas involucradas). Este par de números indican las zonas por donde se deben partir cada una de las soluciones padres para conformar el material genético de intercambio. En la figura 4.6 se muestra una representación de la política de cruce para dos puntos.

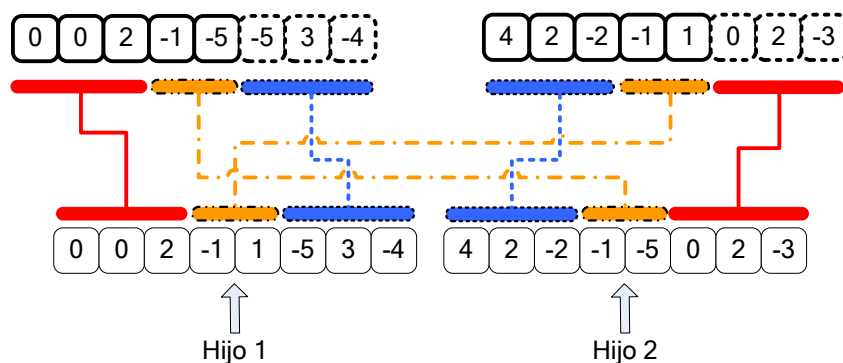


Figura 4.6 Cruce de dos puntos para codificación entera de tomas

Hay que volver a remarcar que, debido a la codificación empleada y a la propia filosofía del algoritmo, cualquier política de cruce que se empleen no genera soluciones infactibles y, por tanto, no es necesario emplear ningún tiempo extra o adicional en implementar métodos de reparación de factibilidad.

Al igual que con la política de cruce monopunto, este operador de cruce es un caso particular del operador cruce multipunto, donde el número de puntos escogidos es igual a dos.

Cruce multipunto barajado

Como una extensión del trabajo realizado, se ha implementado un operado de cruce basado en lo expuesto en [Eshelman 89]. Este operador se fundamenta en el de cruce de un sólo punto, pero al cual se le añade una modificación para conseguir disminuir el sesgo posicional. El cambio consiste en hacer una permuta de posiciones en los genes, de manera que son barajados aleatoriamente antes de ser intercambiados para formar a los hijos. Tras esta mezcla, se produce el cruce monopunto y una vez realizado, los genes de los hijos vuelven a sus posiciones originales sin barajar.

4.1.4.4 Mutación

Para aumentar la diversidad en la población se utiliza un procedimiento de mutación. Según una probabilidad de mutación previamente determinada, se van seleccionando todos los individuos de cada generación y se mutan en función de dicha probabilidad. Dentro de esta solución se cambia el estado de la toma de un transformador, pasando de una posición a otra diferente.




Figura 4.7 Mutación de la toma de un transformador

La implementación del operador mutación se ha realizado teniendo en cuenta que es posible que mute más de un gen dentro del mismo individuo, por lo que habrá algunos cromosomas que cambien de forma acusada su fenotipo, dando lugar a individuos nuevos

que eviten la problemática de quedar estancados en óptimos locales y sobre todo, eviten que la probabilidad de explorar cualquier cadena sea diferente de cero. Esta característica asegura que se puedan recuperar, también, cadenas y material genético que fue desechado o perdido a causa del proceso de selección y cruce.

4.1.4.5 Reinserción

Una vez que se ha obtenido la nueva población mediante selección, cruce y mutación de la población anterior se procede a determinar la aptitud o *fitness* de la misma. Todos los nuevos individuos son evaluados según la expresión (4.2) y están listos para ser reinsertados.

Para mantener el tamaño de la población, los nuevos individuos deben ser reinsertados en la población actual. De este modo, si no todos los individuos nuevos van a ser utilizados o si se genera más descendencia del tamaño de la población, hay que adoptar una política de reinserción adecuada para determinar cuales de los individuos existentes en la población actual deberán seguir existiendo y cuales no. Un detalle importante a tener en cuenta es que, al objeto de reducir la carga computacional, no es adecuado generar muchos más individuos de los ya existentes en la población. Por este motivo, el algoritmo de selección implementado puede generar tantos individuos como se desee hasta un tope igual a la población existente.

Además de todo lo anterior, el proceso de reinserción debe tener en cuenta cuál es la estrategia más apropiada para reemplazar a los individuos de la actual generación con los descendientes obtenidos. En este sentido, la estrategia más lógica, aparentemente, es la de sustituir los individuos menos aptos por aquellos generados en el proceso de selección. Ésta ha sido la lógica de trabajo, aunque en la literatura se han encontrado casos donde es más ventajoso sustituir, no ya a los menos aptos, sino a los que más tiempo llevan en la población.

En el algoritmo implementado, también se ha incluido la posibilidad de introducir elitismo. De esta forma, es posible indicar qué porcentaje de individuos de la población actual se quiere que se sigan manteniendo en la próxima generación, independientemente de los resultados obtenidos en el proceso de generación de nuevos individuos.

Para nuestro caso en particular, y tal como se verán posteriormente en el apartado de resultados, se ha empleado una gran casuística en los parámetros concernientes tanto al elitismo como a la forma de reinsertar a los descendientes en la población vigente.

4.2 Casos de estudio

En este apartado se presentan los resultados obtenidos por los distintos algoritmos propuestos en este capítulo.

En primer lugar, se analizan los resultados obtenidos al aplicar el método propuesto a un conjunto de sistemas diferentes y para una situación concreta en el tiempo de cargas y demanda. Este tipo de algoritmo se denominará “*Algoritmo genético monoetapa*”.

Las situaciones analizadas son las siguientes:

- Red de prueba [IEEE30](#)
- Red de prueba [IEEE57](#)
- Red de prueba [RTS](#)

El primer sistema representa una parte del Sistema Americano de Energía Eléctrica situado en el medio oeste de Estados Unidos, en su configuración de 1961¹. El segundo de ellos representa a otra parte del Sistema Americano de Energía Eléctrica situado en el medio oeste de Estados Unidos, en su configuración de 1960². Ambos sistemas han sido adoptados como estándar de trabajo e investigación y con fines docentes por la asociación internacional “IEEE” (Institute of Electrical and Electronics Engineers). Estas redes de test son ampliamente utilizadas por la comunidad científica internacional al objeto de validar, en situaciones “pseudo-reales”, los algoritmos desarrollados por los mismos.

La última red es un sistema desarrollado por el IEEE al objeto de ofrecer a la comunidad científica un modelo mejorado para su uso general en estudios sobre evaluación de la fiabilidad de sistemas eléctricos de potencia. El sistema original fue desarrollado en 1979 y ha sufrido varias modificaciones hasta su última versión (utilizada en este trabajo), referida como RTS-96³.

¹ http://www.ee.washington.edu/research/pstca/pf30/pg_tca30bus.htm

² http://www.ee.washington.edu/research/pstca/pf57/pg_tca57bus.htm

³ <http://www.ual.es/~pagilm/documentos/RTS.pdf>

En segundo lugar, se analizan los resultados obtenidos al aplicar el método propuesto a dos redes distintas, pero en este caso teniendo en cuenta un horizonte temporal de funcionamiento de la red. Típicamente, este período de planificación suele ser de 24 horas, por lo que se han escogido curvas de carga y demanda para este intervalo, de manera que el algoritmo se ejecute según un patrón definido de resolución temporal. Habitualmente, el horizonte de planificación suele ser horario, es decir, se dan consignas a los equipos de control y regulación cada hora en base a la salida del algoritmo encargado de gestionar el dispositivo correspondiente.

Dado que el horizonte temporal es de una hora, esto nos permite tener cierto margen en la resolución del problema de regulación, aunque hay que señalar que lo normal es que no se sobrepasen los pocos minutos de computación. Obviamente, el computador empleado deberá ser dimensionado en función de la red eléctrica a resolver y del número de variables a manejar. Aun así, y gracias a la introducción de capacidad “*multi-core*” en los procesadores actuales, se pueden conseguir resultados bastante razonables empleando ordenadores de sobremesa que dispongan de varios núcleos (p. ej. DualCore o QuadCore de Intel) y varios gigabytes de RAM (entre 2 y 4 puede ser suficiente).

Lo anterior implica que no es imprescindible el empleo de máquinas de alto rendimiento o clusters de procesadores y que usen sistemas operativos más profesionales tipo UNIX o SOLARIS, para conseguir resultados fiables en cortos espacios de tiempo.

Como herramienta de trabajo se ha elegido el entorno MATLAB, el cual ofrece unas sofisticadas y valiosas herramientas de resolución numérica y matricial. En este entorno se ha desarrollado el módulo optimizador, sirviéndose de módulos adicionales⁴ que realizan tareas unitarias diversas (flujo de cargas, procesos genéticos, etc)

4.2.1 Algoritmo genético monoetapa

Este algoritmo trabaja con redes de cualquier tamaño en base a unos datos de entrada (expuestos en el Apéndice A), y que, fundamentalmente, son la topología de la

red (nodos, líneas, etc), la demanda de potencia activa y reactiva en cada nudo y, por último, la potencia activa y reactiva inyectada por los generadores de la red (a excepción del nudo *slack* o nudo de referencia, que ajusta su potencia en función de las pérdidas de la red).

Estos datos son conocidos previamente y son la base de cálculo en la posterior resolución del flujo de cargas que se invoca durante la iteración del algoritmo. Hay que destacar que un dato fundamental de entrada es el número de transformadores con posibilidad de cambio de tomas existentes en la red, así como su ubicación y las características del propio cambiador de tomas. En nuestro caso, la ubicación y la posibilidad de cambio de tomas, viene dada de forma inherente en el fichero de entrada con los datos de la topología de la red, indicándose específicamente cuándo el elemento que une dos nudos cualesquiera es una línea o es otro elemento (en este caso un transformador). En este sentido, la estructura de entrada elegida para los datos, se corresponde con el formato PTI⁵, más una ligera modificación al objeto de excluir ciertos datos que en nuestro caso son irrelevantes, como por ejemplo, el nombre del nudo, el nombre de una máquina concreta, el nombre del circuito, etc. Una descripción de este formato se puede encontrar en el Apéndice A

La estructura completa del algoritmo puede verse en la figura 4.8. En la misma se puede apreciar el formato y las características típicas de los valores de entrada así como la fisonomía de las variables de control (posición de la toma en el cambiador de un transformador).

Es importante resaltar que para determinar el estado completo de cualquier red eléctrica de potencia, es necesario utilizar algún algoritmo típico de flujo de cargas. Este algoritmo se encarga de realizar una tarea intermedia en el proceso de optimización, cual es, obtener los valores de las tensiones nodales a partir de las condiciones de contorno y de la topología de la red. Sin él, el problema tendría una solución trivial (todos los nodos con tensión nominal) y por tanto, no sería realista.

⁴ <http://www.shef.ac.uk/acse/research/ecrg/gat.html> y <http://www.pserc.cornell.edu/matpower/>

⁵ <http://www.ee.washington.edu/research/pstca/formats/pti.txt>

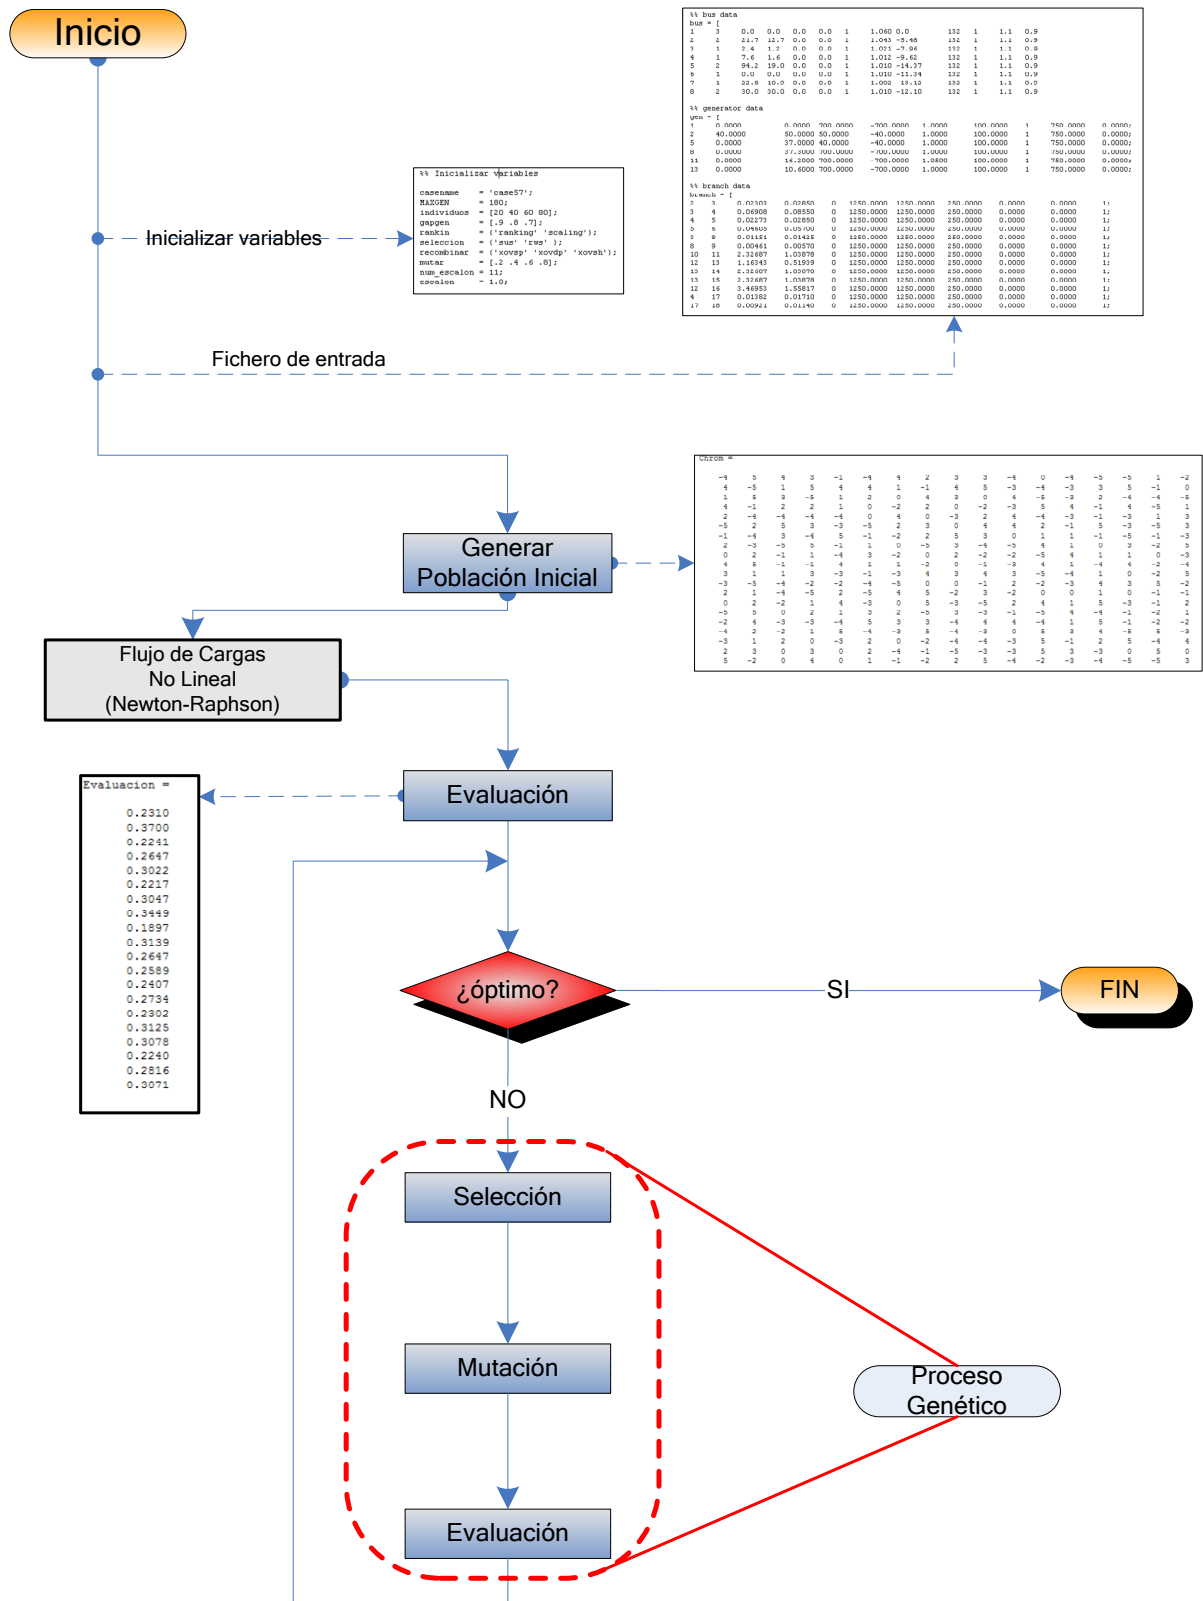


Figura 4.8 Esquema detallado de algoritmo genético monoetapa

4.2.1.1 Red IEEE30

El sistema IEEE 30 se compone de los siguientes elementos:

- 8 unidades de generación, de las cuales 2 son centrales eléctricas y las 6 restantes son generadores síncronos. Las potencias activas y reactivas máximas y mínimas de los generadores han sido elegidas arbitrariamente, aunque se han mantenido en un rango que no provoque inestabilidades en el sistema (de cara a su resolución numérica mediante métodos no lineales). El conjunto puede apreciarse en la figura 4.9.
- Red de transporte y distribución compuesta por 34 líneas que interconectan a 30 nudos. Existen 4 transformadores de potencia con tomas de regulación, de los cuales 2 de ellos son transformadores de tres arrollamientos. Hay dos niveles de tensión: 132 y 33 kV.

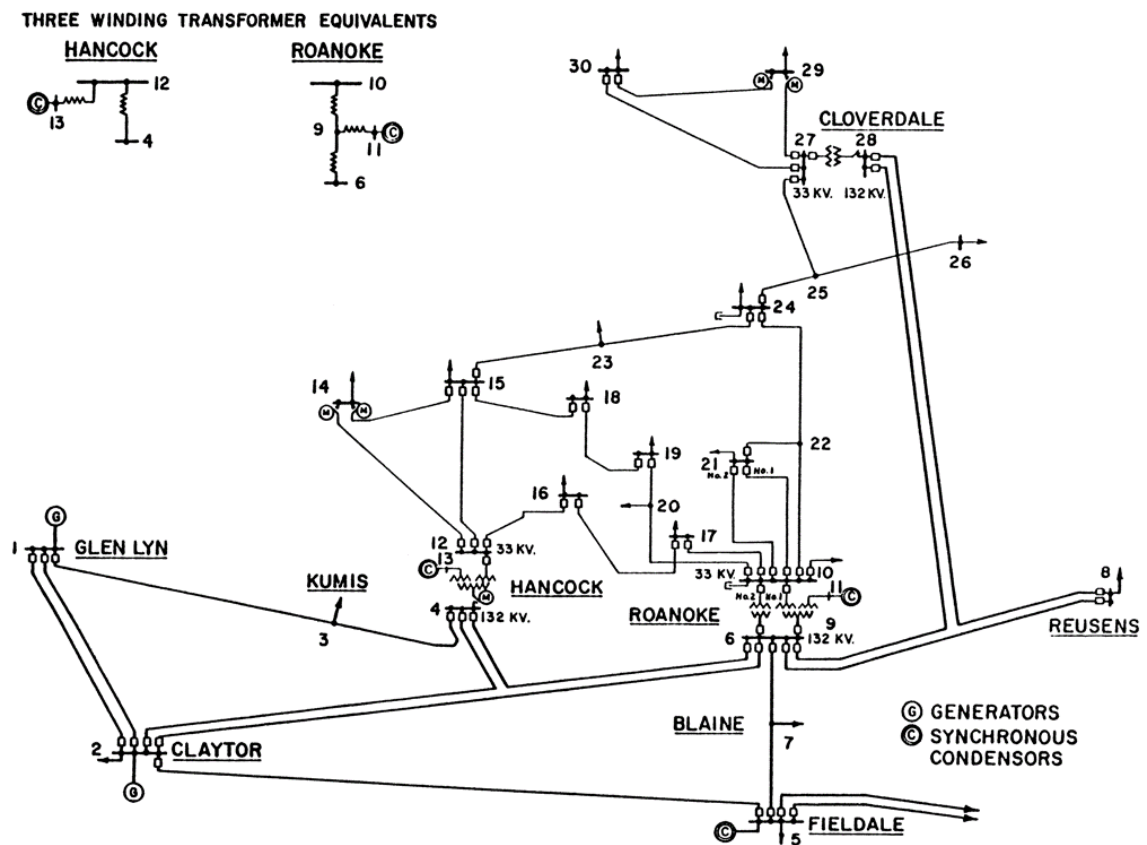


Figura 4.9 Red de potencia IEEE 30

- Como elementos de control de tensión, se tendrán en cuenta los cambiadores de tomas de los transformadores, aunque los condensadores síncronos (o cualquier otro elemento que pueda aportar energía reactiva) pueden efectuar también esa tarea de manera habitual.

Otras características relevantes del sistema son las siguientes:

- El nudo oscilante o *slack* es el número uno, que además coincide con la central generadora de mayor potencia.
- Se ha elegido un momento del día aleatorio para realizar la simulación del ajuste de tensiones.
- La demanda de potencia en cada nudo es conocida de antemano, bien porque se dispone de un histórico de registros, bien porque se dispone de teledemanda en el sistema. Este aspecto es importante porque permite obtener unos resultados fiables y realistas al conocer de manera precisa el estado de las cargas en tiempo real.

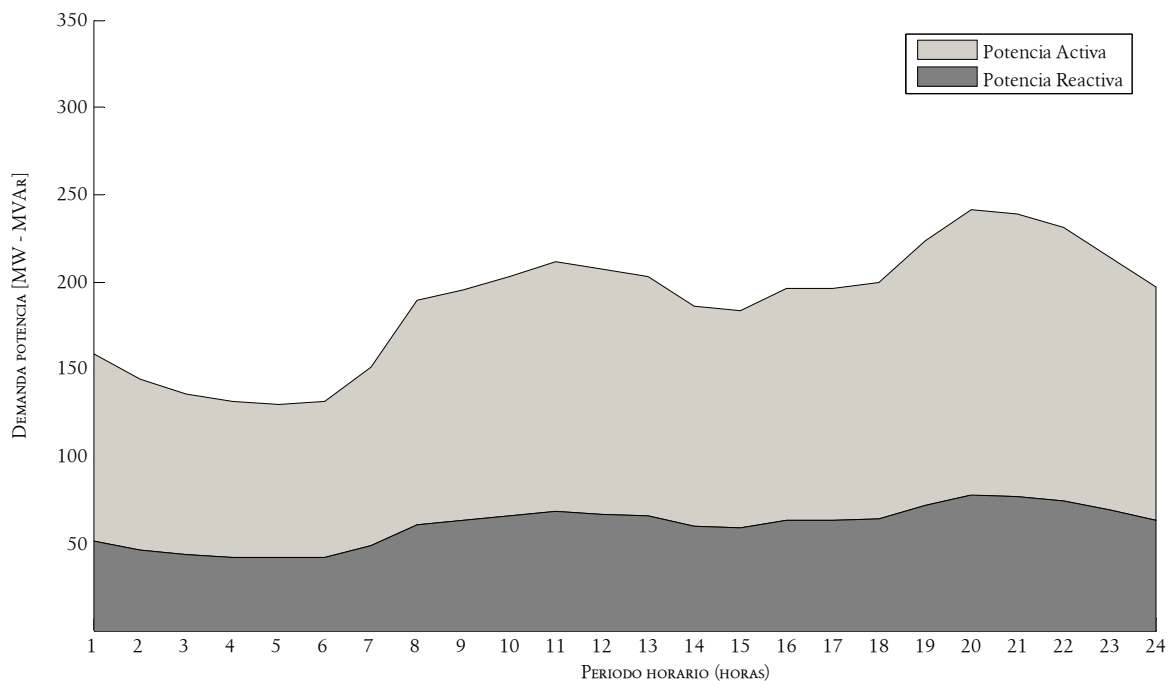


Figura 4.10 Curva de demanda horaria total en el sistema IEEE30

En la tabla 4.2 se presentan los parámetros empleados para la primera ejecución del algoritmo genético desarrollado. Posteriormente, para la determinación óptima de estos

parámetros, se ha realizado un proceso de exploración combinatorio que ha permitido hallar qué rango o valor permite una solución en menor tiempo computacional. Estos parámetros son los que han permitido la obtención de mejores soluciones para los casos de estudio.

Parámetro	Valor
Tamaño de Población	50
Número de Generaciones	15
Tipo de Cruce	Monopunto
Tasa de Mutación	0.2
Tasa de Elitismo	10%

Tabla 4.2 Parámetros del algoritmo genético monoetapa inicial

Caso 1

Según los datos de la Tabla 4.2, el problema converge hacia una solución factible, donde los datos más relevantes son:

Índice de Desviación de Tensión

Según lo expresado en (4.2) se obtiene un valor para el índice de desviación de tensión de

$$IDT = 0,010618$$

Recordemos que este índice tiene a cero como límite inferior y será tanto mejor cuanto menor sea.

Posición de las tomas de los transformadores

Los 4 transformadores existentes interconectan el sistema de 132 kV con el de 33 kV. Según la posición de los cambiadores de tomas, se podrá controlar la tensión de los nudos del sistema a conveniencia, aunque sólo dentro un rango determinado. Para este caso se ha escogido un escalón y un número de tomas arbitrario. En la tabla 4.3 se puede apreciar la distribución de los cambiadores para la situación de cargas de la tabla 4.4.

Trafo	Nudos	Toma	Rango	Incr. escalón
HANCOCK	4-12	-5%	-5% a +5%	2.5%
ROANOKE I	6-10	-5%	-5% a +5%	2.5%
ROANOKE II	6-9	-5%	-5% a +5%	2.5%
CLOVERDALE	27-28	-5%	-5% a +5%	2.5%

Tabla 4.3 Posición de las tomas de los cambiadores para el caso 1 IEEE30

Nudo	Tipo Nudo ⁶	Potencia Activa (MW)	Potencia Reactiva (MVar)
1	3	0,00	0,00
2	2	21,70	12,70
3	1	2,40	1,20
4	1	7,60	1,60
5	2	4,20	1,00
6	1	0,00	0,00
7	1	22,80	10,90
8	2	0,00	0,00
9	1	0,00	0,00
10	1	5,80	2,00
11	2	0,00	0,00
12	1	11,20	7,50
13	2	0,00	0,00
14	1	6,20	1,60
15	1	8,20	2,50
16	1	3,50	1,80
17	1	9,00	5,80
18	1	3,20	0,90
19	1	9,50	3,40
20	1	2,20	0,70
21	1	17,50	11,20
22	1	0,00	0,00
23	1	3,20	1,60
24	1	8,70	6,70
25	1	0,00	0,00
26	1	3,50	2,30
27	1	0,00	0,00
28	1	0,00	0,00
29	1	2,40	0,90
30	1	10,60	1,90

Tabla 4.4 Situación de cargas en el caso 1 para la red IEEE30

⁶ 3: nudo slack

2: nudo PV

1: nudo PQ

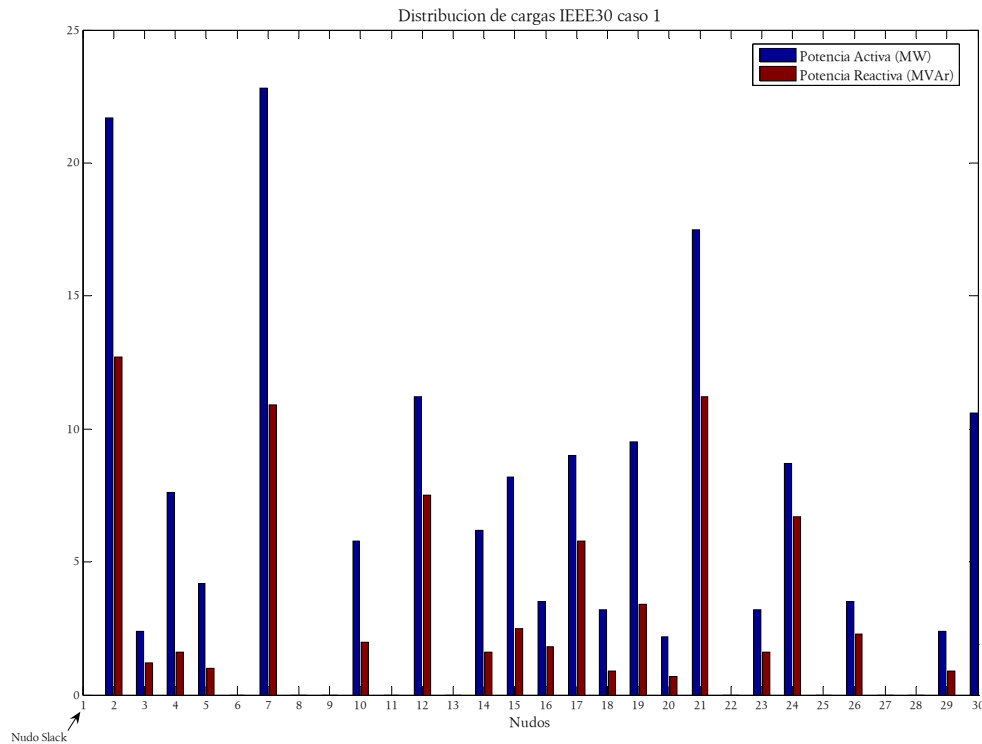


Figura 4.11 Nivel de carga en el caso 1 de la Red IEEE30

Se puede apreciar cómo la situación de cargas existente es tal que fuerza a las tomas de los transformadores existentes a elevar la tensión en los lugares más alejados. Estas tomas se encuentran en su posición más baja y no pueden, por tanto, conseguir disminuir el IDT en una cuantía mayor.

Nivel de tensión en los nodos

En la figura 4.12 se puede observar la situación final de la tensión nodal (módulos). Se comprueba como la mayoría de ellos están cercanos a la tensión nominal, existiendo un pequeño margen de variación.

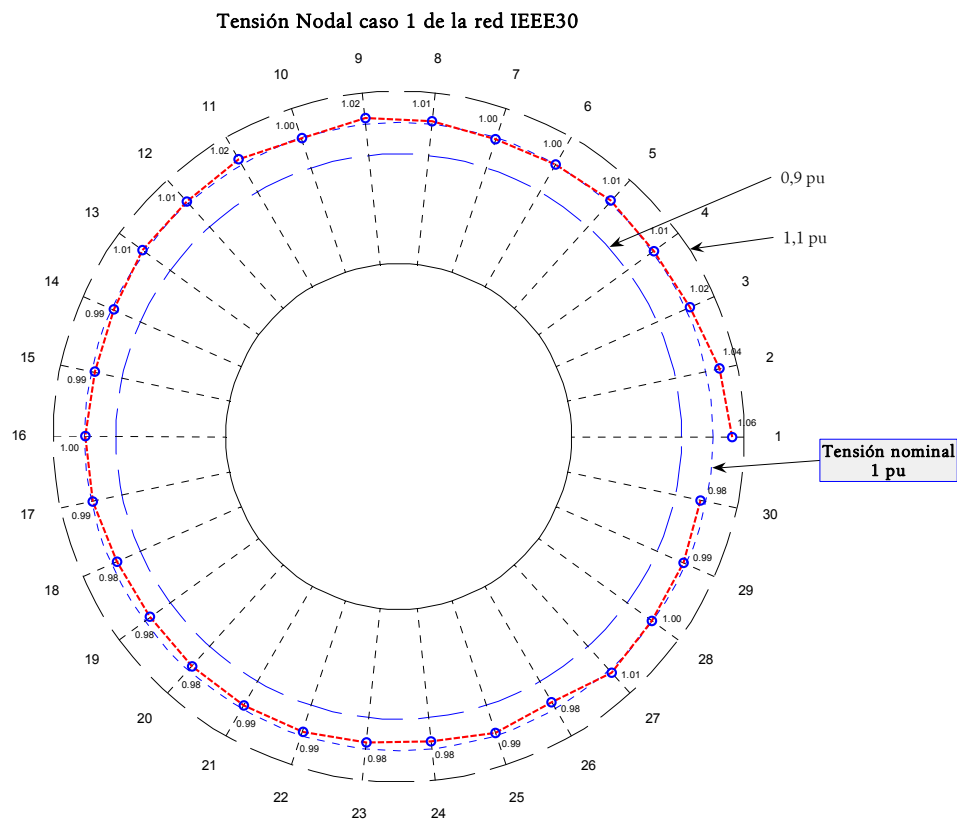


Figura 4.12 Distribución de tensiones nodales para el caso 1 de la red IEEE30

Tiempo de Ejecución

Para el caso 1, con una red de 30 nudos y 4 transformadores, se obtiene un tiempo de ejecución de 16,3 s usando la máquina descrita en la tabla 4.5.

Procesador	Intel Pentium 4
CPU	3 GHz
Memoria RAM	1 GB
Sistema Operativo	Windows XP SP2
Entorno Matlab	Matlab 7.0 R14

Tabla 4.5 Características de la máquina empleada




Figura 4.13 Evolución de la población para el caso 1 de la IEEE30

Este caso de pequeño tamaño nos da una idea acerca de cómo se comporta el algoritmo. En la figura 4.13 vemos que se produce una mejora de la solución conforme se avanza en el número de generaciones. Para el caso que nos ocupa, y debido al pequeño número de variables, se produce una rápida convergencia hacia el óptimo del problema y eso permite reducir el número máximo de generaciones. Lo normal sería permitir ejecuciones con 100-200 generaciones para dar tiempo a una convergencia segura hacia el óptimo global.

Caso 2

En este caso se intenta optimizar el proceso genético al objeto de verificar cuál es el mejor conjunto de parámetros a utilizar en este problema concreto. Este tipo de heurística es necesaria para poder obtener la mejor parametrización posible del problema y, de esta forma, llegar a la mejor solución en el menor tiempo posible.

En la tabla 4.6 se muestra el conjunto de parámetros de trabajo elegido como base para el desarrollo de esta nueva estrategia.

Parametrización Algoritmo Genético				
Núm. Individuos	20	40	60	80
Elitismo	0.9	0.8	0.7	
Método de Ranking ⁷			ranking	scaling
Método Selección ⁸			sus	rws
Método de Recombinación ⁹			xovsp	xovdp
% Mutación	0.2	0.4	0.6	0.8

Tabla 4.6 Conjunto parametrizador para Algoritmo genético monoetapa

El proceso general consiste en ejecutar lo descrito en el Caso 1 para cada combinación posible, obteniendo como resultado el mejor conjunto de parámetros genéticos. Esto implica que se necesita realizar una cantidad importante de pasadas por el algoritmo inicial, aunque sólo se realizará una única vez. A partir de ese momento, el problema quedará caracterizado completamente (en cuanto a parámetros genéticos se refiere) y se darán por buenos y válidos para posteriores redes de mayor envergadura. No obstante, siempre será posible poner en marcha el proceso para asegurar que se dispone de la parametrización correcta en cada red diferente.

En la figura 4.14 y la figura 4.15 se muestran algunos instantes del proceso de ejecución del algoritmo descrito. Se puede apreciar como se van realizando sucesivas “pasadas” o ejecuciones usando diferentes parámetros para el cruce, la mutación o el número de individuos. Además, y para acelerar el proceso en general, se ha implementado un mecanismo de convergencia adicional consistente en verificar que, si tras 15 generaciones no se ha producido una mejora en la solución del problema, entonces se pasa a ejecutar el algoritmo con el siguiente conjunto de elementos genéticos. Mediante este

⁷ Ver sección 2.3.3 Función objetivo y aptitud

⁸ Ver sección 2.3.4 Selección

⁹ Ver sección 2.3.5 Cruce o Recombinación

añadido se consigue reducir en gran medida el tiempo de ejecución, ya que no es necesario agotar el número máximo de generaciones (típicamente 200 generaciones).




Figura 4.14 Vista 1 de la ejecución del algoritmo genético con diferentes parametrizaciones




Figura 4.15 Vista 2 de la ejecución del algoritmo genético con diferentes parametrizaciones

Tras la realización de todo el proceso, se obtienen unos resultados que indican que se ha logrado el óptimo en un número importante de casos, aunque hay muchas combinaciones que no lo consiguen. La tabla 4.7 muestra un resumen de esta situación.

Soluciones Óptimas	Mutación	0,2	0,4	0,6	0,8	Total Ejecuciones	
	Ejecuciones	93	74	47	10		224
	Elitismo	0,9		0,8	0,7		224
	Ejecuciones	73		77	74		
	Población	20	40	60	80		224
	Ejecuciones	48	52	57	67		
	Cruce	xovsp		xovdp			224
	Ejecuciones	111		113			
	Recombinación	rws		sus			224
	Ejecuciones	115		109			
Fitness	ranking		scalling		224		
Ejecuciones	137		87				
Soluciones No Óptimas					160		

Tabla 4.7 Distribución de soluciones óptimas para el caso IEEE30 en función de un conjunto de parámetros genéticos.

Se pueden extraer una serie de conclusiones interesantes del análisis de la misma:

- Más de la mitad de configuraciones posibles, en cuanto a los parámetros genéticos, pudieron lograr alcanzar el objetivo mínimo del IDT.
- De las que lo consiguieron, parece indiferente si se realiza cruce de un sólo punto o de doble punto, así como un proceso de selección estocástico o no.
- La asignación de *fitness* debería realizarse preferentemente mediante *ranking*.
- A mayor cantidad de individuos en la población, más cantidad de soluciones factibles y óptimas encontradas. Esto parece lógico ya que disponemos de un espacio de búsqueda mayor y, por tanto, más posibilidades de hallar el óptimo.
- La alteración en el porcentaje de elitismo parece no afectar en exceso a la mejora del algoritmo.
- Existe una degradación clara en las soluciones óptimas cuánto mayor es el porcentaje de mutación. Este efecto se ha descrito en la literatura bastantes veces, y tiene que ver con un continuo descontrol a la hora de explorar soluciones prometedoras. Puesto que se realiza un constante cambio en los individuos, no se permite explorar suficientemente zonas que presentan un nivel elevado de fitness.
- Para la red IEEE30, interesa ejecutar el algoritmo de optimización de tensiones (bajo cualquier situación arbitraria de cargas) con los siguiente parámetros

% Mutación	0,2
Elitismo	0,9
Tamaño de población	80
Método de Fitness	ranking
Método de Cruce	xovdp
Método de Selección	rws

En la figura 4.16 se presenta la evolución que ha tenido cada uno de los transformadores de la red IEEE30, para cada ejecución con un conjunto concreto de parámetros genéticos. Se observa como existe una cantidad importante de ejecuciones que consiguen obtener el óptimo del problema (todas las tomas a 0.95). También se puede

apreciar como algunos transformadores consiguen alcanzar el nivel óptimo durante más ejecuciones que otros (Trafo 4).

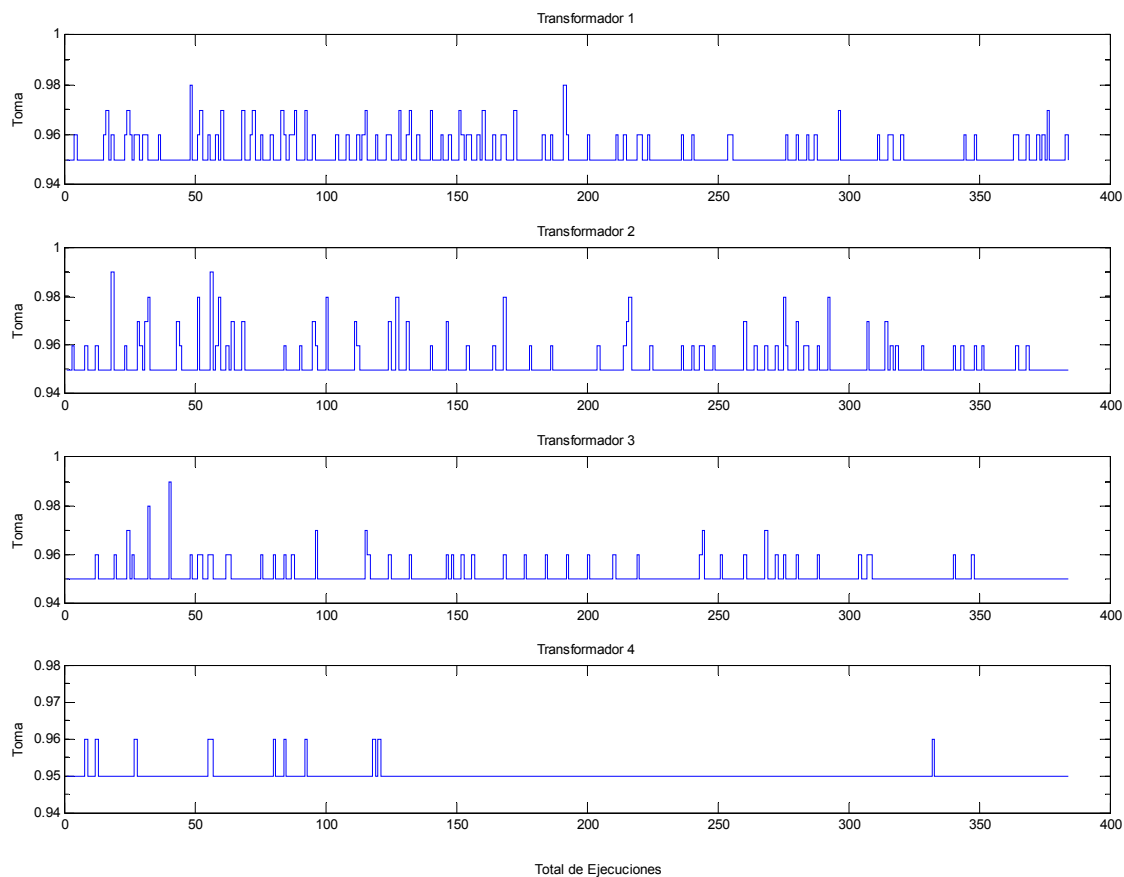


Figura 4.16 Evolución de las tomas de los transformadores de la red IEEE30 para un conjunto de parámetros genéticos

En la figura 4.17 se muestran una serie de gráficos indicativos de la cantidad de individuos óptimos para cada subconjunto de parámetros genéticos. Se puede apreciar como existen unos valores que consiguen encontrar un mayor número de candidatos que otros. Por ejemplo, conforme se usa un tamaño mayor de población, existe un mayor número de ejecuciones que proporcionan el óptimo. Igual sucede con una tasa de mutación pequeña, en este caso 0,2. Otro valor que consigue soluciones óptimas con mayor frecuencia es el ranking (asignación de fitness). El resto de parámetros presentan una mayor igualdad, siendo difícil decantarse por uno de ellos claramente.

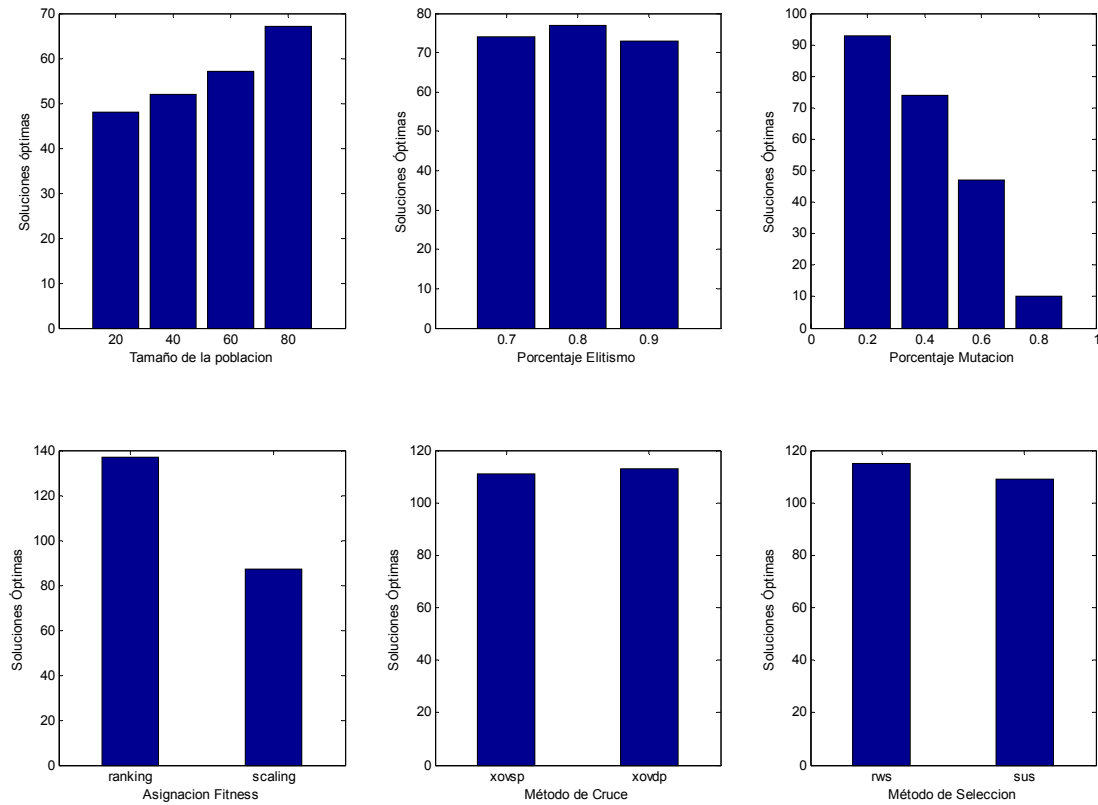


Figura 4.17 Individuos óptimos para cada subconjunto de parámetros genéticos

Para la mejor combinación de parámetros, se obtienen los resultados que a continuación se relacionan. Puesto que son bastante similares a los del primer caso, se presentan de manera resumida

Índice de Desviación de Tensión

Según lo expresado en (4.2) se obtiene

$$IDT = 0,010618$$

Posición de las tomas de los transformadores

En este caso, se ha usado un escalón más pequeño y por tanto, un mayor número de tomas. A pesar de ello y debido al estado de la red, los resultados son similares al caso 1.

Trafo	Nudos	Toma	Rango	Incr. escalón
HANCOCK	4-12	-5%	-5% a +5%	1%
ROANOKE I	6-10	-5%	-5% a +5%	1%
ROANOKE II	6-9	-5%	-5% a +5%	1%
CLOVERDALE	27-28	-5%	-5% a +5%	1%

Tabla 4.8 Estado de las tomas para el Caso 2 y red IEEE30

Nivel de tensión en los nodos

En la figura 4.18 se puede observar la situación final de la tensión nodal (módulos) para el mejor de los individuos. Se comprueba como la mayoría de ellos están cercanos a la tensión nominal, existiendo un pequeño rango de variación. A nivel comparativo, se muestra la figura 4.19 con la peor de las soluciones obtenidas para las tensiones.

En ambas figuras se puede observar que para la red de prueba IEEE30 no existe una gran variación en las tensiones nodales, estando cercanas todas ellas a la unidad. Realmente, el tamaño de la red (pequeño) así como el número de transformadores (también pequeño) no permite mucho margen para la distorsión.




Figura 4.18 Nivel de tensión para la red IEEE30 y caso 2, en su nivel óptimo.




Figura 4.19 Nivel de tensión para la red IEEE30, caso 2 y peor individuo.

Tiempo de Ejecución

Para el caso 2, se obtiene una serie temporal para cada una de las ejecuciones, la cual está reflejada en la tabla 4.9, habiendo hecho uso de la máquina descrita en la tabla 4.5.

Ejecución	t (s)	IDT	Ejecución	t (s)	IDT	Ejecución	t (s)	IDT
1	7,985	0,010618	129	14,75	0,010618	257	20,625	0,010618
2	9,734	0,010618	130	13,562	0,010618	258	16,281	0,010618
3	7,188	0,011077	131	7,219	0,012182	259	15,016	0,010618
4	6,937	0,011075	132	7,234	0,012306	260	13,531	0,012233
5	13,625	0,010618	133	8,75	0,010618	261	23,516	0,010618
6	18,063	0,010618	134	23,282	0,010618	262	16,375	0,010618
7	9,046	0,010618	135	7,609	0,011075	263	16,859	0,010618
8	4,922	0,012297	136	8,703	0,010618	264	14,516	0,011077
9	10,844	0,010618	137	21,235	0,010618	265	12,953	0,010618
10	14,578	0,010618	138	21,062	0,010618	266	28,969	0,010618
11	10,563	0,010618	139	28,344	0,010618	267	24,765	0,010618
12	5,343	0,012958	140	6,875	0,012232	268	13,516	0,01235
13	8,36	0,010618	141	14,922	0,010618	269	14,234	0,010618

Ejecución	t (s)	IDT	Ejecución	t (s)	IDT	Ejecución	t (s)	IDT
14	11,625	0,010618	142	18,422	0,010618	270	21,407	0,010618
15	11,875	0,011075	143	21,531	0,010618	271	17,343	0,010618
16	6,547	0,011631	144	6,469	0,011075	272	9,25	0,011674
17	6,89	0,010618	145	15,437	0,010618	273	8,75	0,010618
18	4,469	0,013462	146	6,844	0,012233	274	16,813	0,010618
19	5,156	0,011161	147	13,375	0,011075	275	12,078	0,012835
20	7,297	0,010618	148	10,469	0,011161	276	20,25	0,011606
21	15,203	0,010618	149	20,484	0,010618	277	21,766	0,010618
22	8,047	0,010618	150	13,687	0,010618	278	24,078	0,010618
23	11,578	0,011606	151	13,985	0,011631	279	36,922	0,010618
24	3,953	0,013059	152	18,453	0,011685	280	13,265	0,012899
25	4,469	0,011075	153	16,953	0,010618	281	24,141	0,010618
26	5,938	0,011161	154	6,453	0,011606	282	27,453	0,010618
27	9,172	0,012301	155	14,813	0,011075	283	17,016	0,011077
28	6,125	0,012182	156	14,781	0,011161	284	8,359	0,011606
29	6,562	0,011077	157	21,719	0,010618	285	30,25	0,010618
30	9,188	0,011075	158	10,968	0,011075	286	18,453	0,010618
31	8,5	0,012182	159	12,579	0,010618	287	23,469	0,011075
32	4,203	0,014469	160	6,656	0,011631	288	14,125	0,011674
33	12,047	0,010618	161	9,937	0,010618	289	20,578	0,010618
34	14,562	0,010618	162	10,625	0,010618	290	38,469	0,010618
35	8,141	0,010618	163	21,641	0,010618	291	36,515	0,010618
36	5,14	0,011075	164	6,141	0,011606	292	15,36	0,012133
37	5,594	0,010618	165	11,421	0,010618	293	20,531	0,010618
38	8,313	0,010618	166	9,891	0,010618	294	27,781	0,010618
39	12,203	0,010618	167	6,578	0,011075	295	26,532	0,010618
40	4,078	0,013251	168	5,922	0,013571	296	19,109	0,011631
41	8,844	0,010618	169	9,422	0,010618	297	28,031	0,010618
42	15,234	0,010618	170	9,156	0,010618	298	38,672	0,010618
43	10,453	0,011582	171	12,906	0,010618	299	64,469	0,010618
44	6,453	0,011077	172	11,657	0,011631	300	39,437	0,010618
45	7,656	0,010618	173	9,437	0,010618	301	24,875	0,010618
46	10,875	0,010618	174	14,516	0,010618	302	19	0,010618
47	7,235	0,010618	175	16,156	0,010618	303	47,844	0,010618
48	3,859	0,01302	176	8,922	0,011161	304	24,688	0,011161
49	13,75	0,010618	177	11,141	0,010618	305	45,734	0,010618
50	13,453	0,010618	178	15,75	0,011077	306	28,5	0,010618
51	4,985	0,013571	179	19,75	0,010618	307	30,219	0,012233
52	4,109	0,012306	180	12,687	0,010618	308	47,781	0,011161
53	8,609	0,010618	181	15,859	0,010618	309	46,812	0,010618
54	9,75	0,010618	182	18,375	0,010618	310	73,438	0,010618
55	4,985	0,012975	183	8,907	0,011075	311	39,062	0,011075
56	3,656	0,014973	184	10,265	0,011161	312	34,079	0,010618
57	11,438	0,010618	185	19,375	0,010618	313	50,359	0,010618
58	8,453	0,011606	186	8,219	0,011606	314	16,922	0,011582
59	6,968	0,012133	187	13,609	0,010618	315	28,375	0,011075
60	5,625	0,011631	188	14,329	0,010618	316	35,781	0,011606
61	10,063	0,010618	189	20,328	0,010618	317	36,172	0,010618
62	4,781	0,011674	190	9,953	0,010618	318	24,141	0,011077
63	6,328	0,011161	191	12	0,01228	319	28,75	0,010618
64	4,532	0,011582	192	20,469	0,011685	320	15,281	0,011075
65	7,562	0,010618	193	21,984	0,010618	321	17,844	0,010618

Ejecución	t (s)	IDT	Ejecución	t (s)	IDT	Ejecución	t (s)	IDT
66	9,109	0,010618	194	23,641	0,010618	322	43,531	0,010618
67	6,829	0,010618	195	22,015	0,010618	323	15,719	0,010618
68	3,718	0,012878	196	28,375	0,010618	324	12,468	0,010618
69	6,86	0,010618	197	17,875	0,010618	325	23,75	0,010618
70	8,515	0,010618	198	18,906	0,010618	326	43,078	0,010618
71	8,578	0,011075	199	14,891	0,010618	327	28,782	0,010618
72	4,469	0,011631	200	10,078	0,011685	328	42,031	0,011077
73	6,828	0,010618	201	16,469	0,010618	329	19,484	0,010618
74	7,5	0,010618	202	30	0,010618	330	37,047	0,010618
75	6,469	0,011685	203	22,641	0,010618	331	31,953	0,010618
76	5,469	0,010618	204	14,265	0,011077	332	13,485	0,011766
77	10,812	0,010618	205	16,219	0,010618	333	20,656	0,010618
78	11,5	0,010618	206	18,953	0,010618	334	33,297	0,010618
79	5,844	0,011075	207	14,281	0,010618	335	26,531	0,010618
80	5,813	0,012373	208	11,297	0,010618	336	30,969	0,010618
81	8,171	0,010618	209	27,875	0,010618	337	22,015	0,010618
82	11,032	0,010618	210	10,11	0,011161	338	47,704	0,010618
83	9,343	0,011631	211	33,281	0,011075	339	24,234	0,010618
84	3,547	0,013632	212	34,406	0,010618	340	17,047	0,011674
85	14,672	0,010618	213	23,094	0,010618	341	26,859	0,010618
86	9,094	0,011075	214	20,187	0,011606	342	30,344	0,010618
87	10,734	0,011685	215	20,266	0,011582	343	30,719	0,011077
88	9,641	0,011631	216	10,734	0,012133	344	28,734	0,011075
89	14,391	0,010618	217	48,657	0,010618	345	30,297	0,010618
90	9,828	0,011077	218	19,671	0,010618	346	33,594	0,010618
91	8,109	0,010618	219	31,016	0,011685	347	21,25	0,011161
92	7,313	0,012934	220	17,234	0,011075	348	17,156	0,011606
93	11,171	0,010618	221	28,547	0,010618	349	36,968	0,010618
94	9,625	0,010618	222	14,844	0,010618	350	28,719	0,010618
95	6,235	0,012182	223	21,484	0,011075	351	30,234	0,011077
96	8,344	0,01235	224	19,032	0,011077	352	18,407	0,010618
97	17,218	0,010618	225	17,968	0,010618	353	21,781	0,010618
98	25,219	0,010618	226	42,204	0,010618	354	34	0,010618
99	19,266	0,010618	227	21	0,010618	355	22,625	0,010618
100	8,656	0,012133	228	19,437	0,010618	356	30,203	0,010618
101	23,328	0,010618	229	21	0,010618	357	19,188	0,010618
102	13,797	0,010618	230	20,922	0,010618	358	25,359	0,010618
103	9,469	0,010618	231	14,469	0,010618	359	20,016	0,010618
104	11,937	0,011075	232	25,359	0,010618	360	21,781	0,010618
105	13,438	0,010618	233	14,078	0,010618	361	26,734	0,010618
106	18,781	0,010618	234	21,156	0,010618	362	27,016	0,010618
107	12,25	0,010618	235	16,219	0,010618	363	16,64	0,011075
108	9,093	0,011075	236	17,313	0,011606	364	10,516	0,011606
109	10,922	0,010618	237	16,297	0,010618	365	19,234	0,010618
110	12,203	0,010618	238	22,046	0,010618	366	21,641	0,010618
111	7,797	0,011582	239	30,672	0,010618	367	23,641	0,010618
112	7	0,011606	240	20,313	0,011606	368	18,547	0,011606
113	27,469	0,010618	241	24,109	0,010618	369	25,968	0,010618
114	15,719	0,011075	242	31,719	0,010618	370	20,61	0,010618
115	9,5	0,013059	243	16,812	0,011674	371	28,562	0,010618
116	11,484	0,011161	244	9,235	0,01235	372	16,188	0,011075
117	20,078	0,010618	245	29,656	0,010618	373	32,203	0,010618

Ejecución	t (s)	IDT	Ejecución	t (s)	IDT	Ejecución	t (s)	IDT
118	8,313	0,011766	246	32,234	0,010618	374	18,234	0,011075
119	9,937	0,011075	247	29,704	0,010618	375	22,453	0,010618
120	11,547	0,011766	248	12,984	0,011077	376	11,407	0,011631
121	17,656	0,010618	249	27,312	0,010618	377	30,25	0,010618
122	21,782	0,010618	250	22,094	0,010618	378	32,375	0,010618
123	8,671	0,011075	251	20,469	0,011161	379	10,765	0,010618
124	11,172	0,012899	252	11,406	0,010618	380	30,438	0,010618
125	23,11	0,010618	253	29,703	0,010618	381	20,422	0,010618
126	19,672	0,010618	254	15,703	0,011075	382	29,89	0,010618
127	13,765	0,012133	255	18,375	0,011075	383	16,516	0,011075
128	10,016	0,011631	256	22,594	0,010618	384	30,453	0,010618

Tabla 4.9 Valor de IDT y tiempo empleado en alcanzar el óptimo para el caso 2 de la red IEEE30

Se pueden extraer algunos datos más relevantes de la tabla anterior. Concretamente, en la figura 4.20 se representa los tiempos de ejecución para cada una de las soluciones óptimas encontradas. Se puede apreciar como la gran mayoría de las veces, el óptimo se encuentra en un intervalo de 10 a 30 segundos.




Figura 4.20 Tiempo empleado para las ejecuciones óptimas de la red IEEE30, caso 2.

4.2.1.2 Red IEEE57

El sistema IEEE 57 se compone de los siguientes elementos:

- 7 unidades de generación, de las cuales 4 son centrales eléctricas y las 3 restantes son generadores síncronos. Las potencias activas y reactivas, tanto máximas como mínimas, de los generadores han sido elegidas arbitrariamente, aunque se han mantenido en un rango que no provoque inestabilidades en el sistema (pensando en su resolución numérica mediante métodos no lineales). El conjunto puede apreciarse en la figura 4.21.
- Red de transporte y distribución compuesta por 63 líneas que interconectan a 57 nudos. Existen 17 transformadores de potencia con tomas de regulación, de los cuales 1 de ellos es de tres arrollamientos.
- Como elementos de control de tensión, se tendrán en cuenta los cambiadores de tomas de los transformadores, aunque los condensadores síncronos (o cualquier otro elemento que pueda aportar energía reactiva) pueden efectuar también esa tarea de manera habitual.

Otras características relevantes del sistema son las siguientes:

- El nudo oscilante o *slack* es el número uno (Kanawha, ver figura 4.21), que además coincide con la central generadora de mayor potencia.
- Se ha elegido un momento del día aleatorio para realizar la simulación del ajuste de tensiones.
- La demanda de potencia en cada nudo es conocida de antemano y tiene una forma similar a la de la tabla 4.4.

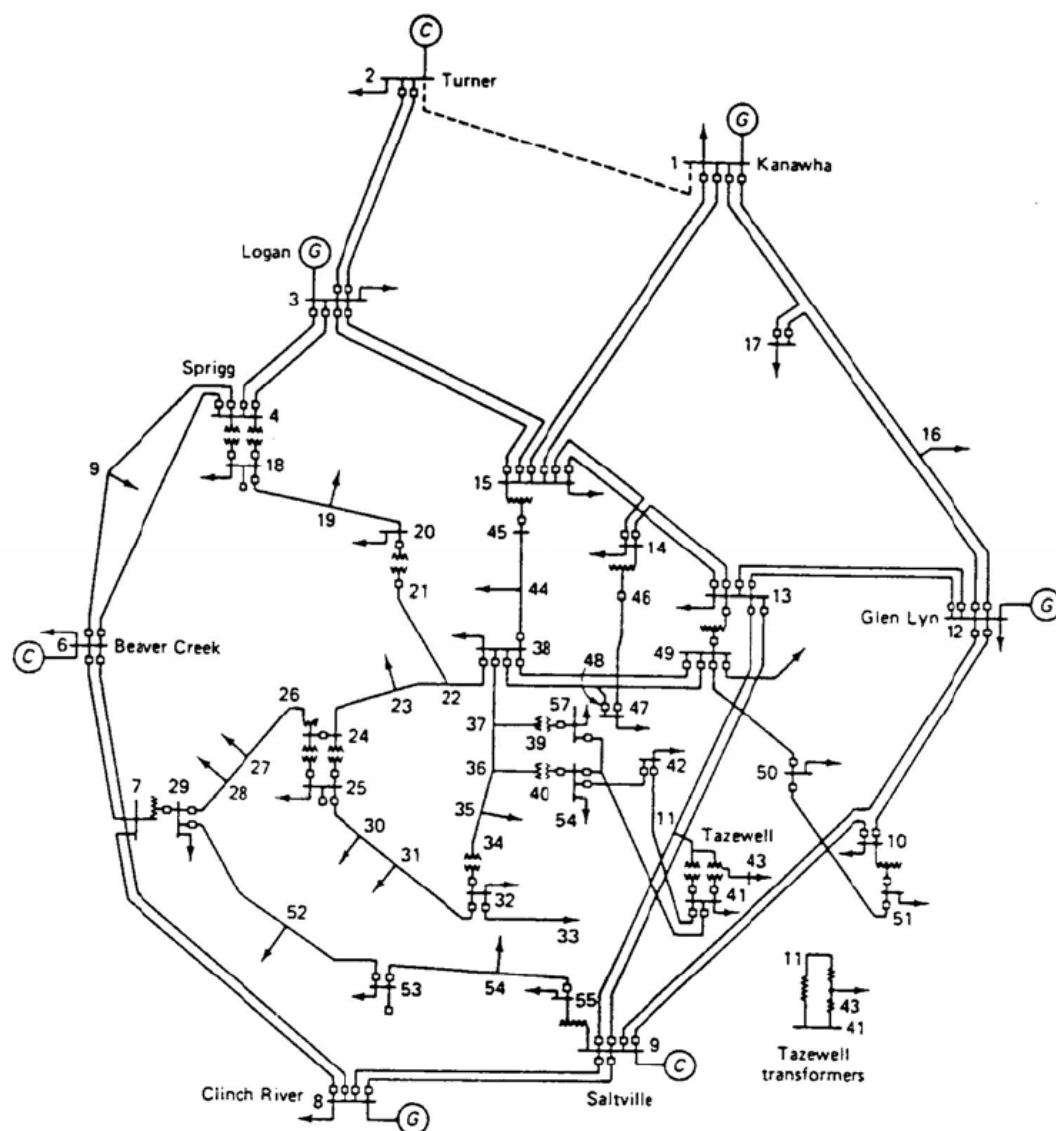


Figura 4.21 Red de potencia IEEE57

En la tabla 4.10 se muestran los parámetros empleados para la ejecución del algoritmo genético desarrollado. Estos parámetros son los que han permitido la obtención de mejores soluciones para los casos de estudio, en base al análisis realizado en el apartado anterior (ver 4.2.1.1 Caso 2).

Parámetro	Valor
Tamaño de Población	80
Número de Generaciones	180
Tipo de Cruce	Monopunto
Tasa de Mutación	0.2
Tasa de Elitismo	10%

Tabla 4.10 Parámetros genéticos para la resolución de la red IEEE57

Índice de Desviación de Tensión

Según lo expresado en (4.2), se obtiene un valor para el índice de desviación de tensión de

$$IDT = 0,0244$$

Recordemos que este índice tiene el cero como límite inferior y será tanto mejor cuanto menor sea.

Posición de las tomas de los transformadores

Los 17 transformadores existentes interconectan tres niveles de tensión diferentes. Según la posición de los cambiadores de tomas, se podrá controlar la tensión de los nudos del sistema a conveniencia, aunque sólo dentro un rango determinado.

Para este caso se ha escogido un escalón y un número de tomas arbitrario. En la tabla 4.11 se puede apreciar la distribución de los cambiadores para la situación de cargas de la tabla 4.12.

	Trafo	Nudos	Toma	Rango	Incr. escalón
1	SPRIGG	4-18	-1 %	-10 a +10%	1 %
2	--	7-29	-3 %	-10 a +10%	1 %
3	SALTVILLE	9-55	-2 %	-10 a +10%	1 %
4	--	10-55	-3 %	-10 a +10%	1 %
5	--	20-21	-4 %	-10 a +10%	1 %
6	--	24-26	+3 %	-10 a +10%	1 %
7	--	24-25	-6 %	-10 a +10%	1 %
8	--	24-25	-7 %	-10 a +10%	1 %
9	--	32-34	-10 %	-10 a +10%	1 %
10	TAZEWELL	41-11	-6 %	-10 a +10%	1 %
11	TAZEWELL	41-43	-9 %	-10 a +10%	1 %
12	TAZEWELL	43-11	-3 %	-10 a +10%	1 %
13	--	13-49	-8 %	-10 a +10%	1 %
14	--	14-46	-5 %	-10 a +10%	1 %
15	--	15-45	0 %	-10 a +10%	1 %
16	--	39-57	-5 %	-10 a +10%	1 %
17	--	40-54	-4 %	-10 a +10%	1 %

Tabla 4.11 Posición de las tomas de los cambiadores para la red IEEE57

Los valores que hacen referencia al rango y escalón expresados en la anterior tabla pueden ser fácilmente adaptados a cualquier topología real donde no todos los transformadores sean iguales y por ende, tengan una regulación diferente.




Figura 4.22 Representación gráfica de las tomas para la red IEEE57

Nudo	Tipo	Potencia Activa (MW)	Potencia Reactiva (MVar)
1	3	55,00	17,00
2	2	3,00	88,00
3	2	41,00	21,00
4	1	0,00	0,00
5	1	13,00	4,00
6	2	75,00	2,00
7	1	0,00	0,00
8	2	150,00	22,00
9	2	121,00	26,00
10	1	5,00	2,00
11	1	0,00	0,00
12	2	377,00	24,00
13	1	18,00	2,30
14	1	10,50	5,30
15	1	22,00	5,00
16	1	43,00	3,00
17	1	42,00	8,00
18	1	27,20	9,80
19	1	3,30	0,60

Nudo	Tipo	Potencia Activa (MW)	Potencia Reactiva (MVar)
20	1	2,30	1,00
21	1	0,00	0,00
22	1	0,00	0,00
23	1	6,30	2,10
24	1	0,00	0,00
25	1	6,30	3,20
26	1	0,00	0,00
27	1	9,30	0,50
28	1	4,60	2,30
29	1	17,00	2,60
30	1	3,60	1,80
31	1	5,80	2,90
32	1	1,60	0,80
33	1	3,80	1,90
34	1	0,00	0,00
35	1	6,00	3,00
36	1	0,00	0,00
37	1	0,00	0,00
38	1	14,00	7,00
39	1	0,00	0,00
40	1	0,00	0,00
41	1	6,30	3,00
42	1	7,10	4,40
43	1	2,00	1,00
44	1	12,00	1,80
45	1	0,00	0,00
46	1	0,00	0,00
47	1	29,70	11,60
48	1	0,00	0,00
49	1	18,00	8,50
50	1	21,00	10,50
51	1	18,00	5,30
52	1	4,90	2,20
53	1	20,00	10,00
54	1	4,10	1,40
55	1	6,80	3,40
56	1	7,60	2,20
57	1	6,70	2,00

Tabla 4.12 Situación de cargas para la red IEEE57




Figura 4.23 Nivel de carga en la Red IEEE57

En este caso, la situación de las tomas responde a una posición más convencional, es decir, los transformadores intentando elevar la tensión en la mayoría de los nodos (y por tanto, usando las tomas por debajo de la nominal).

Se puede apreciar como prácticamente no existe, para este caso transformador alguno que tenga agotado todo su rango de regulación, existiendo por tanto un margen de actuación.

Nivel de tensión en los nodos

En la figura 4.24 se puede observar la situación final de la tensión nodal (módulos). Se comprueba como la mayoría de ellos están cercanos a la tensión nominal, existiendo un pequeño rango de variación.




Figura 4.24 Distribución de tensiones nodales para la red IEEE57

Tiempo de Ejecución

La resolución del problema para la red IEEE57 se realiza en 226 segundos, usando la máquina descrita en la tabla 4.5.




Figura 4.25 Evolución de la población para la red IEEE57

La red IEEE57 se puede considerar como un test de mediano tamaño y que se acerca a redes reales instaladas. Se vuelve a comprobar como el algoritmo converge, en un período de tiempo razonable, hacia una solución donde las tensiones nodales se encuentran en un rango admisible y cercanas a la nominal.

En la figura 4.25 se muestra cómo se produce una mejora de la solución conforme se avanza en el número de generaciones. En este caso, un valor de 180 generaciones es suficiente para obtener un valor razonable, ya que la posible mejora que se pueda conseguir con más generaciones, sería mínima, en comparación con el tiempo empleado.

4.2.1.3 Red RTS

El sistema RTS se compone de los siguientes elementos:

- 33 nodos de generación que agrupan a 99 unidades generadoras, de las cuales 96 son centrales eléctricas y las 3 restantes son generadores síncronos. Las potencias activas y reactivas máximas y mínimas de los generadores han sido elegidas conforme a la propuesta inicial de [Grigg 99]. El conjunto puede apreciarse en la figura 4.26.

- Red de transporte y distribución compuesta por 104 líneas que interconectan a 73 nudos. Existen 16 transformadores de potencia con tomas de regulación. Existen dos niveles de tensión: 138 y 230 kV.
- Como elementos de control de tensión, se tendrán en cuenta los cambiadores de tomas de los transformadores, aunque los condensadores síncronos (o cualquier otro elemento que pueda aportar energía reactiva) pueden efectuar también esa tarea de manera habitual.

Otras características relevantes del sistema son las siguientes:

- El nudo oscilante o *slack* es el número 113, el cuál está en la zona de interconexión entre A y B.
- Se ha elegido un momento del día aleatorio para realizar la simulación del ajuste de tensiones.
- La demanda de potencia en cada nudo es conocida de antemano y tiene una forma similar a la de la tabla 4.12.

En la tabla 4.13 se muestran los parámetros empleados para la ejecución del algoritmo genético desarrollado. Estos parámetros son los que han permitido la obtención de mejores soluciones para los casos de estudio en base al análisis realizado en el apartado anterior.

Parámetro	Valor
Tamaño de Población	80
Número de Generaciones	180
Tipo de Cruce	Monopunto
Tasa de Mutación	0.2
Tasa de Elitismo	10%

Tabla 4.13 Parámetros genéticos para la resolución de la red RTS

Índice de Desviación de Tensión

Según lo expresado en (4.2) se obtiene un valor para el índice de desviación de tensión de

$$IDT = 0,0121$$

Recordemos que este índice tiene el cero como límite inferior y será tanto mejor cuanto menor sea.

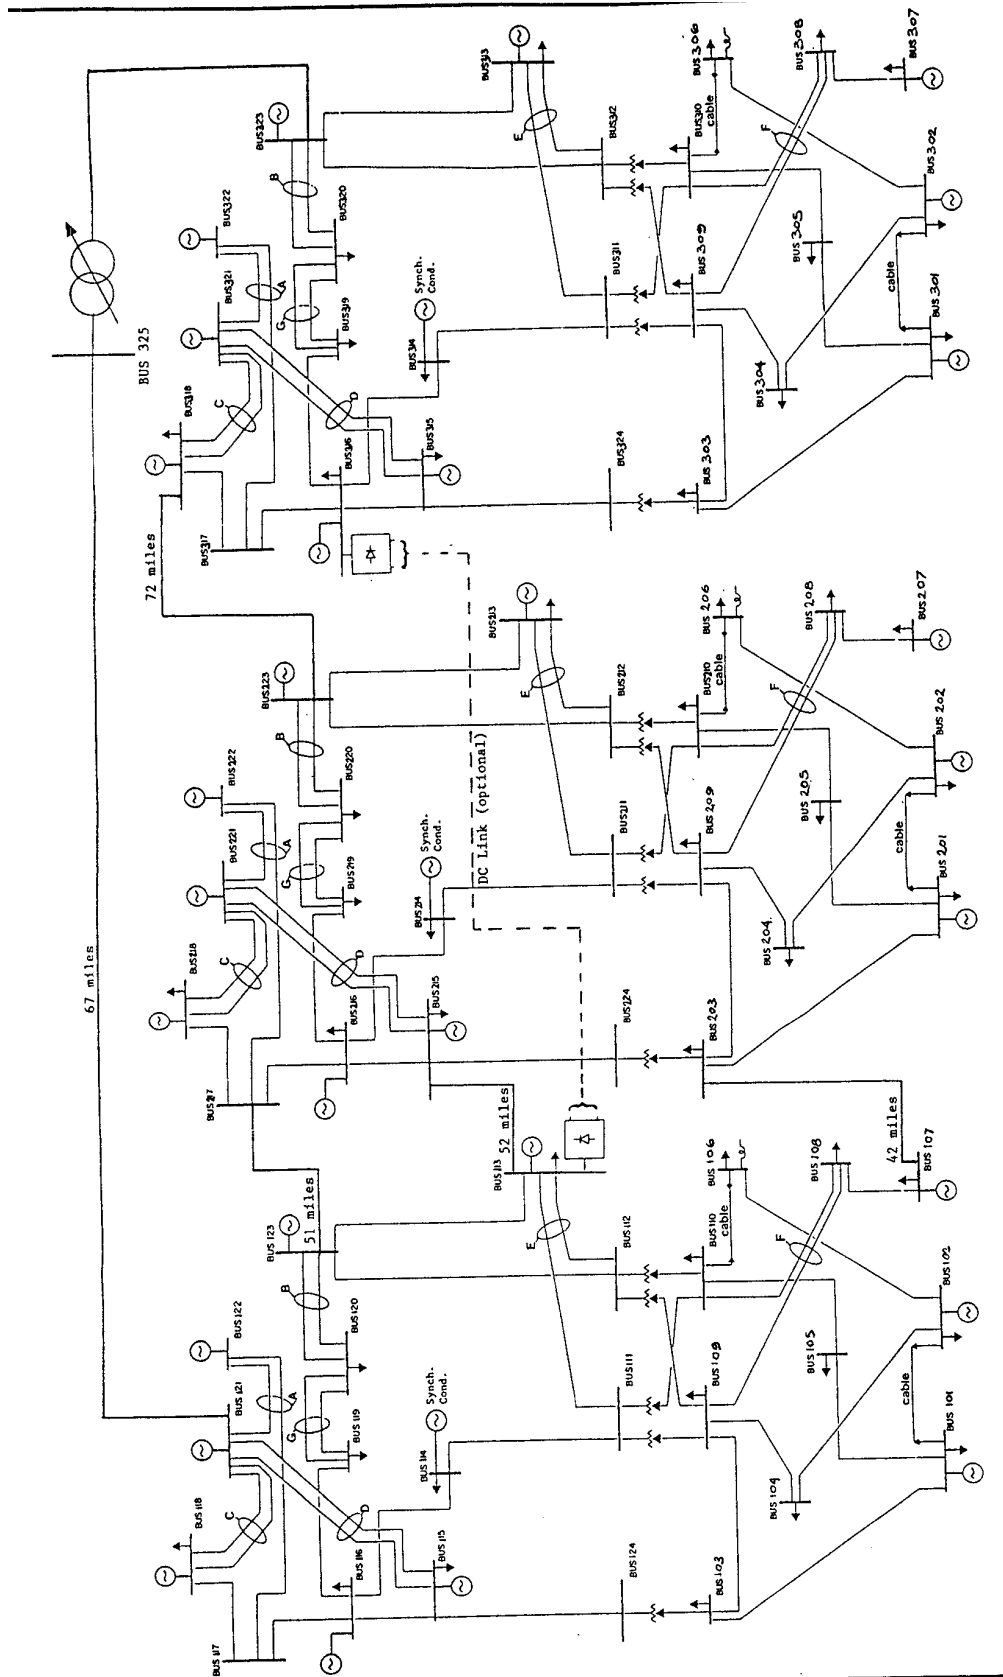


Figura 4.26 Red de potencia RTS

Posición de las tomas de los transformadores

Los 16 transformadores existentes interconectan entre sí dos niveles de tensión diferentes, 138 y 220 kV. Según la posición de los cambiadores de tomas, se podrá controlar la tensión de los nudos del sistema a conveniencia, aunque sólo dentro un rango determinado.

Para este caso, se ha escogido un escalón y un número de tomas arbitrario. En la tabla 4.14 se puede apreciar la distribución de los cambiadores para la situación de cargas de la tabla 4.15.

	Trafo	Nudos	Toma	Rango	Incr. escalón
1	A7	103-124	+2 %	-10 a +10%	1 %
2	A14	109-111	+9 %	-10 a +10%	1 %
3	A15	109-112	+9 %	-10 a +10%	1 %
4	A16	110-111	-1 %	-10 a +10%	1 %
5	A17	110-112	-6 %	-10 a +10%	1 %
6	B7	203-224	0 %	-10 a +10%	1 %
7	B14	209-211	+8 %	-10 a +10%	1 %
8	B15	209-212	+9 %	-10 a +10%	1 %
9	B16	210-211	0 %	-10 a +10%	1 %
10	B17	210-212	-6 %	-10 a +10%	1 %
11	C7	303-324	+3 %	-10 a +10%	1 %
12	C14	309-311	+9 %	-10 a +10%	1 %
13	C15	309-312	+10 %	-10 a +10%	1 %
14	C16	310-311	+1 %	-10 a +10%	1 %
15	C17	310-312	-8 %	-10 a +10%	1 %
16	C35	323-325	0 %	-10 a +10%	1 %

Tabla 4.14 Posición de las tomas de los cambiadores para la red RTS

Los valores que hacen referencia al rango y escalón expresados en la anterior tabla pueden ser fácilmente adaptados a cualquier topología real donde no todos los transformadores sean iguales y por ende, tengan una regulación diferente.




Figura 4.27 Representación gráfica de las tomas para la red RTS

Nudo	Tipo	Potencia Activa (MW)	Potencia Reactiva (MVar)
1	2	108	22,00
2	2	97	20,00
3	1	180	37,00
4	1	74	15,00
5	1	71	14,00
6	1	136	28,00
7	2	125	25,00
8	1	171	35,00
9	1	175	36,00
10	1	195	40,00
11	1	0	0,00
12	1	0	0,00
13	3	300	54,00
14	2	194	39,00
15	2	317	64,00
16	2	100	20,00
17	1	0	0,00
18	2	333	68,00
19	1	181	37,00
20	1	128	26,00
21	2	0	0,00

Nudo	Tipo	Potencia Activa (MW)	Potencia Reactiva (MVar)
22	2	0	0,00
23	2	0	0,00
24	1	0	0,00
25	2	108	22,00
26	2	97	20,00
27	1	180	37,00
28	1	74	15,00
29	1	71	14,00
30	1	136	28,00
31	2	125	25,00
32	1	171	35,00
33	1	175	36,00
34	1	195	40,00
35	1	0	0,00
36	1	0	0,00
37	2	265	54,00
38	2	194	39,00
39	2	317	64,00
40	2	100	20,00
41	1	0	0,00
42	2	333	68,00
43	1	181	37,00
44	1	128	26,00
45	2	0	0,00
46	2	0	0,00
47	2	0	0,00
48	1	0	0,00
49	2	108	22,00
50	2	97	20,00
51	1	180	37,00
52	1	74	15,00
53	1	71	14,00
54	1	136	28,00
55	2	125	25,00
56	1	171	35,00
57	1	175	36,00
58	1	195	40,00
59	1	0	0,00
60	1	0	0,00
61	2	265	54,00
62	2	194	39,00
63	2	317	64,00
64	2	100	20,00
65	1	0	0,00
66	2	333	68,00

Nudo	Tipo	Potencia Activa (MW)	Potencia Reactiva (MVar)
67	1	181	37,00
68	1	128	26,00
69	2	0	0,00
70	2	0	0,00
71	2	0	0,00
72	1	0	0,00
73	1	0	0,00

Tabla 4.15 Situación de cargas para la red RTS




Figura 4.28 Nivel de carga en la Red RTS

En este caso, la situación de las tomas presenta un patrón característico debido a la simetría en la topología de la red, aunque cabe destacar que, a diferencia de los casos anteriores, no existe un sesgo claro que marque una tendencia de elevación o descenso de las tomas en los diferentes transformadores. Son la topología y la distribución de cargas en sí mismas las que provocan que cada toma se sitúe en el nivel adecuado y que se corresponda con la posición que optimiza el conjunto.

Se puede apreciar como existe un transformador que ha agotado todo su rango de regulación, mientras que el resto se encuentra en valores intermedios. Es interesante tener en cuenta este factor ya ante posibles contingencias, sería deseable tener algún margen de maniobra.

Nivel de tensión en los nodos

En la figura 4.29 se puede observar la situación final de la tensión nodal (módulos). Se comprueba como la mayoría de ellos están cercanos a la tensión nominal, existiendo un pequeño rango de variación




Figura 4.29 Distribución de tensiones nodales para la red RTS

Tiempo de Ejecución

La resolución del problema para la red RTS se realiza en 268 segundos, usando la máquina descrita en la tabla 4.5.




Figura 4.30 Evolución de la población para la red RTS

La red RTS se puede considerar como un test de tamaño medio-grande y también se acerca a redes reales instaladas. Se vuelve a comprobar como el algoritmo converge en un período de tiempo razonable hacia una solución donde las tensiones nodales se encuentran en un rango admisible y cercanas a la nominal.

En la figura 4.30 vemos que se produce una mejora de la solución conforme se avanza en el número de generaciones. En este caso, un valor de 180 generaciones es suficiente para obtener un valor razonable, ya que la posible mejora que se pueda conseguir con más generaciones, sería mínima en comparación con el tiempo empleado.

4.2.2 Algoritmo genético multietapa

En el caso del algoritmo genético multietapa, se plantea un escenario más acorde con la programación diaria realizada en los equipos eléctricos pertenecientes a una red de potencia. Se plantea un tiempo de funcionamiento de 24 horas, caso típico en la explotación de redes reales. Para cada tramo horario se definen unos niveles de referencia en base a previsiones que tienen en cuenta datos estadísticos y diferentes aspectos como la climatología, condiciones de servicio, estado de la red, etc.

En el caso que nos ocupa, se dispondría de datos reales sobre el estado de la red, por ejemplo, medida de las demandas de energía activa y reactiva para cada uno de los periodos en estudio. De esta manera, el algoritmo se ejecutará según un patrón definido de resolución temporal.

El resultado final será la obtención de las consignas necesarias para los equipos de control y regulación de los cambiadores de tomas de los transformadores. Estas consignas se proporcionarán diariamente según un patrón horario.

Puesto que la resolución del algoritmo no abarca más allá de unos pocos minutos, se dispone del tiempo suficiente para resolver el problema de manera adecuada en momento y forma.

Al igual que el algoritmo genético monoetapa, la versión multietapa trabaja con redes de cualquier tamaño según los datos de entrada típicos como topología de red (nudos, líneas, etc.), demanda de potencias activa y reactiva en cada nudo y potencias activa y reactiva inyectada por los generadores de la red. Ahora, sin embargo, se va a tener que realizar un trabajo extra, ya que continuamente habrá que resolver situaciones diferentes de carga (para cada hora del día).

Para ello, los datos de entrada cambian ligeramente, y ahora en la matriz de carga aparece un nuevo vector que se corresponde con una curva típica de carga diaria, según se aprecia en la figura 4.31.




Figura 4.31 Curva base de carga diaria confeccionada con datos reales de <http://www.ree.es>

Esta curva base hará de factor multiplicador, en un escenario concreto, para las cargas nodales de la red, de manera que se podrán obtener diferentes modelos de carga con sólo variar los valores de entrada en cada nodo de la red. Ha sido confeccionada de manualmente, siguiendo los patrones típicos de una red de potencia cualquiera.

Los datos de entrada, en su conjunto, son los definidos en la sección 4.2.1 y que pueden encontrarse en el Apéndice A. La estructura completa del algoritmo puede verse en la figura 4.32.

En los siguientes apartados se muestran los resultados obtenidos para dos redes de tamaño medio-grande, teniendo en cuenta un período diario completo de 24 horas.

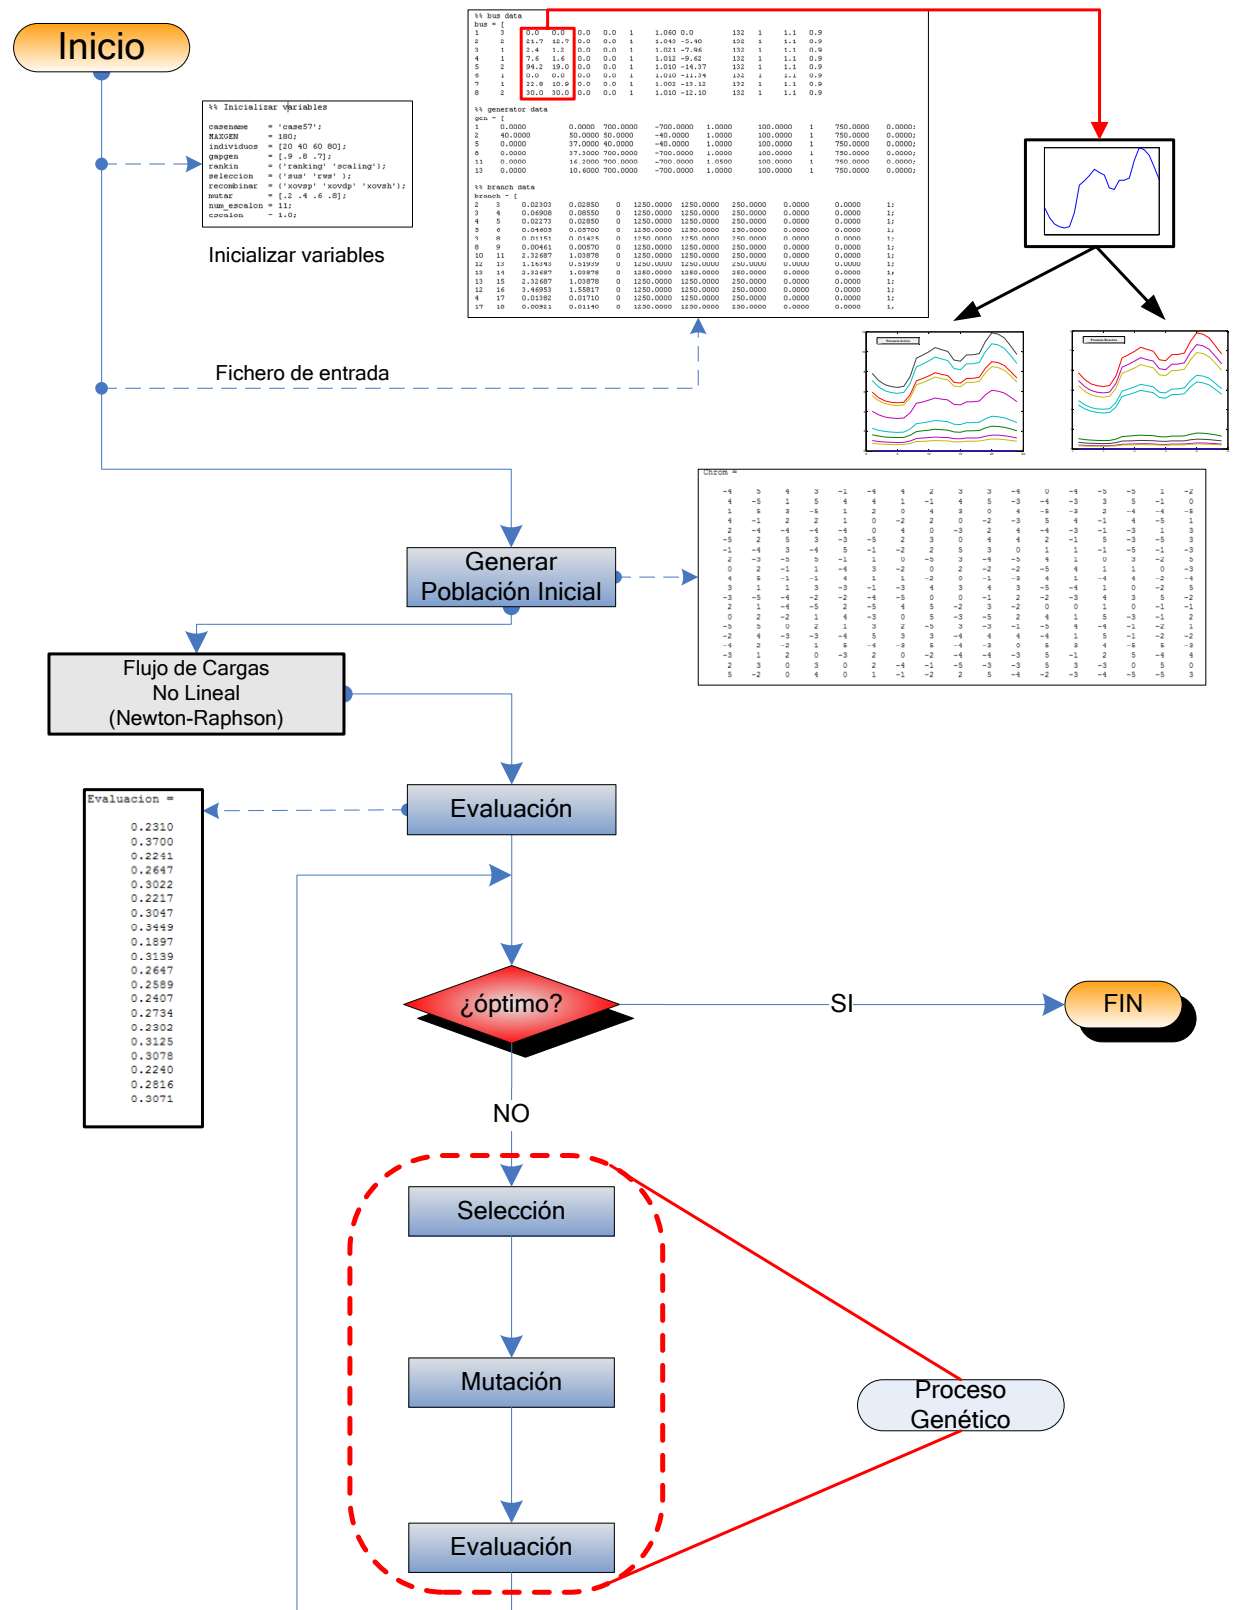


Figura 4.32 Esquema detallado de algoritmo genético multietapa

4.2.2.1 Red IEEE57

En el apartado 4.2.1.2 se detalla con precisión la estructura de la red, por lo que se remite a su consulta.

En la tabla 4.16 se muestran los parámetros empleados para la ejecución del algoritmo genético desarrollado. Estos parámetros son los que han permitido la obtención de mejores soluciones para los casos de estudio, en base al análisis realizado en el apartado anterior.

Parámetro	Valor
Tamaño de Población	80
Número de Generaciones	180
Tipo de Cruce	Monopunto
Tasa de Mutación	0.2
Tasa de Elitismo	10%

Tabla 4.16 Parámetros genéticos para la resolución de la red IEEE57 en periodos de 24 horas

Índice de Desviación de Tensión

A diferencia del planteamiento monoetapa, la versión multietapa obtiene un conjunto de índices para cada franja horaria. En la tabla 4.17 se muestran los valores obtenidos para la curva de la figura 4.33.

En dicha figura se puede observar como los índices obtenidos varían de forma similar a como lo hace el perfil de cargas de la red. En cada periodo horario se obtiene un valor diferente, el cual es mayor cuanto más elevado es el nivel de carga. Esto indica que es más difícil armonizar en tensiones al sistema, si las cargas de la red son elevadas, y lo contrario, se puede conseguir un perfil de tensiones más plano si la carga del sistema no es tan elevada.

Hora	IDT
1	0,012673
2	0,010962
3	0,010464
4	0,0096707
5	0,009941
6	0,0097518
7	0,011763
8	0,017529
9	0,01876
10	0,020667

Hora	IDT
11	0,023187
12	0,022457
13	0,02122
14	0,016692
15	0,01633
16	0,019451
17	0,018913
18	0,020092
19	0,031608
20	0,040087
21	0,041338
22	0,03239
23	0,025187
24	0,019174

Tabla 4.17 Índices de desviación de tensión para la red IEEE57 y un periodo de 24 horas




Figura 4.33 Conjunto de IDT's de la red IEEE57 en un periodo de 24 horas

Posición de las tomas de los transformadores

La situación de las tomas de los transformadores se torna cambiante a lo largo de cada periodo. En función del nivel de carga, algunos transformadores van variando su posición para ajustar el nivel de tensión a la salida. Este efecto no es del todo beneficioso a priori, sobre todo cuando se producen muchas variaciones para un sólo transformador, debido a que uno de los factores que limitan la vida útil de los cambiadores es precisamente el número de maniobras que se realizan en el mismo. Este tema se deja abierto para el futuro poder implementar alguna política al respecto.

En esta fase de diseño no se impondrán restricciones acerca de las veces que un transformador puede cambiar de toma para un periodo horario concreto.

Los datos utilizados vuelven a ser los expuestos en el apartado 4.2.1.2.

Tras la ejecución del algoritmo se obtiene un resultado como el de la figura 4.34. Además, los resultados numéricos se pueden consultar en la tabla 4.18 y tabla 4.19. Se puede observar como existen algunos transformadores que varían constantemente su toma para ajustar el nivel de tensión en función de la carga, mientras que otros no se ven muy afectados. La topología de la red y la distribución de las cargas influyen en esta variable de forma decisiva.

Como se ha comentado anteriormente, esta forma de plantear el problema presenta la desventaja de no limitar el número de veces que el cambiador actúa, aunque por otra parte se consigue llevar al sistema a su nivel óptimo en cuanto a perfil de tensiones.

Desde la tabla 4.20 hasta la tabla 4.23 se presentan los datos reales sobre el estado de cargas correspondiente a un día completo (24 horas) tanto para la potencia activa como reactiva.

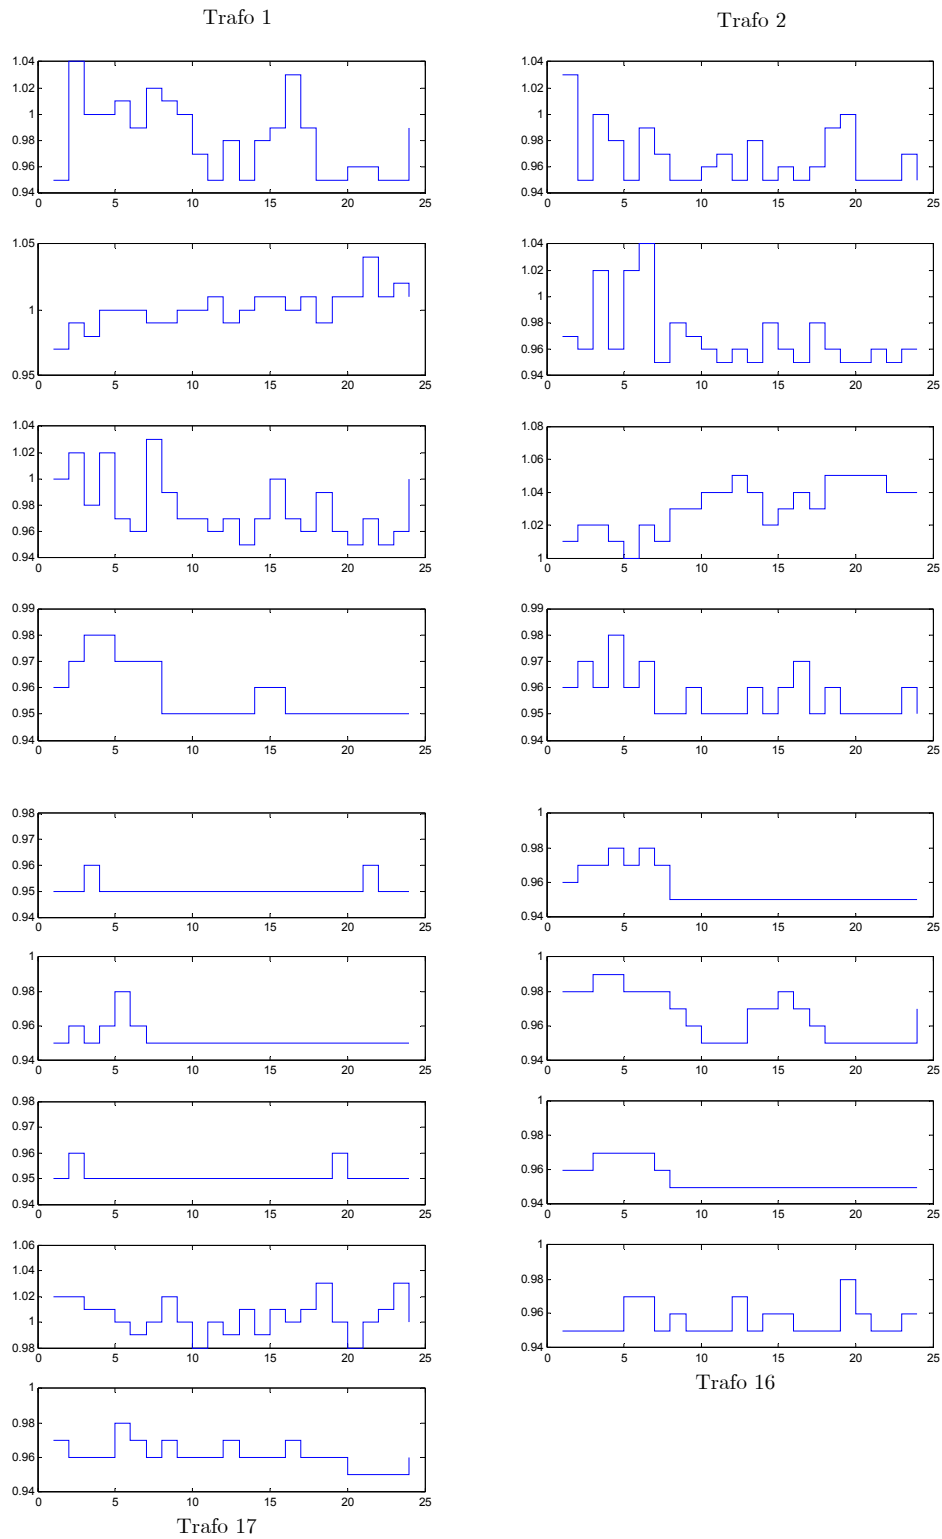


Figura 4.34 Representación gráfica de las tomas para la red IEEE57 en un periodo de 24 horas

Trafo	Nudos	Hora 1	Hora 2	Hora 3	Hora 4	Hora 5	Hora 6	Hora 7	Hora 8	Hora 9	Hora 10	Hora 11	Hora 12
1 SPRIGG	4-18	-5%	4%	0%	0%	1%	-1%	2%	1%	0%	-3%	-5%	-2%
2 --	7-29	3%	-5%	0%	-2%	-5%	-1%	-3%	-5%	-5%	-4%	-3%	-5%
3 SALTVILLE	9-55	-3%	-1%	-2%	0%	0%	0%	-1%	-1%	0%	0%	1%	-1%
4 --	10-55	-3%	-4%	2%	-4%	2%	4%	-5%	-2%	-3%	-4%	-5%	-4%
5 --	20-21	0%	2%	-2%	2%	-3%	-4%	3%	-1%	-3%	-3%	-4%	-3%
6 --	24-26	1%	2%	2%	1%	0%	2%	1%	3%	3%	4%	4%	5%
7 --	24-25	-4%	-3%	-2%	-2%	-3%	-3%	-3%	-5%	-5%	-5%	-5%	-5%
8 --	24-25	-4%	-3%	-4%	-2%	-4%	-3%	-5%	-5%	-4%	-5%	-5%	-5%
9 --	32-34	-5%	-5%	-4%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%
10 TAZEWELL	41-11	-4%	-3%	-3%	-2%	-3%	-2%	-3%	-5%	-5%	-5%	-5%	-5%
11 TAZEWELL	41-43	-5%	-4%	-5%	-4%	-2%	-4%	-5%	-5%	-5%	-5%	-5%	-5%
12 TAZEWELL	43-11	-2%	-2%	-1%	-1%	-2%	-2%	-2%	-3%	-4%	-5%	-5%	-5%
13 --	13-49	-5%	-4%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%
14 --	14-46	-4%	-4%	-3%	-3%	-3%	-3%	-4%	-5%	-5%	-5%	-5%	-5%
15 --	15-45	2%	2%	1%	1%	0%	-1%	0%	2%	0%	-2%	0%	-1%
16 --	39-57	-5%	-5%	-5%	-5%	-3%	-3%	-5%	-4%	-5%	-5%	-5%	-3%
17 --	40-54	-3%	-4%	-4%	-4%	-2%	-3%	-4%	-3%	-4%	-4%	-4%	-3%

Tabla 4.18 Posición de las tomas de los cambiadores para la red IEEE57 en un periodo de 24 horas (I)

Trafo	Nudos	Hora 13	Hora 14	Hora 15	Hora 16	Hora 17	Hora 18	Hora 19	Hora 20	Hora 21	Hora 22	Hora 23	Hora 24
1 SPRIGG	4-18	-5%	-2%	-1%	3%	-1%	-5%	-5%	-4%	-4%	-5%	-5%	-1%
2 --	7-29	-2%	-5%	-4%	-5%	-4%	-1%	0%	-5%	-5%	-5%	-3%	-5%
3 SALTVILLE	9-55	0%	1%	1%	0%	1%	-1%	1%	1%	4%	1%	2%	1%
4 --	10-55	-5%	-2%	-4%	-5%	-2%	-4%	-5%	-5%	-4%	-5%	-4%	-4%
5 --	20-21	-5%	-3%	0%	-3%	-4%	-1%	-4%	-5%	-3%	-5%	-4%	0%
6 --	24-26	4%	2%	3%	4%	3%	5%	5%	5%	5%	4%	4%	4%
7 --	24-25	-5%	-4%	-4%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%
8 --	24-25	-4%	-5%	-4%	-3%	-5%	-4%	-5%	-5%	-5%	-5%	-4%	-5%
9 --	32-34	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-4%	-5%	-5%	-5%
10 TAZEWELL	41-11	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%
11 TAZEWELL	41-43	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%
12 TAZEWELL	43-11	-3%	-3%	-2%	-3%	-4%	-5%	-5%	-5%	-5%	-5%	-5%	-3%
13 --	13-49	-5%	-5%	-5%	-5%	-5%	-5%	-4%	-5%	-5%	-5%	-5%	-5%
14 --	14-46	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%
15 --	15-45	1%	-1%	1%	0%	1%	3%	0%	-2%	0%	1%	3%	0%
16 --	39-57	-5%	-4%	-4%	-5%	-5%	-5%	-2%	-4%	-5%	-5%	-4%	-4%
17 --	40-54	-4%	-4%	-4%	-3%	-4%	-4%	-4%	-5%	-5%	-5%	-5%	-4%

Tabla 4.19 Posición de las tomas de los cambiadores para la red IEEE57 en un periodo de 24 horas (II)

25	1	4,14	3,76	3,53	3,43	3,38	3,44	3,95	4,95	5,11	5,29	5,51	5,40
26	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
27	1	6,10	5,55	5,22	5,06	5,00	5,08	5,83	7,30	7,54	7,81	8,14	7,98
28	1	3,02	2,74	2,58	2,51	2,47	2,51	2,88	3,61	3,73	3,86	4,03	3,94
29	1	11,16	10,14	9,54	9,26	9,13	9,28	10,65	13,35	13,78	14,28	14,88	14,58
30	1	2,36	2,15	2,02	1,96	1,93	1,97	2,26	2,83	2,92	3,02	3,15	3,09
31	1	3,81	3,46	3,25	3,16	3,12	3,17	3,63	4,55	4,70	4,87	5,08	4,97
32	1	1,05	0,95	0,90	0,87	0,86	0,87	1,00	1,26	1,30	1,34	1,40	1,37
33	1	2,49	2,27	2,13	2,07	2,04	2,08	2,38	2,98	3,08	3,19	3,33	3,26
34	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
35	1	3,94	3,58	3,37	3,27	3,22	3,28	3,76	4,71	4,86	5,04	5,25	5,15
36	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
37	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
38	1	9,19	8,35	7,86	7,62	7,52	7,65	8,77	10,99	11,35	11,76	12,26	12,01
39	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
40	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
41	1	4,14	3,76	3,53	3,43	3,38	3,44	3,95	4,95	5,11	5,29	5,51	5,40
42	1	4,66	4,24	3,98	3,87	3,81	3,88	4,45	5,57	5,76	5,97	6,22	6,09
43	1	1,31	1,19	1,12	1,09	1,07	1,09	1,25	1,57	1,62	1,68	1,75	1,72
44	1	7,88	7,16	6,73	6,54	6,45	6,55	7,52	9,42	9,73	10,08	10,50	10,29
45	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
46	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
47	1	19,49	17,72	16,67	16,17	15,96	16,22	18,61	23,32	24,08	24,95	26,00	25,47
48	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
49	1	11,81	10,74	10,10	9,80	9,67	9,83	11,28	14,13	14,59	15,12	15,76	15,44
50	1	13,78	12,53	11,78	11,44	11,28	11,47	13,16	16,49	17,03	17,64	18,38	18,01
51	1	11,81	10,74	10,10	9,80	9,67	9,83	11,28	14,13	14,59	15,12	15,76	15,44
52	1	3,22	2,92	2,75	2,67	2,63	2,68	3,07	3,85	3,97	4,12	4,29	4,20

53	1	13,13	11,93	11,22	10,89	10,75	10,92	12,53	15,70	16,22	16,80	17,51	17,15
54	1	2,69	2,45	2,30	2,23	2,20	2,24	2,57	3,22	3,32	3,44	3,59	3,52
55	1	4,46	4,06	3,82	3,70	3,65	3,71	4,26	5,34	5,51	5,71	5,95	5,83
56	1	4,99	4,54	4,26	4,14	4,08	4,15	4,76	5,97	6,16	6,39	6,65	6,52
57	1	4,40	4,00	3,76	3,65	3,60	3,66	4,20	5,26	5,43	5,63	5,87	5,75

Tabla 4.20 Situación de cargas para la red IEEE57 en un periodo de 24 horas (I)

Nudo	Tipo	Potencia Activa (MW)											
		Hora 13	Hora 14	Hora 15	Hora 16	Hora 17	Hora 18	Hora 19	Hora 20	Hora 21	Hora 22	Hora 23	Hora 24
1	3	46,34	42,28	41,76	44,65	44,74	45,41	50,95	55,00	54,38	52,64	48,84	44,87
2	2	2,53	2,31	2,28	2,44	2,44	2,48	2,78	3,00	2,97	2,87	2,66	2,45
3	2	34,54	31,52	31,13	33,29	33,35	33,85	37,98	41,00	40,53	39,24	36,41	33,45
4	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
5	1	10,95	9,99	9,87	10,55	10,57	10,73	12,04	13,00	12,85	12,44	11,54	10,61
6	2	63,19	57,66	56,95	60,89	61,00	61,92	69,48	75,00	74,15	71,78	66,60	61,18
7	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
8	2	126,38	115,31	113,90	121,78	122,01	123,84	138,96	150,00	148,29	143,56	133,20	122,36
9	2	101,95	93,02	91,88	98,24	98,42	99,90	112,10	121,00	119,62	115,81	107,45	98,70
10	1	4,21	3,84	3,80	4,06	4,07	4,13	4,63	5,00	4,94	4,79	4,44	4,08
11	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
12	2	317,64	289,82	286,26	306,08	306,64	311,25	349,26	377,00	372,71	360,83	334,78	307,53
13	1	15,17	13,84	13,67	14,61	14,64	14,86	16,68	18,00	17,80	17,23	15,98	14,68
14	1	8,85	8,07	7,97	8,52	8,54	8,67	9,73	10,50	10,38	10,05	9,32	8,57
15	1	18,54	16,91	16,71	17,86	17,89	18,16	20,38	22,00	21,75	21,06	19,54	17,95
16	1	36,23	33,06	32,65	34,91	34,98	35,50	39,84	43,00	42,51	41,16	38,19	35,08
17	1	35,39	32,29	31,89	34,10	34,16	34,68	38,91	42,00	41,52	40,20	37,30	34,26

Nudo	Tipo	Potencia Activa (MW)											
		Hora 13	Hora 14	Hora 15	Hora 16	Hora 17	Hora 18	Hora 19	Hora 20	Hora 21	Hora 22	Hora 23	Hora 24
18	1	22,92	20,91	20,65	22,08	22,12	22,46	25,20	27,20	26,89	26,03	24,15	22,19
19	1	2,78	2,54	2,51	2,68	2,68	2,72	3,06	3,30	3,26	3,16	2,93	2,69
20	1	1,94	1,77	1,75	1,87	1,87	1,90	2,13	2,30	2,27	2,20	2,04	1,88
21	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
22	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
23	1	5,31	4,84	4,78	5,11	5,12	5,20	5,84	6,30	6,23	6,03	5,59	5,14
24	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
25	1	5,31	4,84	4,78	5,11	5,12	5,20	5,84	6,30	6,23	6,03	5,59	5,14
26	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
27	1	7,84	7,15	7,06	7,55	7,56	7,68	8,62	9,30	9,19	8,90	8,26	7,59
28	1	3,88	3,54	3,49	3,73	3,74	3,80	4,26	4,60	4,55	4,40	4,08	3,75
29	1	14,32	13,07	12,91	13,80	13,83	14,04	15,75	17,00	16,81	16,27	15,10	13,87
30	1	3,03	2,77	2,73	2,92	2,93	2,97	3,34	3,60	3,56	3,45	3,20	2,94
31	1	4,89	4,46	4,40	4,71	4,72	4,79	5,37	5,80	5,73	5,55	5,15	4,73
32	1	1,35	1,23	1,21	1,30	1,30	1,32	1,48	1,60	1,58	1,53	1,42	1,31
33	1	3,20	2,92	2,89	3,09	3,09	3,14	3,52	3,80	3,76	3,64	3,37	3,10
34	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
35	1	5,06	4,61	4,56	4,87	4,88	4,95	5,56	6,00	5,93	5,74	5,33	4,89
36	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
37	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
38	1	11,80	10,76	10,63	11,37	11,39	11,56	12,97	14,00	13,84	13,40	12,43	11,42
39	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
40	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
41	1	5,31	4,84	4,78	5,11	5,12	5,20	5,84	6,30	6,23	6,03	5,59	5,14
42	1	5,98	5,46	5,39	5,76	5,77	5,86	6,58	7,10	7,02	6,80	6,31	5,79
43	1	1,69	1,54	1,52	1,62	1,63	1,65	1,85	2,00	1,98	1,91	1,78	1,63

Nudo	Tipo	Potencia Activa (MW)											
		Hora 13	Hora 14	Hora 15	Hora 16	Hora 17	Hora 18	Hora 19	Hora 20	Hora 21	Hora 22	Hora 23	Hora 24
44	1	10,11	9,23	9,11	9,74	9,76	9,91	11,12	12,00	11,86	11,49	10,66	9,79
45	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
46	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
47	1	25,02	22,83	22,55	24,11	24,16	24,52	27,52	29,70	29,36	28,43	26,37	24,23
48	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
49	1	15,17	13,84	13,67	14,61	14,64	14,86	16,68	18,00	17,80	17,23	15,98	14,68
50	1	17,69	16,14	15,95	17,05	17,08	17,34	19,46	21,00	20,76	20,10	18,65	17,13
51	1	15,17	13,84	13,67	14,61	14,64	14,86	16,68	18,00	17,80	17,23	15,98	14,68
52	1	4,13	3,77	3,72	3,98	3,99	4,05	4,54	4,90	4,84	4,69	4,35	4,00
53	1	16,85	15,38	15,19	16,24	16,27	16,51	18,53	20,00	19,77	19,14	17,76	16,32
54	1	3,45	3,15	3,11	3,33	3,33	3,39	3,80	4,10	4,05	3,92	3,64	3,34
55	1	5,73	5,23	5,16	5,52	5,53	5,61	6,30	6,80	6,72	6,51	6,04	5,55
56	1	6,40	5,84	5,77	6,17	6,18	6,27	7,04	7,60	7,51	7,27	6,75	6,20
57	1	5,65	5,15	5,09	5,44	5,45	5,53	6,21	6,70	6,62	6,41	5,95	5,47

Tabla 4.21 Situación de cargas para la red IEEE57 en un periodo de 24 horas (II)

25	1	2,10	1,91	1,80	1,74	1,72	1,75	2,00	2,51	2,59	2,69	2,80	2,74
26	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
27	1	0,33	0,30	0,28	0,27	0,27	0,27	0,31	0,39	0,41	0,42	0,44	0,43
28	1	1,51	1,37	1,29	1,25	1,24	1,26	1,44	1,81	1,86	1,93	2,01	1,97
29	1	1,71	1,55	1,46	1,42	1,40	1,42	1,63	2,04	2,11	2,18	2,28	2,23
30	1	1,18	1,07	1,01	0,98	0,97	0,98	1,13	1,41	1,46	1,51	1,58	1,54
31	1	1,90	1,73	1,63	1,58	1,56	1,58	1,82	2,28	2,35	2,44	2,54	2,49
32	1	0,53	0,48	0,45	0,44	0,43	0,44	0,50	0,63	0,65	0,67	0,70	0,69
33	1	1,25	1,13	1,07	1,03	1,02	1,04	1,19	1,49	1,54	1,60	1,66	1,63
34	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
35	1	1,97	1,79	1,68	1,63	1,61	1,64	1,88	2,36	2,43	2,52	2,63	2,57
36	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
37	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
38	1	4,59	4,18	3,93	3,81	3,76	3,82	4,39	5,50	5,68	5,88	6,13	6,00
39	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
40	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
41	1	1,97	1,79	1,68	1,63	1,61	1,64	1,88	2,36	2,43	2,52	2,63	2,57
42	1	2,89	2,63	2,47	2,40	2,36	2,40	2,76	3,45	3,57	3,70	3,85	3,77
43	1	0,66	0,60	0,56	0,54	0,54	0,55	0,63	0,79	0,81	0,84	0,88	0,86
44	1	1,18	1,07	1,01	0,98	0,97	0,98	1,13	1,41	1,46	1,51	1,58	1,54
45	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
46	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
47	1	7,61	6,92	6,51	6,32	6,23	6,33	7,27	9,11	9,41	9,75	10,15	9,95
48	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
49	1	5,58	5,07	4,77	4,63	4,57	4,64	5,33	6,67	6,89	7,14	7,44	7,29
50	1	6,89	6,27	5,89	5,72	5,64	5,73	6,58	8,24	8,51	8,82	9,19	9,00
51	1	3,48	3,16	2,97	2,89	2,85	2,89	3,32	4,16	4,30	4,45	4,64	4,55
52	1	1,44	1,31	1,23	1,20	1,18	1,20	1,38	1,73	1,78	1,85	1,93	1,89

53	1	6,56	5,97	5,61	5,45	5,37	5,46	6,27	7,85	8,11	8,40	8,75	8,58
54	1	0,92	0,84	0,79	0,76	0,75	0,76	0,88	1,10	1,14	1,18	1,23	1,20
55	1	2,23	2,03	1,91	1,85	1,83	1,86	2,13	2,67	2,76	2,86	2,98	2,92
56	1	1,44	1,31	1,23	1,20	1,18	1,20	1,38	1,73	1,78	1,85	1,93	1,89
57	1	1,31	1,19	1,12	1,09	1,07	1,09	1,25	1,57	1,62	1,68	1,75	1,72

Tabla 4.22 Situación de cargas para la red IEEE57 en un periodo de 24 horas (III)

Nudo	Tipo	Potencia Reactiva (MVar)											
		Hora 13	Hora 14	Hora 15	Hora 16	Hora 17	Hora 18	Hora 19	Hora 20	Hora 21	Hora 22	Hora 23	Hora 24
1	3	14,32	13,07	12,91	13,80	13,83	14,04	15,75	17,00	16,81	16,27	15,10	13,87
2	2	74,14	67,65	66,82	71,45	71,58	72,65	81,53	88,00	87,00	84,23	78,15	71,78
3	2	17,69	16,14	15,95	17,05	17,08	17,34	19,46	21,00	20,76	20,10	18,65	17,13
4	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
5	1	3,37	3,08	3,04	3,25	3,25	3,30	3,71	4,00	3,95	3,83	3,55	3,26
6	2	1,69	1,54	1,52	1,62	1,63	1,65	1,85	2,00	1,98	1,91	1,78	1,63
7	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
8	2	18,54	16,91	16,71	17,86	17,89	18,16	20,38	22,00	21,75	21,06	19,54	17,95
9	2	21,91	19,99	19,74	21,11	21,15	21,47	24,09	26,00	25,70	24,89	23,09	21,21
10	1	1,69	1,54	1,52	1,62	1,63	1,65	1,85	2,00	1,98	1,91	1,78	1,63
11	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
12	2	20,22	18,45	18,22	19,49	19,52	19,81	22,23	24,00	23,73	22,97	21,31	19,58
13	1	1,94	1,77	1,75	1,87	1,87	1,90	2,13	2,30	2,27	2,20	2,04	1,88
14	1	4,47	4,07	4,02	4,30	4,31	4,38	4,91	5,30	5,24	5,07	4,71	4,32
15	1	4,21	3,84	3,80	4,06	4,07	4,13	4,63	5,00	4,94	4,79	4,44	4,08
16	1	2,53	2,31	2,28	2,44	2,44	2,48	2,78	3,00	2,97	2,87	2,66	2,45
17	1	6,74	6,15	6,07	6,50	6,51	6,60	7,41	8,00	7,91	7,66	7,10	6,53
18	1	8,26	7,53	7,44	7,96	7,97	8,09	9,08	9,80	9,69	9,38	8,70	7,99
19	1	0,51	0,46	0,46	0,49	0,49	0,50	0,56	0,60	0,59	0,57	0,53	0,49

Nudo	Tipo	Potencia Reactiva (MVar)											
		Hora 13	Hora 14	Hora 15	Hora 16	Hora 17	Hora 18	Hora 19	Hora 20	Hora 21	Hora 22	Hora 23	Hora 24
20	1	0,84	0,77	0,76	0,81	0,81	0,83	0,93	1,00	0,99	0,96	0,89	0,82
21	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
22	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
23	1	1,77	1,61	1,59	1,70	1,71	1,73	1,95	2,10	2,08	2,01	1,86	1,71
24	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
25	1	2,70	2,46	2,43	2,60	2,60	2,64	2,96	3,20	3,16	3,06	2,84	2,61
26	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
27	1	0,42	0,38	0,38	0,41	0,41	0,41	0,46	0,50	0,49	0,48	0,44	0,41
28	1	1,94	1,77	1,75	1,87	1,87	1,90	2,13	2,30	2,27	2,20	2,04	1,88
29	1	2,19	2,00	1,97	2,11	2,11	2,15	2,41	2,60	2,57	2,49	2,31	2,12
30	1	1,52	1,38	1,37	1,46	1,46	1,49	1,67	1,80	1,78	1,72	1,60	1,47
31	1	2,44	2,23	2,20	2,35	2,36	2,39	2,69	2,90	2,87	2,78	2,58	2,37
32	1	0,67	0,62	0,61	0,65	0,65	0,66	0,74	0,80	0,79	0,77	0,71	0,65
33	1	1,60	1,46	1,44	1,54	1,55	1,57	1,76	1,90	1,88	1,82	1,69	1,55
34	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
35	1	2,53	2,31	2,28	2,44	2,44	2,48	2,78	3,00	2,97	2,87	2,66	2,45
36	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
37	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
38	1	5,90	5,38	5,32	5,68	5,69	5,78	6,49	7,00	6,92	6,70	6,22	5,71
39	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
40	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
41	1	2,53	2,31	2,28	2,44	2,44	2,48	2,78	3,00	2,97	2,87	2,66	2,45
42	1	3,71	3,38	3,34	3,57	3,58	3,63	4,08	4,40	4,35	4,21	3,91	3,59
43	1	0,84	0,77	0,76	0,81	0,81	0,83	0,93	1,00	0,99	0,96	0,89	0,82
44	1	1,52	1,38	1,37	1,46	1,46	1,49	1,67	1,80	1,78	1,72	1,60	1,47
45	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00

Nudo	Tipo	Potencia Reactiva (MVar)											
		Hora 13	Hora 14	Hora 15	Hora 16	Hora 17	Hora 18	Hora 19	Hora 20	Hora 21	Hora 22	Hora 23	Hora 24
46	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
47	1	9,77	8,92	8,81	9,42	9,44	9,58	10,75	11,60	11,47	11,10	10,30	9,46
48	1	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
49	1	7,16	6,53	6,45	6,90	6,91	7,02	7,87	8,50	8,40	8,14	7,55	6,93
50	1	8,85	8,07	7,97	8,52	8,54	8,67	9,73	10,50	10,38	10,05	9,32	8,57
51	1	4,47	4,07	4,02	4,30	4,31	4,38	4,91	5,30	5,24	5,07	4,71	4,32
52	1	1,85	1,69	1,67	1,79	1,79	1,82	2,04	2,20	2,18	2,11	1,95	1,79
53	1	8,43	7,69	7,59	8,12	8,13	8,26	9,26	10,00	9,89	9,57	8,88	8,16
54	1	1,18	1,08	1,06	1,14	1,14	1,16	1,30	1,40	1,38	1,34	1,24	1,14
55	1	2,86	2,61	2,58	2,76	2,77	2,81	3,15	3,40	3,36	3,25	3,02	2,77
56	1	1,85	1,69	1,67	1,79	1,79	1,82	2,04	2,20	2,18	2,11	1,95	1,79
57	1	1,69	1,54	1,52	1,62	1,63	1,65	1,85	2,00	1,98	1,91	1,78	1,63

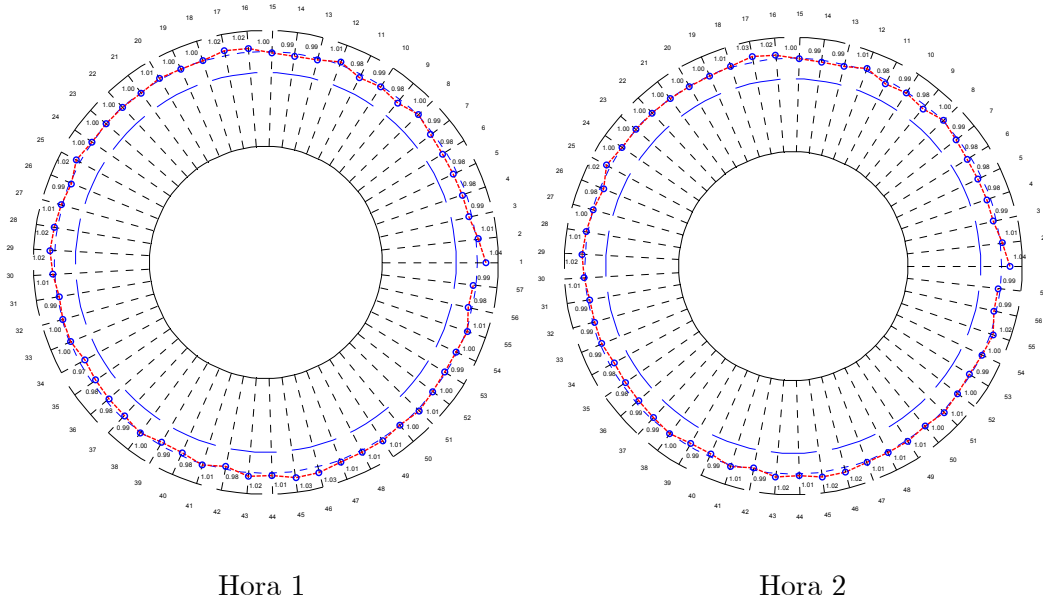
Tabla 4.23 Situación de cargas para la red IEEE57 en un periodo de 24 horas (IV)


Al igual que en los casos anteriores, la distribución de las tomas no presenta un patrón característico o repetitivo, sino que depende del nivel de cargas asociado a cada nodo de la red. Además, la configuración del sistema y su topología determinan claramente su nivel.

Cabe destacar que los transformadores no llegan a agotar su rango de regulación de manera clara, por lo que se suele mantener un margen para regulación que conviene desde el punto de vista del tratamiento de contingencias.

Nivel de tensión en los nodos


En la secuencia siguiente se puede observar la situación final de la tensión nodal (módulos) para cada uno de los periodos horarios. Se vuelve a comprobar como la mayoría de ellos siguen cercanos a la tensión nominal, por lo que no hay gran variación o desvío en el sistema.






Hora 3

Hora 4




Hora 5


Hora 6




Hora 7




Hora 8




Hora 9




Hora 10




Hora 11




Hora 12




Hora 13




Hora 14




Hora 15




Hora 16




Hora 17




Hora 18




Hora 19




Hora 20




Hora 21



Hora 22



Hora 23



Hora 24

Tiempo de Ejecución

La resolución del problema IEEE57 para un periodo horario de 24 horas, se realiza en un tiempo variable tal y como se muestra en la tabla 4.24, usando la máquina descrita en la tabla 4.5.

Hora	Tiempo (s)
1	80,844
2	101,39
3	90,719
4	50,781
5	38,953
6	83,782
7	80,359
8	91,656
9	91,156
10	78,047
11	171,75
12	75,485
13	65,984
14	94,141
15	78,968
16	60,344
17	90,5
18	74,516
19	58,765

Hora	Tiempo (s)
20	82,954
21	72,343
22	139,11
23	59,14
24	112,84

Tabla 4.24 Tiempos de resolución para cada hora de la red IEEE57




Figura 4.35 Evolución de la población en la red IEEE57 para un periodo horario cualquiera

En la figura 4.35 se aprecia cómo se produce una mejora de la solución conforme se avanza en el número de generaciones. En este caso, un valor de 180 generaciones es suficiente para obtener un valor razonable, ya que la posible mejora que se pueda conseguir con más generaciones, sería mínima en comparación con el tiempo empleado

4.2.2.2 Red RTS

La red RTS estudiada en este apartado vuelve a ser la misma que la descrita en el apartado 4.2.1.3.

En la tabla 4.25 se muestran los parámetros empleados para la ejecución del algoritmo genético desarrollado.

Parámetro	Valor
Tamaño de Población	80
Número de Generaciones	180
Tipo de Cruce	Monopunto
Tasa de Mutación	0.2
Tasa de Elitismo	10%

Tabla 4.25 Parámetros genéticos para la resolución de la red RTS en periodos de 24 horas

Índice de Desviación de Tensión

Los resultados obtenidos para la red RTS vuelven a ser muy similares a la red IEEE57. El rango de variación del IDT vuelve a ser parecido a la curva de carga del sistema, realizando un seguimiento en la gráfica de resultados.

En la tabla 4.26 se muestran los valores numéricos para esta red.

Hora	IDT
1	0,0090518
2	0,0098471
3	0,010416
4	0,010694
5	0,01077
6	0,010477
7	0,0082608
8	0,0092582
9	0,012197
10	0,013051
11	0,012625
12	0,012138
13	0,012109
14	0,012334
15	0,011337
16	0,011515
17	0,013585
18	0,014099
19	0,014231
20	0,012263
21	0,010796
22	0,0087074
23	0,0083454
24	0,0097092

Tabla 4.26 Índices de desviación de tensión para la red RTS y un periodo de 24 horas




Figura 4.36 Conjunto de IDT's de la red RTS en un periodo de 24 horas

Posición de las tomas de los transformadores

Los resultados obtenidos vuelven a ser muy similares a la red IEEE57, es decir, las tomas varían constantemente para ajustar los valores de la tensión según la indicación de alcanzar la tensión nominal del sistema

La figura 4.36 muestra el conjunto de estados por los que pasa cada transformador en un periodo de 24 horas. La tabla 4.27 y tabla 4.28 contienen los datos numéricos relativos a la variación de las tomas. Se puede observar como existen algunos transformadores que varían constantemente su toma para ajustar el nivel de tensión en función de la carga, mientras que otros no se ven prácticamente afectados.

Desde la tabla 4.29 a la tabla 4.32 se presentan los datos reales sobre el estado de cargas correspondiente a un día completo (24 horas) tanto para la potencia activa como reactiva.

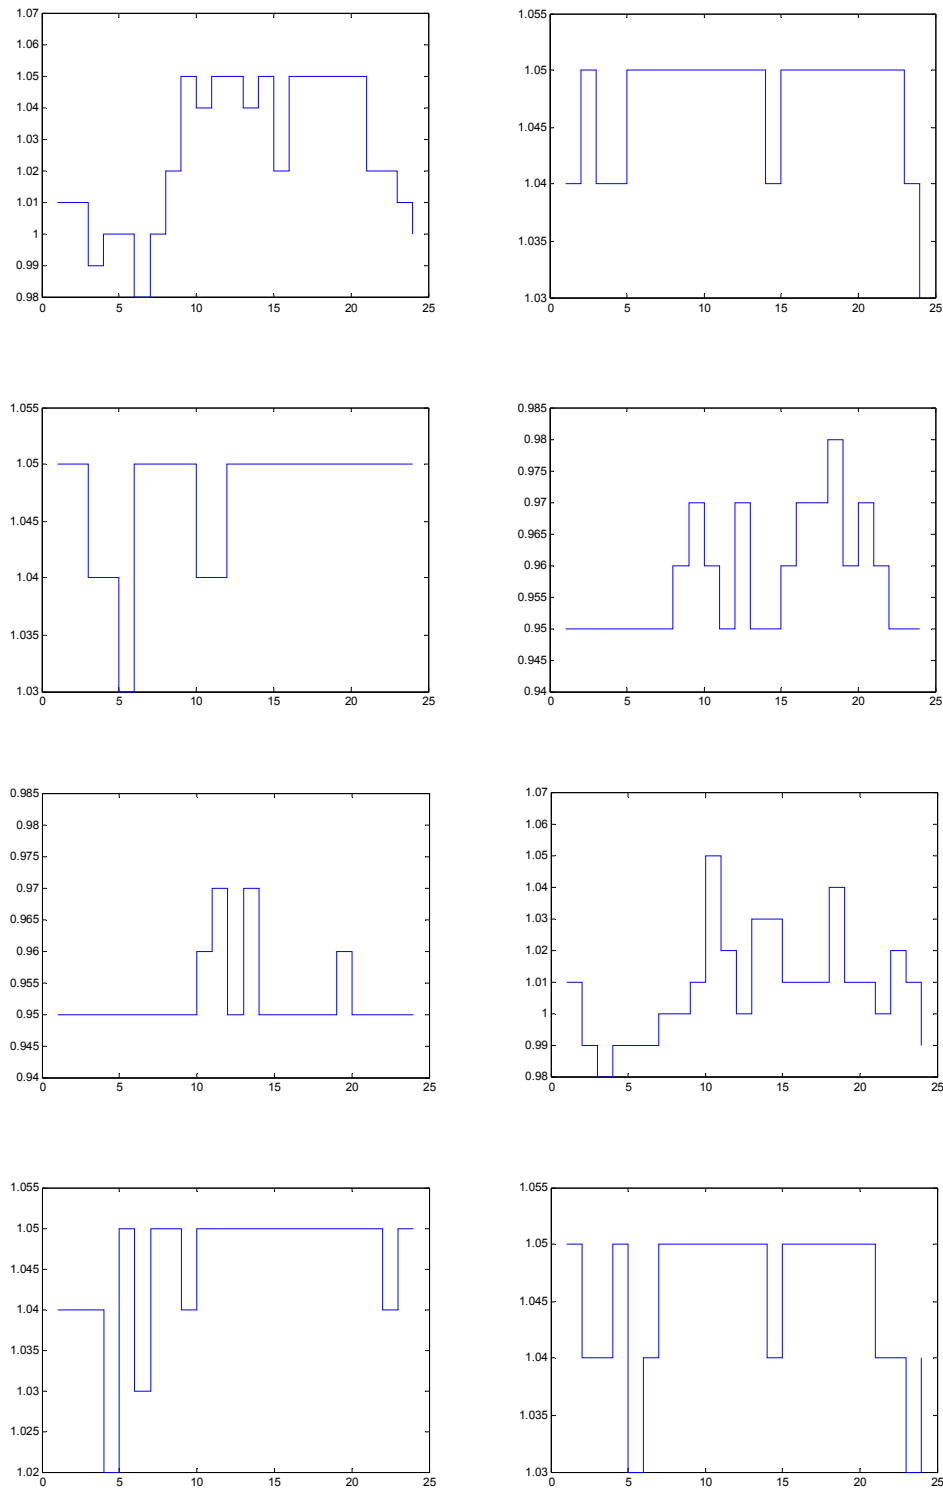


Figura 4.37 Representación gráfica de las tomas para la red RTS en un periodo de 24 horas (I)

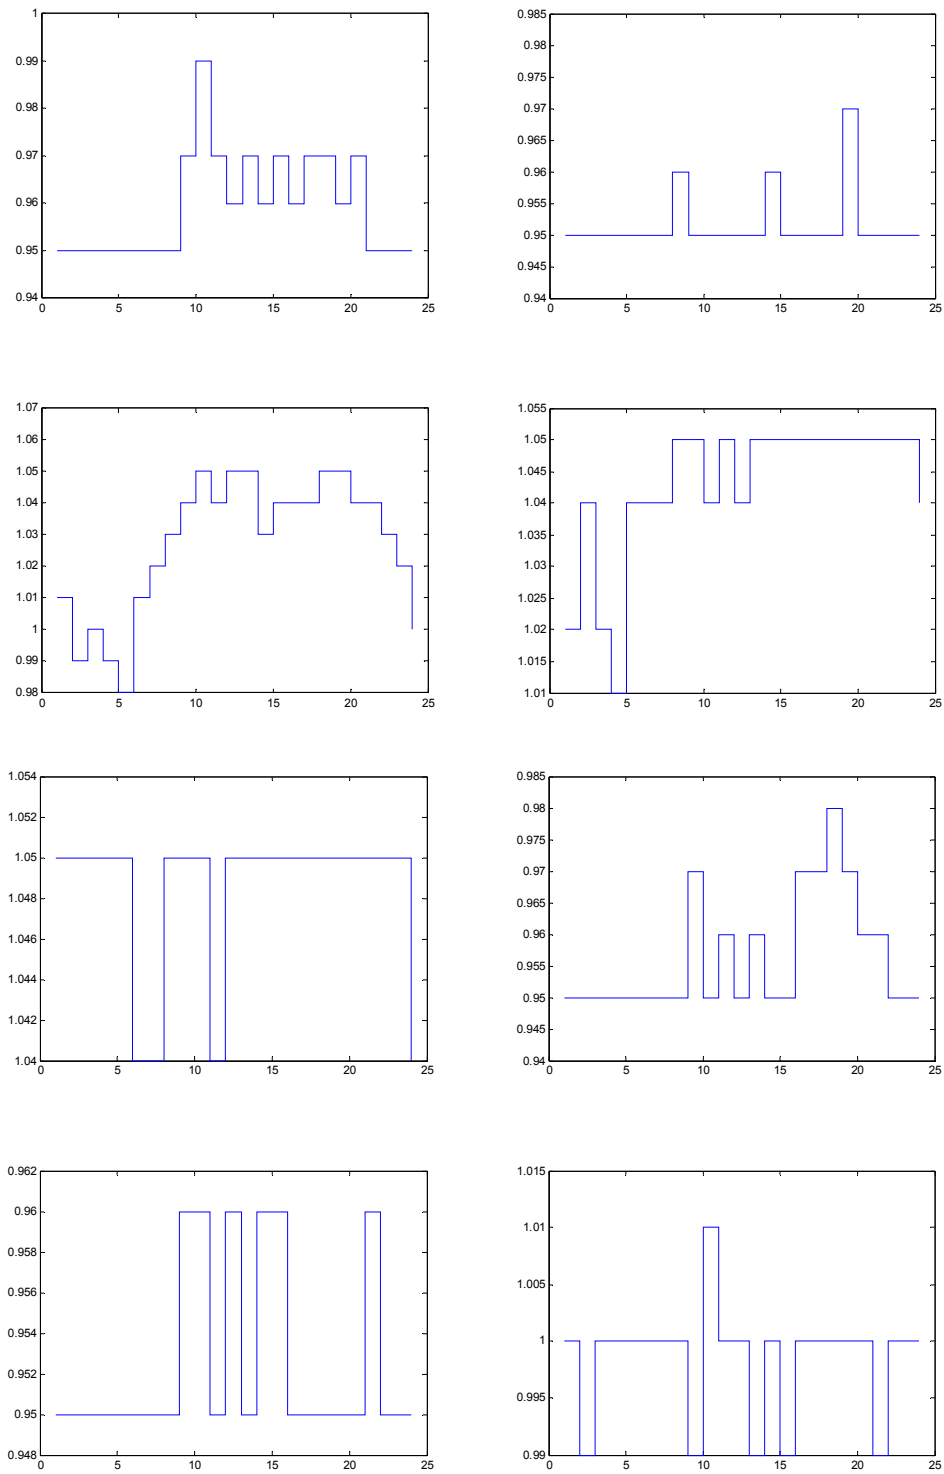


Figura 4.38 Representación gráfica de las tomas para la red RTS en un periodo de 24 horas (II)

Trafo	Hora 1	Hora 2	Hora 3	Hora 4	Hora 5	Hora 6	Hora 7	Hora 8	Hora 9	Hora 10	Hora 11	Hora 12
1	1%	1%	-1%	0%	0%	-2%	0%	2%	5%	4%	5%	5%
2	4%	5%	4%	4%	5%	5%	5%	5%	5%	5%	5%	5%
3	5%	5%	4%	4%	3%	5%	5%	5%	5%	4%	4%	5%
4	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-4%	-3%	-4%	-5%	-3%
5	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-4%	-3%	-5%
6	1%	-1%	-2%	-1%	-1%	-1%	0%	0%	1%	5%	2%	0%
7	4%	4%	4%	2%	5%	3%	5%	5%	4%	5%	5%	5%
8	5%	4%	4%	5%	3%	4%	5%	5%	5%	5%	5%	5%
9	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-3%	-1%	-3%	-4%
10	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-4%	-5%	-5%	-5%	-5%
11	1%	-1%	0%	-1%	-2%	1%	2%	3%	4%	5%	4%	5%
12	2%	4%	2%	1%	4%	4%	4%	5%	5%	4%	5%	4%
13	5%	5%	5%	5%	5%	4%	4%	5%	5%	5%	4%	5%
14	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-3%	-5%	-4%	-5%
15	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-5%	-4%	-4%	-5%	-4%
16	0%	-1%	0%	0%	0%	0%	0%	0%	-1%	1%	0%	0%

Tabla 4.27 Posición de las tomas de los cambiadores para la red RTS en un periodo de 24 horas (I)

Trafo	Hora 13	Hora 14	Hora 15	Hora 16	Hora 17	Hora 18	Hora 19	Hora 20	Hora 21	Hora 22	Hora 23	Hora 24
1	4%	5%	2%	5%	5%	5%	5%	5%	2%	2%	1%	0%
2	5%	4%	5%	5%	5%	5%	5%	5%	5%	5%	4%	3%
3	5%	5%	5%	5%	5%	5%	5%	5%	5%	5%	5%	5%
4	-5%	-5%	-4%	-3%	-3%	-2%	-4%	-3%	-4%	-5%	-5%	-5%
5	-3%	-5%	-5%	-5%	-5%	-5%	-4%	-5%	-5%	-5%	-5%	-5%
6	3%	3%	1%	1%	1%	4%	1%	1%	0%	2%	1%	-1%
7	5%	5%	5%	5%	5%	5%	5%	5%	5%	4%	5%	5%
8	5%	4%	5%	5%	5%	5%	5%	5%	4%	4%	3%	4%
9	-3%	-4%	-3%	-4%	-3%	-3%	-4%	-3%	-5%	-5%	-5%	-5%
10	-5%	-4%	-5%	-5%	-5%	-5%	-3%	-5%	-5%	-5%	-5%	-5%
11	5%	3%	4%	4%	4%	5%	5%	4%	4%	3%	2%	0%
12	5%	5%	5%	5%	5%	5%	5%	5%	5%	5%	5%	4%
13	5%	5%	5%	5%	5%	5%	5%	5%	5%	5%	5%	4%
14	-4%	-5%	-5%	-3%	-3%	-2%	-3%	-4%	-4%	-5%	-5%	-5%
15	-5%	-4%	-4%	-5%	-5%	-5%	-5%	-5%	-4%	-5%	-5%	-5%
16	-1%	0%	-1%	0%	0%	0%	0%	0%	-1%	0%	0%	0%

Tabla 4.28 Posición de las tomas de los cambiadores para la red RTS en un periodo de 24 horas (II)

Nudo	Tipo	Potencia Activa (MW)											
		Hora 1	Hora 2	Hora 3	Hora 4	Hora 5	Hora 6	Hora 7	Hora 8	Hora 9	Hora 10	Hora 11	Hora 12
		1	2	72,36	68,04	64,8	63,72	63,72	64,8	79,92	92,88	102,6	103,68
2	2	64,99	61,11	58,2	57,23	57,23	58,2	71,78	83,42	92,15	93,12	93,12	92,15
3	1	120,6	113,4	108	106,2	106,2	108	133,2	154,8	171	172,8	172,8	171
4	1	49,58	46,62	44,4	43,66	43,66	44,4	54,76	63,64	70,3	71,04	71,04	70,3
5	1	47,57	44,73	42,6	41,89	41,89	42,6	52,54	61,06	67,45	68,16	68,16	67,45
6	1	91,12	85,68	81,6	80,24	80,24	81,6	100,64	116,96	129,2	130,56	130,56	129,2
7	2	83,75	78,75	75	73,75	73,75	75	92,5	107,5	118,75	120	120	118,75
8	1	114,57	107,73	102,6	100,89	100,89	102,6	126,54	147,06	162,45	164,16	164,16	162,45
9	1	117,25	110,25	105	103,25	103,25	105	129,5	150,5	166,25	168	168	166,25
10	1	130,65	122,85	117	115,05	115,05	117	144,3	167,7	185,25	187,2	187,2	185,25
11	1	0	0	0	0	0	0	0	0	0	0	0	0
12	1	0	0	0	0	0	0	0	0	0	0	0	0
13	3	201	189	180	177	177	180	222	258	285	288	288	285
14	2	129,98	122,22	116,4	114,46	114,46	116,4	143,56	166,84	184,3	186,24	186,24	184,3
15	2	212,39	199,71	190,2	187,03	187,03	190,2	234,58	272,62	301,15	304,32	304,32	301,15
16	2	67	63	60	59	59	60	74	86	95	96	96	95
17	1	0	0	0	0	0	0	0	0	0	0	0	0
18	2	223,11	209,79	199,8	196,47	196,47	199,8	246,42	286,38	316,35	319,68	319,68	316,35
19	1	121,27	114,03	108,6	106,79	106,79	108,6	133,94	155,66	171,95	173,76	173,76	171,95
20	1	85,76	80,64	76,8	75,52	75,52	76,8	94,72	110,08	121,6	122,88	122,88	121,6
21	2	0	0	0	0	0	0	0	0	0	0	0	0
22	2	0	0	0	0	0	0	0	0	0	0	0	0
23	2	0	0	0	0	0	0	0	0	0	0	0	0
24	1	0	0	0	0	0	0	0	0	0	0	0	0

25	2	72,36	68,04	64,8	63,72	63,72	64,8	79,92	92,88	102,6	103,68	103,68	102,6
26	2	64,99	61,11	58,2	57,23	57,23	58,2	71,78	83,42	92,15	93,12	93,12	92,15
27	1	120,6	113,4	108	106,2	106,2	108	133,2	154,8	171	172,8	172,8	171
28	1	49,58	46,62	44,4	43,66	43,66	44,4	54,76	63,64	70,3	71,04	71,04	70,3
29	1	47,57	44,73	42,6	41,89	41,89	42,6	52,54	61,06	67,45	68,16	68,16	67,45
30	1	91,12	85,68	81,6	80,24	80,24	81,6	100,64	116,96	129,2	130,56	130,56	129,2
31	2	83,75	78,75	75	73,75	73,75	75	92,5	107,5	118,75	120	120	118,75
32	1	114,57	107,73	102,6	100,89	100,89	102,6	126,54	147,06	162,45	164,16	164,16	162,45
33	1	117,25	110,25	105	103,25	103,25	105	129,5	150,5	166,25	168	168	166,25
34	1	130,65	122,85	117	115,05	115,05	117	144,3	167,7	185,25	187,2	187,2	185,25
35	1	0	0	0	0	0	0	0	0	0	0	0	0
36	1	0	0	0	0	0	0	0	0	0	0	0	0
37	2	177,55	166,95	159	156,35	156,35	159	196,1	227,9	251,75	254,4	254,4	251,75
38	2	129,98	122,22	116,4	114,46	114,46	116,4	143,56	166,84	184,3	186,24	186,24	184,3
39	2	212,39	199,71	190,2	187,03	187,03	190,2	234,58	272,62	301,15	304,32	304,32	301,15
40	2	67	63	60	59	59	60	74	86	95	96	96	95
41	1	0	0	0	0	0	0	0	0	0	0	0	0
42	2	223,11	209,79	199,8	196,47	196,47	199,8	246,42	286,38	316,35	319,68	319,68	316,35
43	1	121,27	114,03	108,6	106,79	106,79	108,6	133,94	155,66	171,95	173,76	173,76	171,95
44	1	85,76	80,64	76,8	75,52	75,52	76,8	94,72	110,08	121,6	122,88	122,88	121,6
45	2	0	0	0	0	0	0	0	0	0	0	0	0
46	2	0	0	0	0	0	0	0	0	0	0	0	0
47	2	0	0	0	0	0	0	0	0	0	0	0	0
48	1	0	0	0	0	0	0	0	0	0	0	0	0
49	2	72,36	68,04	64,8	63,72	63,72	64,8	79,92	92,88	102,6	103,68	103,68	102,6
50	2	64,99	61,11	58,2	57,23	57,23	58,2	71,78	83,42	92,15	93,12	93,12	92,15
51	1	120,6	113,4	108	106,2	106,2	108	133,2	154,8	171	172,8	172,8	171
52	1	49,58	46,62	44,4	43,66	43,66	44,4	54,76	63,64	70,3	71,04	71,04	70,3

53	1	47,57	44,73	42,6	41,89	41,89	42,6	52,54	61,06	67,45	68,16	68,16	67,45
54	1	91,12	85,68	81,6	80,24	80,24	81,6	100,64	116,96	129,2	130,56	130,56	129,2
55	2	83,75	78,75	75	73,75	73,75	75	92,5	107,5	118,75	120	120	118,75
56	1	114,57	107,73	102,6	100,89	100,89	102,6	126,54	147,06	162,45	164,16	164,16	162,45
57	1	117,25	110,25	105	103,25	103,25	105	129,5	150,5	166,25	168	168	166,25
58	1	130,65	122,85	117	115,05	115,05	117	144,3	167,7	185,25	187,2	187,2	185,25
59	1	0	0	0	0	0	0	0	0	0	0	0	0
60	1	0	0	0	0	0	0	0	0	0	0	0	0
61	2	177,55	166,95	159	156,35	156,35	159	196,1	227,9	251,75	254,4	254,4	251,75
62	2	129,98	122,22	116,4	114,46	114,46	116,4	143,56	166,84	184,3	186,24	186,24	184,3
63	2	212,39	199,71	190,2	187,03	187,03	190,2	234,58	272,62	301,15	304,32	304,32	301,15
64	2	67	63	60	59	59	60	74	86	95	96	96	95
65	1	0	0	0	0	0	0	0	0	0	0	0	0
66	2	223,11	209,79	199,8	196,47	196,47	199,8	246,42	286,38	316,35	319,68	319,68	316,35
67	1	121,27	114,03	108,6	106,79	106,79	108,6	133,94	155,66	171,95	173,76	173,76	171,95
68	1	85,76	80,64	76,8	75,52	75,52	76,8	94,72	110,08	121,6	122,88	122,88	121,6
69	2	0	0	0	0	0	0	0	0	0	0	0	0
70	2	0	0	0	0	0	0	0	0	0	0	0	0
71	2	0	0	0	0	0	0	0	0	0	0	0	0
72	1	0	0	0	0	0	0	0	0	0	0	0	0
73	1	0	0	0	0	0	0	0	0	0	0	0	0

Tabla 4.29 Situación de cargas para la red RTS en un periodo de 24 horas (I)

Nudo	Tipo	Potencia Activa (MW)											
		Hora 13	Hora 14	Hora 15	Hora 16	Hora 17	Hora 18	Hora 19	Hora 20	Hora 21	Hora 22	Hora 23	Hora 24
1	2	102,6	102,6	100,44	101,52	106,92	108	108	103,68	98,28	89,64	78,84	68,04
2	2	92,15	92,15	90,21	91,18	96,03	97	97	93,12	88,27	80,51	70,81	61,11
3	1	171	171	167,4	169,2	178,2	180	180	172,8	163,8	149,4	131,4	113,4
4	1	70,3	70,3	68,82	69,56	73,26	74	74	71,04	67,34	61,42	54,02	46,62
5	1	67,45	67,45	66,03	66,74	70,29	71	71	68,16	64,61	58,93	51,83	44,73
6	1	129,2	129,2	126,48	127,84	134,64	136	136	130,56	123,76	112,88	99,28	85,68
7	2	118,75	118,75	116,25	117,5	123,75	125	125	120	113,75	103,75	91,25	78,75
8	1	162,45	162,45	159,03	160,74	169,29	171	171	164,16	155,61	141,93	124,83	107,73
9	1	166,25	166,25	162,75	164,5	173,25	175	175	168	159,25	145,25	127,75	110,25
10	1	185,25	185,25	181,35	183,3	193,05	195	195	187,2	177,45	161,85	142,35	122,85
11	1	0	0	0	0	0	0	0	0	0	0	0	0
12	1	0	0	0	0	0	0	0	0	0	0	0	0
13	3	285	285	279	282	297	300	300	288	273	249	219	189
14	2	184,3	184,3	180,42	182,36	192,06	194	194	186,24	176,54	161,02	141,62	122,22
15	2	301,15	301,15	294,81	297,98	313,83	317	317	304,32	288,47	263,11	231,41	199,71
16	2	95	95	93	94	99	100	100	96	91	83	73	63
17	1	0	0	0	0	0	0	0	0	0	0	0	0
18	2	316,35	316,35	309,69	313,02	329,67	333	333	319,68	303,03	276,39	243,09	209,79
19	1	171,95	171,95	168,33	170,14	179,19	181	181	173,76	164,71	150,23	132,13	114,03
20	1	121,6	121,6	119,04	120,32	126,72	128	128	122,88	116,48	106,24	93,44	80,64
21	2	0	0	0	0	0	0	0	0	0	0	0	0
22	2	0	0	0	0	0	0	0	0	0	0	0	0
23	2	0	0	0	0	0	0	0	0	0	0	0	0
24	1	0	0	0	0	0	0	0	0	0	0	0	0
25	2	102,6	102,6	100,44	101,52	106,92	108	108	103,68	98,28	89,64	78,84	68,04
26	2	92,15	92,15	90,21	91,18	96,03	97	97	93,12	88,27	80,51	70,81	61,11

27	1	171	171	167,4	169,2	178,2	180	180	172,8	163,8	149,4	131,4	113,4
28	1	70,3	70,3	68,82	69,56	73,26	74	74	71,04	67,34	61,42	54,02	46,62
29	1	67,45	67,45	66,03	66,74	70,29	71	71	68,16	64,61	58,93	51,83	44,73
30	1	129,2	129,2	126,48	127,84	134,64	136	136	130,56	123,76	112,88	99,28	85,68
31	2	118,75	118,75	116,25	117,5	123,75	125	125	120	113,75	103,75	91,25	78,75
32	1	162,45	162,45	159,03	160,74	169,29	171	171	164,16	155,61	141,93	124,83	107,73
33	1	166,25	166,25	162,75	164,5	173,25	175	175	168	159,25	145,25	127,75	110,25
34	1	185,25	185,25	181,35	183,3	193,05	195	195	187,2	177,45	161,85	142,35	122,85
35	1	0	0	0	0	0	0	0	0	0	0	0	0
36	1	0	0	0	0	0	0	0	0	0	0	0	0
37	2	251,75	251,75	246,45	249,1	262,35	265	265	254,4	241,15	219,95	193,45	166,95
38	2	184,3	184,3	180,42	182,36	192,06	194	194	186,24	176,54	161,02	141,62	122,22
39	2	301,15	301,15	294,81	297,98	313,83	317	317	304,32	288,47	263,11	231,41	199,71
40	2	95	95	93	94	99	100	100	96	91	83	73	63
41	1	0	0	0	0	0	0	0	0	0	0	0	0
42	2	316,35	316,35	309,69	313,02	329,67	333	333	319,68	303,03	276,39	243,09	209,79
43	1	171,95	171,95	168,33	170,14	179,19	181	181	173,76	164,71	150,23	132,13	114,03
44	1	121,6	121,6	119,04	120,32	126,72	128	128	122,88	116,48	106,24	93,44	80,64
45	2	0	0	0	0	0	0	0	0	0	0	0	0
46	2	0	0	0	0	0	0	0	0	0	0	0	0
47	2	0	0	0	0	0	0	0	0	0	0	0	0
48	1	0	0	0	0	0	0	0	0	0	0	0	0
49	2	102,6	102,6	100,44	101,52	106,92	108	108	103,68	98,28	89,64	78,84	68,04
50	2	92,15	92,15	90,21	91,18	96,03	97	97	93,12	88,27	80,51	70,81	61,11
51	1	171	171	167,4	169,2	178,2	180	180	172,8	163,8	149,4	131,4	113,4
52	1	70,3	70,3	68,82	69,56	73,26	74	74	71,04	67,34	61,42	54,02	46,62
53	1	67,45	67,45	66,03	66,74	70,29	71	71	68,16	64,61	58,93	51,83	44,73
54	1	129,2	129,2	126,48	127,84	134,64	136	136	130,56	123,76	112,88	99,28	85,68

55	2	118,75	118,75	116,25	117,5	123,75	125	125	120	113,75	103,75	91,25	78,75
56	1	162,45	162,45	159,03	160,74	169,29	171	171	164,16	155,61	141,93	124,83	107,73
57	1	166,25	166,25	162,75	164,5	173,25	175	175	168	159,25	145,25	127,75	110,25
58	1	185,25	185,25	181,35	183,3	193,05	195	195	187,2	177,45	161,85	142,35	122,85
59	1	0	0	0	0	0	0	0	0	0	0	0	0
60	1	0	0	0	0	0	0	0	0	0	0	0	0
61	2	251,75	251,75	246,45	249,1	262,35	265	265	254,4	241,15	219,95	193,45	166,95
62	2	184,3	184,3	180,42	182,36	192,06	194	194	186,24	176,54	161,02	141,62	122,22
63	2	301,15	301,15	294,81	297,98	313,83	317	317	304,32	288,47	263,11	231,41	199,71
64	2	95	95	93	94	99	100	100	96	91	83	73	63
65	1	0	0	0	0	0	0	0	0	0	0	0	0
66	2	316,35	316,35	309,69	313,02	329,67	333	333	319,68	303,03	276,39	243,09	209,79
67	1	171,95	171,95	168,33	170,14	179,19	181	181	173,76	164,71	150,23	132,13	114,03
68	1	121,6	121,6	119,04	120,32	126,72	128	128	122,88	116,48	106,24	93,44	80,64
69	2	0	0	0	0	0	0	0	0	0	0	0	0
70	2	0	0	0	0	0	0	0	0	0	0	0	0
71	2	0	0	0	0	0	0	0	0	0	0	0	0
72	1	0	0	0	0	0	0	0	0	0	0	0	0
73	1	0	0	0	0	0	0	0	0	0	0	0	0

Tabla 4.30 Situación de cargas para la red RTS en un periodo de 24 horas (II)

Nudo	Tipo	Potencia Reactiva (MVar)											
		Hora 1	Hora 2	Hora 3	Hora 4	Hora 5	Hora 6	Hora 7	Hora 8	Hora 9	Hora 10	Hora 11	Hora 12
		1	2	14,74	13,86	13,2	12,98	12,98	13,2	16,28	18,92	20,9	21,12
2	2	13,4	12,6	12	11,8	11,8	12	14,8	17,2	19	19,2	19,2	19
3	1	24,79	23,31	22,2	21,83	21,83	22,2	27,38	31,82	35,15	35,52	35,52	35,15
4	1	10,05	9,45	9	8,85	8,85	9	11,1	12,9	14,25	14,4	14,4	14,25
5	1	9,38	8,82	8,4	8,26	8,26	8,4	10,36	12,04	13,3	13,44	13,44	13,3
6	1	18,76	17,64	16,8	16,52	16,52	16,8	20,72	24,08	26,6	26,88	26,88	26,6
7	2	16,75	15,75	15	14,75	14,75	15	18,5	21,5	23,75	24	24	23,75
8	1	23,45	22,05	21	20,65	20,65	21	25,9	30,1	33,25	33,6	33,6	33,25
9	1	24,12	22,68	21,6	21,24	21,24	21,6	26,64	30,96	34,2	34,56	34,56	34,2
10	1	26,8	25,2	24	23,6	23,6	24	29,6	34,4	38	38,4	38,4	38
11	1	0	0	0	0	0	0	0	0	0	0	0	0
12	1	0	0	0	0	0	0	0	0	0	0	0	0
13	3	36,18	34,02	32,4	31,86	31,86	32,4	39,96	46,44	51,3	51,84	51,84	51,3
14	2	26,13	24,57	23,4	23,01	23,01	23,4	28,86	33,54	37,05	37,44	37,44	37,05
15	2	42,88	40,32	38,4	37,76	37,76	38,4	47,36	55,04	60,8	61,44	61,44	60,8
16	2	13,4	12,6	12	11,8	11,8	12	14,8	17,2	19	19,2	19,2	19
17	1	0	0	0	0	0	0	0	0	0	0	0	0
18	2	45,56	42,84	40,8	40,12	40,12	40,8	50,32	58,48	64,6	65,28	65,28	64,6
19	1	24,79	23,31	22,2	21,83	21,83	22,2	27,38	31,82	35,15	35,52	35,52	35,15
20	1	17,42	16,38	15,6	15,34	15,34	15,6	19,24	22,36	24,7	24,96	24,96	24,7
21	2	0	0	0	0	0	0	0	0	0	0	0	0
22	2	0	0	0	0	0	0	0	0	0	0	0	0
23	2	0	0	0	0	0	0	0	0	0	0	0	0
24	1	0	0	0	0	0	0	0	0	0	0	0	0

25	2	14,74	13,86	13,2	12,98	12,98	13,2	16,28	18,92	20,9	21,12	21,12	20,9
26	2	13,4	12,6	12	11,8	11,8	12	14,8	17,2	19	19,2	19,2	19
27	1	24,79	23,31	22,2	21,83	21,83	22,2	27,38	31,82	35,15	35,52	35,52	35,15
28	1	10,05	9,45	9	8,85	8,85	9	11,1	12,9	14,25	14,4	14,4	14,25
29	1	9,38	8,82	8,4	8,26	8,26	8,4	10,36	12,04	13,3	13,44	13,44	13,3
30	1	18,76	17,64	16,8	16,52	16,52	16,8	20,72	24,08	26,6	26,88	26,88	26,6
31	2	16,75	15,75	15	14,75	14,75	15	18,5	21,5	23,75	24	24	23,75
32	1	23,45	22,05	21	20,65	20,65	21	25,9	30,1	33,25	33,6	33,6	33,25
33	1	24,12	22,68	21,6	21,24	21,24	21,6	26,64	30,96	34,2	34,56	34,56	34,2
34	1	26,8	25,2	24	23,6	23,6	24	29,6	34,4	38	38,4	38,4	38
35	1	0	0	0	0	0	0	0	0	0	0	0	0
36	1	0	0	0	0	0	0	0	0	0	0	0	0
37	2	36,18	34,02	32,4	31,86	31,86	32,4	39,96	46,44	51,3	51,84	51,84	51,3
38	2	26,13	24,57	23,4	23,01	23,01	23,4	28,86	33,54	37,05	37,44	37,44	37,05
39	2	42,88	40,32	38,4	37,76	37,76	38,4	47,36	55,04	60,8	61,44	61,44	60,8
40	2	13,4	12,6	12	11,8	11,8	12	14,8	17,2	19	19,2	19,2	19
41	1	0	0	0	0	0	0	0	0	0	0	0	0
42	2	45,56	42,84	40,8	40,12	40,12	40,8	50,32	58,48	64,6	65,28	65,28	64,6
43	1	24,79	23,31	22,2	21,83	21,83	22,2	27,38	31,82	35,15	35,52	35,52	35,15
44	1	17,42	16,38	15,6	15,34	15,34	15,6	19,24	22,36	24,7	24,96	24,96	24,7
45	2	0	0	0	0	0	0	0	0	0	0	0	0
46	2	0	0	0	0	0	0	0	0	0	0	0	0
47	2	0	0	0	0	0	0	0	0	0	0	0	0
48	1	0	0	0	0	0	0	0	0	0	0	0	0
49	2	14,74	13,86	13,2	12,98	12,98	13,2	16,28	18,92	20,9	21,12	21,12	20,9
50	2	13,4	12,6	12	11,8	11,8	12	14,8	17,2	19	19,2	19,2	19
51	1	24,79	23,31	22,2	21,83	21,83	22,2	27,38	31,82	35,15	35,52	35,52	35,15
52	1	10,05	9,45	9	8,85	8,85	9	11,1	12,9	14,25	14,4	14,4	14,25

53	1	9,38	8,82	8,4	8,26	8,26	8,4	10,36	12,04	13,3	13,44	13,44	13,3
54	1	18,76	17,64	16,8	16,52	16,52	16,8	20,72	24,08	26,6	26,88	26,88	26,6
55	2	16,75	15,75	15	14,75	14,75	15	18,5	21,5	23,75	24	24	23,75
56	1	23,45	22,05	21	20,65	20,65	21	25,9	30,1	33,25	33,6	33,6	33,25
57	1	24,12	22,68	21,6	21,24	21,24	21,6	26,64	30,96	34,2	34,56	34,56	34,2
58	1	26,8	25,2	24	23,6	23,6	24	29,6	34,4	38	38,4	38,4	38
59	1	0	0	0	0	0	0	0	0	0	0	0	0
60	1	0	0	0	0	0	0	0	0	0	0	0	0
61	2	36,18	34,02	32,4	31,86	31,86	32,4	39,96	46,44	51,3	51,84	51,84	51,3
62	2	26,13	24,57	23,4	23,01	23,01	23,4	28,86	33,54	37,05	37,44	37,44	37,05
63	2	42,88	40,32	38,4	37,76	37,76	38,4	47,36	55,04	60,8	61,44	61,44	60,8
64	2	13,4	12,6	12	11,8	11,8	12	14,8	17,2	19	19,2	19,2	19
65	1	0	0	0	0	0	0	0	0	0	0	0	0
66	2	45,56	42,84	40,8	40,12	40,12	40,8	50,32	58,48	64,6	65,28	65,28	64,6
67	1	24,79	23,31	22,2	21,83	21,83	22,2	27,38	31,82	35,15	35,52	35,52	35,15
68	1	17,42	16,38	15,6	15,34	15,34	15,6	19,24	22,36	24,7	24,96	24,96	24,7
69	2	0	0	0	0	0	0	0	0	0	0	0	0
70	2	0	0	0	0	0	0	0	0	0	0	0	0
71	2	0	0	0	0	0	0	0	0	0	0	0	0
72	1	0	0	0	0	0	0	0	0	0	0	0	0
73	1	0	0	0	0	0	0	0	0	0	0	0	0

Tabla 4.31 Situación de cargas para la red RTS en un periodo de 24 horas (III)

Nudo	Tipo	Potencia Reactiva (MVar)											
		Hora 13	Hora 14	Hora 15	Hora 16	Hora 17	Hora 18	Hora 19	Hora 20	Hora 21	Hora 22	Hora 23	Hora 24
1	2	20,9	20,9	20,46	20,68	21,78	22	22	21,12	20,02	18,26	16,06	13,86
2	2	19	19	18,6	18,8	19,8	20	20	19,2	18,2	16,6	14,6	12,6
3	1	35,15	35,15	34,41	34,78	36,63	37	37	35,52	33,67	30,71	27,01	23,31
4	1	14,25	14,25	13,95	14,1	14,85	15	15	14,4	13,65	12,45	10,95	9,45
5	1	13,3	13,3	13,02	13,16	13,86	14	14	13,44	12,74	11,62	10,22	8,82
6	1	26,6	26,6	26,04	26,32	27,72	28	28	26,88	25,48	23,24	20,44	17,64
7	2	23,75	23,75	23,25	23,5	24,75	25	25	24	22,75	20,75	18,25	15,75
8	1	33,25	33,25	32,55	32,9	34,65	35	35	33,6	31,85	29,05	25,55	22,05
9	1	34,2	34,2	33,48	33,84	35,64	36	36	34,56	32,76	29,88	26,28	22,68
10	1	38	38	37,2	37,6	39,6	40	40	38,4	36,4	33,2	29,2	25,2
11	1	0	0	0	0	0	0	0	0	0	0	0	0
12	1	0	0	0	0	0	0	0	0	0	0	0	0
13	3	51,3	51,3	50,22	50,76	53,46	54	54	51,84	49,14	44,82	39,42	34,02
14	2	37,05	37,05	36,27	36,66	38,61	39	39	37,44	35,49	32,37	28,47	24,57
15	2	60,8	60,8	59,52	60,16	63,36	64	64	61,44	58,24	53,12	46,72	40,32
16	2	19	19	18,6	18,8	19,8	20	20	19,2	18,2	16,6	14,6	12,6
17	1	0	0	0	0	0	0	0	0	0	0	0	0
18	2	64,6	64,6	63,24	63,92	67,32	68	68	65,28	61,88	56,44	49,64	42,84
19	1	35,15	35,15	34,41	34,78	36,63	37	37	35,52	33,67	30,71	27,01	23,31
20	1	24,7	24,7	24,18	24,44	25,74	26	26	24,96	23,66	21,58	18,98	16,38
21	2	0	0	0	0	0	0	0	0	0	0	0	0
22	2	0	0	0	0	0	0	0	0	0	0	0	0
23	2	0	0	0	0	0	0	0	0	0	0	0	0
24	1	0	0	0	0	0	0	0	0	0	0	0	0
25	2	20,9	20,9	20,46	20,68	21,78	22	22	21,12	20,02	18,26	16,06	13,86
26	2	19	19	18,6	18,8	19,8	20	20	19,2	18,2	16,6	14,6	12,6

27	1	35,15	35,15	34,41	34,78	36,63	37	37	35,52	33,67	30,71	27,01	23,31
28	1	14,25	14,25	13,95	14,1	14,85	15	15	14,4	13,65	12,45	10,95	9,45
29	1	13,3	13,3	13,02	13,16	13,86	14	14	13,44	12,74	11,62	10,22	8,82
30	1	26,6	26,6	26,04	26,32	27,72	28	28	26,88	25,48	23,24	20,44	17,64
31	2	23,75	23,75	23,25	23,5	24,75	25	25	24	22,75	20,75	18,25	15,75
32	1	33,25	33,25	32,55	32,9	34,65	35	35	33,6	31,85	29,05	25,55	22,05
33	1	34,2	34,2	33,48	33,84	35,64	36	36	34,56	32,76	29,88	26,28	22,68
34	1	38	38	37,2	37,6	39,6	40	40	38,4	36,4	33,2	29,2	25,2
35	1	0	0	0	0	0	0	0	0	0	0	0	0
36	1	0	0	0	0	0	0	0	0	0	0	0	0
37	2	51,3	51,3	50,22	50,76	53,46	54	54	51,84	49,14	44,82	39,42	34,02
38	2	37,05	37,05	36,27	36,66	38,61	39	39	37,44	35,49	32,37	28,47	24,57
39	2	60,8	60,8	59,52	60,16	63,36	64	64	61,44	58,24	53,12	46,72	40,32
40	2	19	19	18,6	18,8	19,8	20	20	19,2	18,2	16,6	14,6	12,6
41	1	0	0	0	0	0	0	0	0	0	0	0	0
42	2	64,6	64,6	63,24	63,92	67,32	68	68	65,28	61,88	56,44	49,64	42,84
43	1	35,15	35,15	34,41	34,78	36,63	37	37	35,52	33,67	30,71	27,01	23,31
44	1	24,7	24,7	24,18	24,44	25,74	26	26	24,96	23,66	21,58	18,98	16,38
45	2	0	0	0	0	0	0	0	0	0	0	0	0
46	2	0	0	0	0	0	0	0	0	0	0	0	0
47	2	0	0	0	0	0	0	0	0	0	0	0	0
48	1	0	0	0	0	0	0	0	0	0	0	0	0
49	2	20,9	20,9	20,46	20,68	21,78	22	22	21,12	20,02	18,26	16,06	13,86
50	2	19	19	18,6	18,8	19,8	20	20	19,2	18,2	16,6	14,6	12,6
51	1	35,15	35,15	34,41	34,78	36,63	37	37	35,52	33,67	30,71	27,01	23,31
52	1	14,25	14,25	13,95	14,1	14,85	15	15	14,4	13,65	12,45	10,95	9,45
53	1	13,3	13,3	13,02	13,16	13,86	14	14	13,44	12,74	11,62	10,22	8,82
54	1	26,6	26,6	26,04	26,32	27,72	28	28	26,88	25,48	23,24	20,44	17,64

55	2	23,75	23,75	23,25	23,5	24,75	25	25	24	22,75	20,75	18,25	15,75
56	1	33,25	33,25	32,55	32,9	34,65	35	35	33,6	31,85	29,05	25,55	22,05
57	1	34,2	34,2	33,48	33,84	35,64	36	36	34,56	32,76	29,88	26,28	22,68
58	1	38	38	37,2	37,6	39,6	40	40	38,4	36,4	33,2	29,2	25,2
59	1	0	0	0	0	0	0	0	0	0	0	0	0
60	1	0	0	0	0	0	0	0	0	0	0	0	0
61	2	51,3	51,3	50,22	50,76	53,46	54	54	51,84	49,14	44,82	39,42	34,02
62	2	37,05	37,05	36,27	36,66	38,61	39	39	37,44	35,49	32,37	28,47	24,57
63	2	60,8	60,8	59,52	60,16	63,36	64	64	61,44	58,24	53,12	46,72	40,32
64	2	19	19	18,6	18,8	19,8	20	20	19,2	18,2	16,6	14,6	12,6
65	1	0	0	0	0	0	0	0	0	0	0	0	0
66	2	64,6	64,6	63,24	63,92	67,32	68	68	65,28	61,88	56,44	49,64	42,84
67	1	35,15	35,15	34,41	34,78	36,63	37	37	35,52	33,67	30,71	27,01	23,31
68	1	24,7	24,7	24,18	24,44	25,74	26	26	24,96	23,66	21,58	18,98	16,38
69	2	0	0	0	0	0	0	0	0	0	0	0	0
70	2	0	0	0	0	0	0	0	0	0	0	0	0
71	2	0	0	0	0	0	0	0	0	0	0	0	0
72	1	0	0	0	0	0	0	0	0	0	0	0	0
73	1	0	0	0	0	0	0	0	0	0	0	0	0

Tabla 4.32 Situación de cargas para la red RTS en un periodo de 24 horas (IV)

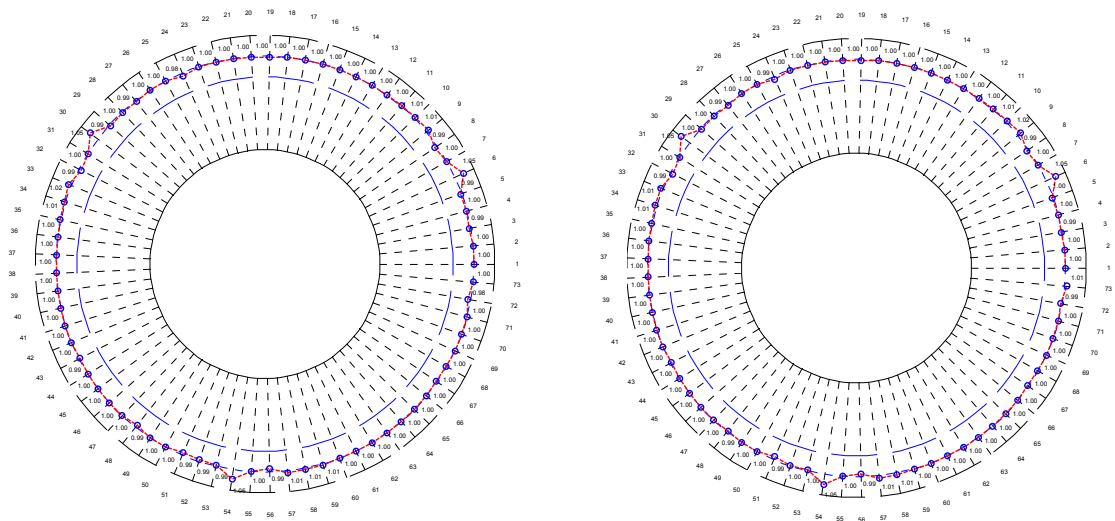
Al igual que en los casos anteriores, la distribución de las tomas no presenta un patrón característico o repetitivo, sino que depende del nivel de cargas asociado a cada nodo de la red. Además, la configuración del sistema y su topología determinan claramente su nivel.

Cabe destacar que los transformadores no llegan a agotar su rango de regulación de manera clara, por lo que se suele mantener un margen para regulación que conviene desde el punto de vista del tratamiento de contingencias.

Nivel de tensión en los nodos


Se vuelve a presentar la distribución de tensiones nodales para el periodo de estudio de 24 horas. Al igual que en el caso de la red IEEE57, las tensiones se mantienen cercanas a la nominal sin llegar a salirse del rango marcado del $\pm 10\%$.

La figura que se muestra a continuación, refleja el panorama de tensiones para la red RTS.




Hora 1


Hora 2




Hora 3




Hora 4




Hora 5




Hora 6




Hora 7




Hora 8




Hora 9




Hora 10




Hora 11




Hora 12




Hora 13




Hora 14




Hora 15




Hora 16




Hora 17




Hora 18




Hora 19




Hora 20




Hora 21



Hora 22



Hora 23



Hora 24

Tiempo de Ejecución

La resolución del problema RTS para un periodo horario de 24 horas, se realiza en un tiempo variable tal y como se muestra en la tabla 4.33, usando la máquina descrita en la tabla 4.5.

Hora	Tiempo (s)
1	111,81
2	101,24
3	147,66
4	144,92
5	82,531
6	86,953
7	93,438
8	148,16
9	73,547
10	55,547
11	73,406
12	106,84
13	70,265
14	71,157
15	91,422
16	117,47
17	134,11
18	93,031
19	131,3

Hora	Tiempo (s)
20	116,08
21	60,656
22	114,94
23	130,5
24	150,66

Tabla 4.33 Tiempos de resolución para cada hora de la red RTS




Figura 4.39 Evolución de la población para un periodo horario cualquiera de la red RTS

Capítulo 5

Aplicación de algoritmos multi-objetivo a la optimización de tensiones

En el capítulo anterior se presentó un algoritmo genético para minimizar el índice de desviación de tensiones mediante la configuración óptima de las tomas de regulación de los transformadores. En este capítulo se presenta una mejora a dicho planteamiento mediante la inclusión de nuevos objetivos a optimizar. En concreto, se añade como objetivo la minimización de las pérdidas de potencia en las líneas eléctricas como consecuencia del flujo de cargas por la red. El planteamiento seguido para llevar a cabo dicha optimización multi-objetivo es el de optimización mediante frentes de Pareto. Tal y como describimos con detalle en el Capítulo 2, se basa en incluir en un algoritmo los mecanismos de selección y almacenamiento de soluciones necesarios para obtener finalmente un conjunto de soluciones no dominadas que optimicen los diferentes objetivos a optimizar. Dichas soluciones no dominadas que constituyen el frente obtenido conforman a su vez la base de trabajo para un posterior análisis, por parte de un responsable o decisor de alto nivel, que pueda plantear una solución adecuada en función de las circunstancias, intereses o condicionantes específicos de la coyuntura en cuestión. Indicar igualmente que, aunque se han añadido nuevos objetivos a optimizar, se han respetado las mismas restricciones que en el caso mono-objetivo.

A la hora de tratar la formulación multi-objetivo de dicho problema es necesario establecer un nuevo planteamiento, no sólo a la hora de evaluar las soluciones obtenidas en ambos objetivos, sino también en lo referente al proceso de selección y almacenamiento de dichas soluciones. Es decir, que mientras que en la versión mono-objetivo del algoritmo genético a cada solución se le aplican los operadores de cruce y mutación, obteniendo una nueva solución que es evaluada en función del índice de desviación de tensión, en el planteamiento multi-objetivo se evalúa también el otro objetivo (pérdida de potencia), y se determina si la nueva solución obtenida domina o es dominada por algunas de las soluciones almacenadas en un archivo de soluciones no dominadas. Dicho archivo externo se irá actualizando continuamente con las soluciones encontradas hasta que el algoritmo finalice, siendo este archivo el conjunto de soluciones no dominadas representativo del frente Pareto-óptimo, que es desconocido.

Cabe destacar que una gran parte de los trabajos previos en el campo de la optimización multi-objetivo han sido tratados mediante funciones agregadas, normalmente basadas en suma de pesos, consistentes en combinar los diferentes objetivos a optimizar en una única función que obtiene como resultado un valor numérico único que describe la calidad de las soluciones encontradas. Pese a que el tratamiento mediante funciones agregadas es muy intuitivo y fácil de implementar, la calidad de resultados obtenidos suele ser baja, principalmente debido a la gran dificultad que conlleva establecer los pesos en dichas funciones agregadas, sobretodo cuando los objetivos a optimizar tienen diferentes escalas. Es por ello, que el planteamiento multi-objetivo basado en frentes de Pareto que se presenta en esta Tesis supone otra aportación importante en el campo de la optimización de redes eléctricas, y complementa a su vez a otras de las pocas investigaciones previas que hacen uso del concepto de optimización de Pareto [Augugliaro 04, Ramos 04, Popovic 99].

Al igual que se planteó en el capítulo referente a algoritmos genéticos, las diferentes versiones de estrategia multi-objetivo presentada a continuación es altamente paralelizable mediante sistemas multiprocesador y será objeto de estudio en futuras investigaciones.

5.1 Estructura y características de los algoritmos multi-objetivo desarrollados

A la hora de optimizar la versión multi-objetivo del problema tratado se han utilizado muchas ideas del algoritmo evolutivo multi-objetivo llamado PAES [Knowles 99] (ver sección 2.4.2.2). Aunque la implementación multi-objetivo ha utilizado la misma estructura de los datos basada en codificación entera utilizada en el algoritmo genético mono-objetivo, son muchas las diferencias entre las implementaciones en ambos casos, como describiremos posteriormente. Debemos indicar que además de la adaptación de PAES al problema multi-objetivo, se han realizado una serie de mejoras a dicho algoritmo que tras ser analizadas empíricamente en las redes de prueba han obtenido frentes de soluciones, en algunos casos, de mayor calidad que las obtenidas por PAES. Algunas de variaciones (Annealing-PAES y Tabu-PAES) fueron propuestas teóricamente por Knowles [Knowles 02], pero no implementadas en ningún problema real, por lo que su implementación y estudio aquí supone otro aspecto innovador a destacar de esta Tesis. La elección de PAES como algoritmo base se ha realizado atendiendo a las siguientes características:

- Utiliza una única solución durante el proceso de búsqueda.
- Utiliza selección basada Pareto dominancia.
- Utiliza un archivo de tamaño limitado para almacenar las soluciones no dominadas.
- Utiliza una técnica de almacenamiento de soluciones basadas en grid (malla).
- Trabaja con un número de parámetros reducido.
- Los requisitos computacionales son inferiores a los algoritmos poblacionales.

Desde el punto de vista de este investigador, esta opción presenta unas interesantes características que hacen viable su uso y exploración. Se deja como un trabajo futuro, el análisis y estudio comparativo con otras técnicas multi-objetivo al objeto de determinar si es posible hallar mejores resultados.

En los siguientes apartados se detalla más en profundidad las características de los algoritmos implementados

5.1.1 Técnica PAES (Pareto Archived Evolution Strategy)

5.1.1.1 Aspectos generales.

La técnica PAES es uno de los primeros MOEA (*Multi Objective Evolutionary Algorithm*) basado en estrategias de evolución y no en algoritmos genéticos. En su forma más simple PAES utiliza una estrategia de evolución de tipo 1+1 (en este tipo de técnicas en cada iteración se usa un padre para crear un hijo mediante el uso de un operador de mutación gaussiano).

Tal vez la principal diferencia visible con respecto a los algoritmos genéticos radica en que PAES es una técnica no poblacional, esto es, está formado por un solo individuo que va evolucionando iteración tras iteración. En cada iteración la solución actual (padre) genera una nueva solución (hijo), de forma que el paso a dar por el algoritmo es seleccionar en función de relaciones de Pareto-dominancia al mejor de entre las soluciones padre e hijo. Es decir, tras generar a la solución hijo se evalúa si dicha solución domina a la solución padre en el sentido de Pareto (si el hijo es mejor en los dos objetivos, o mejor en uno y no peor en el otro), en cuyo caso la solución actual (padre) es sustituida por la solución hijo. En caso contrario la solución padre pasaría a la siguiente evaluación y volvería a evolucionar. Es decir, en cada generación se lleva a cabo un proceso de selección basada en relaciones de Pareto-dominancia que determina cual es la solución más adecuada que debe pasar a evolucionar en la siguiente iteración. Pudiera ocurrir que ambas soluciones fueran indiferentes, esto es, que ninguna dominara a la otra solución. Para este caso, PAES sólo aceptará la solución hijo en caso de que no sea dominada por ninguna otra solución almacenada en el archivo externo de soluciones no dominadas. Para realizar dicha comprobación, PAES implementa una “función de aceptación” que comprueba si la solución mutante o candidata domina dentro de un archivo de soluciones previas, y por tanto, si está en disposición de ser parte de dicho archivo dependiendo de la estrategia de almacenamiento seguida. Si la comprobación es positiva, la solución candidata debe ser insertada en el archivo de soluciones.

Lo anterior implica que PAES debe incorporar una implementación eficiente de almacenamiento. En este trabajo se ha optado por la estrategia de almacenamiento de *malla adaptativa*, debido que es la más eficiente aunque también la más compleja [Knowles 02].

5.1.1.2 Estrategia de almacenamiento

Se ha optado por la estrategia de almacenamiento de malla adaptativa (Adaptive Grid Archiving, AGA), que aunque es una estrategia más complicada que ciertas otras y ha sido la implementada en la práctica debido a las ventajas que a continuación veremos.

Dicho método utiliza un procedimiento “*crowding*” de aglomeración en el espacio de objetivos el cual puede obtener un archivo de puntos limitados y bien distribuidos con un esfuerzo computacional mínimo.

En [Knowles 02] se muestra que, bajo ciertas condiciones, esta estrategia garantiza poblar ciertas regiones en el espacio objetivo, manteniendo las soluciones correctamente distribuidas en dichas regiones.

El procedimiento de “*crowding*” utilizado por AGA trabaja, para la iteración t , mediante la división en mallas rectangulares o *grids* del espacio k -dimensional de objetivos ocupado por los vectores de soluciones en el archivo M_t (archivo de soluciones). El número de mallas lo establece, a priori, el usuario mediante la elección del valor de un parámetro de entrada, el cual establece la cantidad de divisiones del espacio objetivo. De esta forma, el número de mallas permanece constante, pero el espacio ocupado por los vectores cambia, de forma que la ubicación y la extensión de las mallas en el espacio objetivo se adaptan y cambian con el paso del tiempo de la misma forma que lo hacen los vectores en el archivo M_t . Esto se puede observar en la figura 4.4. En el instante t , cada vector en M_t ocupa exactamente una región malla y el número de vectores que ocupan la malla es conocido como su población. Se puede demostrar que los límites de la malla adaptativa y, por lo tanto, de todas las mallas siempre convergen bajo ciertas condiciones, es decir, su ubicación y extensión es inalterable después de algún tiempo t .

Las reglas de almacenamiento en AGA son tales que cuando el archivo esta completo, es decir, su capacidad es igual que el *arcsize*, los nuevos vectores no dominados producidos por $Gen(t)$ todavía pueden ser aceptados si hay, al menos, una región con una población mayor que la población de la región que ocuparía el nuevo vector no dominado. En este caso, un vector seleccionado al azar desde una de las regiones más densamente pobladas se eliminará desde M_t para dar cabida al nuevo vector. Esta regla ayuda a distribuir los vectores en el espacio objetivo de una manera uniforme.

La distribución de puntos obtenidos mediante la aplicación de las reglas de almacenamiento en AGA depende de varios factores. Entre estos factores se encuentra el

número de regiones que hay, la ubicación y la distribución de los vectores en el Frente Óptimo de Pareto, y el tamaño del archivo.




Figura 5.1 Ilustración de la evolución de la malla adaptativa

En la figura 5.1 se puede observar cómo la malla adaptativa cambia su ubicación y forma en el espacio de objetivos, así como también cambian los vectores en M_t para las iteraciones $t_k > t_j > t_i$.

5.1.1.3 Estructura del algoritmo

A continuación se muestra el esquema desarrollado para el algoritmo PAES.

PAES

M_t es el archivo de soluciones descubiertas

x solución actual

x' solución candidata

Inicializar el archivo de soluciones $M_t = 0$

Inicializar la población $x = \text{init}()$

Añadir la solución actual al archivo de soluciones $M_t = M_{t-1} \cup \{x\}$

Repetir

Aplicar la función de mutación $x' = \text{mutar}(x)$

Si la candidata no domina a la solución actual **entonces**

La descartamos

Sino

Si la candidata domina a la solución actual **entonces**

Calcular la localización en la malla para la candidata y renormalizar si fuese necesario.

Actualizar el archivo y eliminar los individuos dominados

Hacer la solución actual igual a la candidata

Sino

Si la candidata y el mutante son indiferentes **entonces**

Si la candidata es no dominada por el archivo **entonces**

Calcular la localización en la malla para la candidata y renormalizar si fuese necesario.

Actualizar el archivo y eliminar los individuos dominados

Hacer la solución actual igual a la candidata

Sino

Descartar la solución candidata

Hasta que se satisfaga el criterio de convergencia

Devolver el Archivo de soluciones M_t

5.1.1.4 Orden de complejidad para PAES.

Para analizar el orden de complejidad de PAES se debe calcular la complejidad de la *aceptación/no-aceptación* de la solución candidata y la actualización si fuese necesaria del archivo.

En este proceso, PAES requiere K iteraciones para comparar la solución candidata con la solución actual y por otro lado $|M_{t-1}| \cdot K$ comparaciones (en el peor de los casos) para comparar la solución mutante con el archivo, donde $|M_{t-1}|$ es el tamaño del archivo en la iteración anterior, y K es el número de objetivos del problema.

Por tanto esto requiere de $l \cdot K$ para encontrar la localización de la solución candidata en la malla. Por otro lado se requieren $2K$ comparaciones para actualizar los rangos de la malla y otras $|M_{t-1}|lK$ comparaciones si hay que actualizar los rangos de la malla y también se tiene que actualizar la población en las distintas regiones de la malla.

La complejidad de encontrar una solución en una región de la malla es descartada por ser de orden $O(M_{t-1})$.

En conclusión el orden de complejidad para PAES es de $O(tam)$ por iteración, donde tam es la capacidad del archivo. Y el orden de complejidad para PAES en el peor de los casos sería de $O(n^2)$ que viene a ser el orden de complejidad de muchos MOEAs [Knowles 02].

5.1.2 MultiStart-PAES

5.1.2.1 Aspectos generales

MultiStart-PAES (Ms-PAES) realiza varias ejecuciones simultáneas de PAES, llamadas mini-ejecuciones. En cada iteración de las mini-ejecuciones se va obteniendo la mejor solución y ésta se va almacenando en un archivo, de manera que se tienen tantos archivos como mini-ejecuciones. Por último, estos archivos son combinados para obtener el archivo final de las soluciones.

Una forma simple y eficiente de almacenar las soluciones consiste en tener dos archivos:

1. Un archivo global que almacena una muestra diversa de todas las soluciones descubiertas (las mejores encontradas), independientemente de que mini-ejecución la haya generado.
2. Un segundo archivo, llamado archivo local, por cada una de las mini-ejecuciones de PAES donde se van almacenando las mejores soluciones de cada mini-ejecución, pudiendo alguna de éstas estar dominada por otra del archivo global. Esta estrategia permite una mejor preservación de la diversidad.

Al final de la ejecución, el archivo global es devuelto como el conjunto de soluciones óptimas. Ambos, el archivo local y global, son actualizados en cada una de las iteraciones de acuerdo con la estrategia de almacenamiento.

5.1.2.2 Estructura del algoritmo

A continuación se muestra el pseudo-código asociado a Ms-PAES.

Ms-PAES

M_t es el archivo (local) de soluciones descubiertas

G_t es el archivo (global) de soluciones descubiertas

x solución actual

x' solución candidata

Inicializar el archivo Global $G_t = 0$

Repetir

Inicializar el archivo $M_t = 0$

Inicializar la población $x = \text{init}()$

Añadir la solución actual al global archivo $M_t = M_{t-1} \cup \{x\}$

Actualizar el archivo global con la solución actual

Repetir

Aplicar la función de mutación $x' = \text{mutar}(x)$

Si la candidata no domina a la solución actual **entonces**

Se descarta

Sino

Si la candidata domina a la solución actual **entonces**

Calcular la localización en la malla para la candidata y renormalizar si fuese necesario (local).

Actualizar el archivo y eliminar los individuos dominados (local).

Hacer la solución actual igual a la candidata.

Actualizar archivo Global con la candidata

Sino

Si la candidata y el mutante son indiferentes **entonces**

Si La candidata es no dominada por el archivo **entonces**

Calcular la localización en la malla para la candidata y renormalizar si fuese necesario (local).

Actualizar el archivo y eliminar los individuos dominados (local).

Hacer la solución actual igual a la candidata

Actualizar archivo Global con la candidata

Sino

Descartar la solución candidata

Hasta que se satisfaga el criterio de convergencia

Hasta que se cumpla la condición de finalización

Devolver el Archivo de soluciones G_t

5.1.2.3 Análisis comparativo PAES y Ms-PAES

Tras presentar Ms-PAES, podemos describir brevemente las principales diferencias observadas en comparación PAES:

- Ms-PAES requiere más de un archivo para almacenar las soluciones. En general, se requieren $N + 1$ archivos, siendo N el número de mini-ejecuciones. Por tanto, computacionalmente necesita N veces más memoria que PAES.

- b) Al tener más de un archivo, se mantiene una mejor diversidad, ya que posee mayor capacidad de almacenamiento, y por tanto existe más posibilidad de volver atrás para escapar de un óptimo local.
- c) Ms-PAES ya no parte desde un solo punto inicial, sino que cada mini-ejecución parte desde un punto distinto en el espacio de objetivos, con lo que se consigue una mayor probabilidad de convergencia.

5.1.3 Annealing-PAES

5.1.3.1 Aspectos generales

Annealing-PAES (A-PAES) consiste en extender el funcionamiento de PAES mediante la inclusión de la metaheurística conocida como enfriamiento simulado (*Simulated Annealing*). Su simplicidad y buenos resultados en numerosos problemas, la ha convertido en una herramienta muy popular, con cientos de aplicaciones en variados campos.

Desde que Kirkpatrick en 1983 introdujera el concepto de enfriamiento simulado, esta metaheurística ha demostrado ser una herramienta muy exitosa para resolver una amplia gama de problemas de optimización combinatoria. El funcionamiento del enfriamiento simulado es similar al proceso de enfriamiento al que es sometido un metal fundido. Cuando el metal se funde, sus partículas toman configuraciones aleatorias siendo propenso a deformarse. Tras la fundición, su temperatura disminuye lentamente hasta alcanzar un estado de mínima energía, proceso durante el cual dichas partículas van tomando una configuración robusta, y por tanto se dificulta su deformación. La analogía en el campo computacional radica en que la técnica de enfriamiento simulado trabaja con una solución inicial aleatoria, que se va optimizando de forma que al inicio del proceso se permiten variaciones de las soluciones que empeoren la función de aptitud con el propósito de escapar de los óptimos locales, mientras que conforme el proceso avanza disminuye la probabilidad de aceptar soluciones que empeoren dicha función. Esta analogía ha sido probada con éxito en numerosos problemas de optimización, mostrando gran habilidad para evitar quedar atrapado en óptimos locales.

Gráficamente, se puede ver como funciona el enfriamiento simulado en la figura 5.2. En dicha figura se puede observar cómo, dada una configuración inicial, el uso de enfriamiento simulado permite que vaya escapando de sucesivos óptimos locales hasta

llegar a encontrar el objetivo deseado, el mínimo global, en contraposición con la trayectoria que seguiría un algoritmo de optimización normal.




Figura 5.2 Ejemplo de la acción del enfriamiento simulado

A la hora de aplicar el enfriamiento simulado es muy importante determinar el esquema de enfriamiento. En concreto hay que determinar los valores óptimos de temperatura inicial, así como el factor de reducción de la temperatura. Es por ello que en algunos problemas el esquema de enfriamiento utilizado influya de forma importante en la calidad de las soluciones.

En la figura 5.3 se describe de forma detallada el funcionamiento básico de un algoritmo basado en enfriamiento simulado para problemas de minimización. En los algoritmos de enfriamiento simulado, las soluciones candidatas son aceptadas si estas no son más grandes que la solución actual en un cierto factor o porcentaje prefijado de antemano. Por tanto se trata de una regla determinista, en la cual la temperatura de enfriamiento puede ser constante o decreciente de acuerdo con una planificación.

```

Sea  $f(s)$  el coste de la solución  $s$  y sea  $N(s)$  su entorno.
Seleccionar una solución inicial  $s_0$ ;
Seleccionar una temperatura inicial  $t_0 > 0$ ;
Seleccionar una función de reducción de la temperatura  $\alpha$ ;
Seleccionar un número de iteraciones  $nrep$ ;
Seleccionar un criterio_de_parada;
REPETIR
  REPETIR
    Seleccionar aleatoriamente una solución  $s \in N(s_0)$ ;
    Sea  $\delta = f(s) - f(s_0)$ ;
    SI  $\delta < 0$  ENTONCES  $s_0 = s$ 
    SINO
      Generar aleatoriamente  $u \in U(0,1)$ ;
      SI  $u < \exp(-\delta/t)$  ENTONCES  $s_0 = s$ ;
    FINSINO
  HASTAQUE cuenta_iteraciones =  $nrep$ 
   $t = \alpha(t)$ ;
HASTAQUE criterio_de_parada = CIERTO.

La mejor solución visitada será la solución heurística dada
por el algoritmo

```

Figura 5.3 Pseudo-código de un algoritmo básico de enfriamiento simulado

Normalmente la función de aceptación de un algoritmo de enfriamiento simulado se basa en una función probabilística, con bastante frecuencia se usa la función de Boltzmann, que podemos ver en [Aarts 89]. Por tanto tenemos un parámetro, la “temperatura”, y una diferencia entre la solución actual y la candidata. Dado que vamos a utilizar el enfriamiento simulado en el contexto multi-objetivo, el esquema de enfriamiento consistirá en ir disminuyendo la temperatura de enfriamiento en función del número de soluciones almacenadas en el archivo y el tamaño del mismo, según la siguiente razón:

$$T_{sim} = \frac{N_{sol,t}}{N_{tam}}$$

- siendo T_{sim} la temperatura de enfriamiento, $N_{sol,t}$ el número de soluciones almacenadas en la iteración t y N_{tam} el tamaño del archivo.

5.1.3.2 Estructura del algoritmo

A continuación se muestra el pseudo-código de Annealing-PAES.

Annealing-PAES

M_t es el archivo de soluciones descubiertas

x solución actual

x' solución candidata

T es el parámetro temperatura

T_{start} es la temperatura inicial

$Cool(T, M_t)$ devuelve un nuevo valor para la temperatura, dependiendo del valor de T y del tamaño del archivo.

Inicializar el archivo $M_t = \emptyset$

Inicializar la población $x = \text{init}()$

Añadir la solución actual al global archivo $M_t = M_{t-1} \cup \{x\}$

Inicializar el parámetro Temperatura $T = T_{start}$.

Repetir

Aplicar la función de mutación $x' = \text{mutar}(x)$

Si la candidata es mayor a la solución actual **entonces**

Se descarta

Sino

Si la candidata es menor a la solución actual **entonces**

Calcular la localización en la malla para la candidata y renormalizar si fuese necesario

Actualizar el archivo y eliminar los individuos dominados

Hacer la solución actual igual a la candidata.

Sino

Si la candidata y el mutante son iguales **entonces**

Si la candidata es menor al archivo **entonces**

Calcular la localización en la malla para la candidata y renormalizar si fuese necesario

Actualizar el archivo y eliminar los individuos dominados

Hacer la solución actual igual a la candidata

Sino

Descartar la solución candidata

Actualizar la Temperatura $T = Cool(T, M_t)$

Hasta que se satisfaga el criterio de convergencia

Devolver el Archivo de soluciones M_t

Se debe comentar que aplicar esta metaheurística en PAES conlleva dos aspectos importantes a tener en cuenta:

- PAES sólo utiliza relaciones de dominancia, no establece ninguna función para diferenciar dos soluciones.

El algoritmo tiene que aceptar soluciones dominadas por lo que la estrategia de almacenamiento se ve seriamente degradada y puede que a veces no converja

5.1.3.3 Análisis comparativo entre Annealing-PAES y PAES

Las principales diferencias observadas entre los dos algoritmos son:

- a) Annealing-PAES necesita de una relación de diferencia entre soluciones para que la función de aceptación decida con cual de las dos se queda.
- b) También necesita de un procedimiento que regule el parámetro temperatura, con el cual ir refinando la selección en la función de aceptación.
- c) A cambio ofrece una mayor convergencia hacia frente óptimo, ya que posee un mecanismo de marcha atrás, con el fin de escapar de óptimos locales, donde PAES puede quedar atrapado

5.1.4 Tabu-PAES

5.1.4.1 Aspectos generales

Tabu-PAES (T-PAES) consiste en extender el funcionamiento de PAES mediante la inclusión de la metaheurística conocida como búsqueda tabú (*Tabu Search*). Al igual que el enfriamiento simulado, la búsqueda tabú consiste en intentar encontrar el óptimo del problema a resolver, combinando la búsqueda local con una heurística para evitar quedar atrapado en óptimos locales y evitar entrar en ciclos. A tal efecto, hace uso del concepto de memoria y lo implementa mediante estructuras simples con el objetivo de dirigir la búsqueda teniendo en cuenta la historia previa. Puede decirse que se lleva a cabo un cierto aprendizaje y que la búsqueda es inteligente. Su filosofía es que es mejor una mala decisión basada en información que una buena decisión al azar, ya que, en un sistema que emplea memoria, una mala elección basada en una estrategia proporcionará claves útiles

para continuar la búsqueda de forma eficiente, mientras que una buena elección fruto del azar no proporcionará ninguna información para posteriores acciones.

Por tanto, la característica distintiva de la búsqueda tabú es el uso de memoria adaptativa y de estrategias especiales de resolución de problemas basadas en procedimientos de aprendizaje. El marco de memoria adaptativa de búsqueda tabú explota la historia del proceso de resolución haciendo referencia a cuatro dimensiones principales consistentes en la propiedad de ser reciente, en frecuencia, en calidad, y en influencia. La búsqueda Tabú tiene sus antecedentes en métodos diseñados para cruzar cotas de factibilidad u optimalidad locales tratadas como barreras en procedimientos clásicos, e imponer y eliminar cotas sistemáticamente para permitir la exploración de regiones no consideradas en otro caso [Glover 97].

El nombre y la terminología de búsqueda tabú vienen de [Glover 97]. Búsqueda Tabú es el origen del enfoque basado en memoria y estrategia intensiva en la literatura de las metaheurísticas, en contraposición con los métodos que no tienen memoria o que sólo usan una débil memoria basada en herencia.

También es el responsable de enfatizar el uso de los diseños estructurados para explotar los patrones históricos de la búsqueda, de forma opuesta a los procesos que confían casi exclusivamente en la aleatoriedad.

Los principios fundamentales de la Búsqueda Tabú fueron elaborados en una serie de artículos a finales de los años 80 y principios de los 90, y han sido unificados en el libro “Tabu Search” [Glover 97].

5.1.4.2 Estructura del algoritmo

La estructura general de Tabu-PAES se muestra a continuación.

Tabu-PAES

M_t es el archivo de soluciones descubiertas

x solución actual

x' solución candidata

Tabu es la estructura donde se almacenan los movimientos tabú

Inicializar el archivo $M_t = 0$

Inicializar la población $x = \text{init}()$

Añadir la solución actual al global archivo $M_t = M_{t-1} \cup \{x\}$

Inicializar la lista Tabú $Tabu = 0$

Repetir

Repetir

Aplicar la función de mutación $x' = \text{mutar}(x)$

Mientras sea movimiento tabú

Actualizar la lista tabú

Si la candidata es mayor a la solución actual **entonces**

Se descarta

Sino

Si la candidata domina a la solución actual **entonces**

Calcular la localización en la malla para la candidata y renormalizar si fuese necesario

Actualizar el archivo y eliminar los individuos dominados

Hacer la solución actual igual a la candidata.

Sino

Si la candidata y el mutante son indiferentes **entonces**

Si la candidata no es dominada por el archivo **entonces**

Calcular la localización en la malla para la candidata y renormalizar si fuese necesario

Actualizar el archivo y eliminar los individuos dominados

Hacer la solución actual igual a la candidata

Sino

Descartar la solución candidata

Hasta que se satisfaga el criterio de convergencia

Devolver el Archivo de soluciones M_t

5.1.4.3 Análisis comparativo PAES y Tabú-PAES

Las principales diferencias observadas entre los dos algoritmos son:

- a) Tabú-PAES necesita de estructuras de datos adicionales, para mantener almacenados los movimientos no permitidos o movimientos tabú.
- b) También necesita de un procedimiento que regule cuando un movimiento se puede o no permitir.
- c) A cambio ofrece una mayor convergencia al frente óptimo, ya que evita que se produzcan ciclos que nos lleven de un estado actual a un estado anterior, deshaciendo lo que se acababa de hacer.
- d) Computacionalmente requiere de más tiempo y más recursos que PAES, pero ofrece mejores resultados tal y como se verá en el capítulo de resultados experimentales.

5.1.5 Hibridación de Annealing y Tabu-PAES

5.1.5.1 Aspectos generales

En el apartado de “Casos de Estudio”, que se presenta posteriormente, se puede observar como los algoritmos de enfriamiento simulado y búsqueda tabú obtienen, en algunos casos, mejores soluciones que PAES. Esto lleva a plantearse la pregunta de qué ocurriría si se combinasen aspectos de ambas técnicas, lo cual llevó a plantearnos la idea de diseñar e implementar un algoritmo que utilice por un lado lo mejor de la técnica de enfriamiento simulado, su capacidad de escapar de óptimos locales, y lo mejor de la búsqueda tabú, utilización de memoria para evitar que se repitan aquellas variaciones de soluciones no satisfactorias que se llevaron a cabo recientemente.

Como resultado se ha obtenido el algoritmo llamado Annealing-Tabu-Paes (AT-PAES), el cual proporciona unos resultados mejores de los esperados frente a las otras técnicas.

5.1.5.2 Estructura del algoritmo

A continuación se ofrece una descripción en pseudo-código correspondiente a la estructura general de Annealing-Tabu-PAES.

Annealing-Tabu-PAES

M_t es el archivo de soluciones descubiertas

x solución actual

x' solución candidata

T es el parámetro temperatura

T_{start} es la temperatura inicial

$Cool(T, M_t)$ devuelve un nuevo valor para la temperatura, dependiendo del valor de T y del tamaño del archivo.

$Tabu$ es la estructura donde se almacenan los movimientos tabú

Inicializar el archivo $M_t = 0$

Inicializar la población $x = \text{init}()$

Añadir la solución actual al global archivo $M_t = M_{t-1} \cup \{x\}$

Inicializar el parámetro Temperatura $T = T_{start}$

Repetir**Repetir**

Aplicar la función de mutación $x' = \text{mutar}(x)$

Mientras sea movimiento tabú

Actualizar la lista tabú

Si la candidata es mayor a la solución actual **entonces**

Se descarta

Sino

Si la candidata es menor a la solución actual **entonces**

Calcular la localización en la malla para la candidata y renormalizar si fuese necesario

Actualizar el archivo y eliminar los individuos dominados

Hacer la solución actual igual a la candidata.

Sino

Si la candidata y el mutante son iguales **entonces**

Si la candidata es menor al archivo **entonces**

Calcular la localización en la malla para la candidata y renormalizar si fuese necesario

Actualizar el archivo y eliminar los individuos dominados

Hacer la solución actual igual a la candidata

Sino

Descartarla solución candidata

Actualizar la Temperatura $T = \text{Cool}(T, M_t)$

Hasta que se satisfaga el criterio de convergencia

Devolver el Archivo de soluciones M_t

5.1.5.3 Análisis comparativo frente a PAES.

Las principales diferencias observadas entre los dos algoritmos son:

- a) Necesita de estructuras de datos adicionales, para mantener almacenados los movimientos no permitidos o movimientos tabú.
- b) Se hace necesario un procedimiento que regule cuando un movimiento se puede o no permitir.
- c) Precisa de una relación de diferencia entre soluciones para que la función de aceptación decida con cual de las dos se queda.
- d) Requiere de un procedimiento que regule el parámetro temperatura con el cual ir refinando la selección en la función de aceptación.
- e) A cambio ofrece una mayor convergencia al frente óptimo, ya que evita que se produzcan ciclos que nos lleven de un estado actual a un estado anterior, deshaciendo lo que se acababa de hacer.

- f) Computacionalmente requiere de más tiempo y más recursos que PAES, pero ofrece mejores resultados tal y como se verá en el capítulo de resultados experimentales.
- g) Ofrece una mayor convergencia al frente óptimo, ya que posee un mecanismo de marcha atrás, con el fin de escapar de óptimos locales, donde PAES quedaría atrapado.

5.2 Casos de estudio

Al igual que se hizo en el capítulo anterior, se estudian los algoritmos multi-objetivo propuestos en las diferentes redes de test disponibles según la IEEE. En este caso, y debido a la similitud de tamaño entre la red IEEE57 y la red RTS, se han obtenido resultados muy similares para dichas redes, por lo que sólo se muestran los test realizados usando la red IEEE30 y la red RTS.

Asimismo, se omiten intencionadamente los resultados obtenidos para la versión multietapa (ejecuciones durante 24 horas) ya que no aportan ninguna novedad respecto a la versión monoetapa, tras haberse constatado que suponen repetición en el tiempo de dicha versión monoetapa, pero con valores de entrada diferentes.

Los test efectuados sobre las diferentes redes han sido:

- **Algoritmo PAES multi-objetivo.** Optimiza simultáneamente dos objetivos: minimización de la desviación de tensiones y minimización en las pérdidas de potencia en la red.
- **Algoritmo Annealing-PAES.** Versión híbrida de PAES con elementos de *Simulated Annealing* para los dos objetivos.
- **Algoritmo Tabu-PAES.** Versión híbrida de PAES con elementos de *Tabu Search* para los dos objetivos.
- **Algoritmo Annealing-Tabu-PAES.** Mezcla de elementos de *Tabu Search*, *Simulated Annealing* y PAES para los dos objetivos.
- **Algoritmo PAES mono-objetivo.** Se ha lanzado el algoritmo PAES con un sólo objetivo (optimización de la tensión nodal a través del IDT) y se ha comparado con la versión genética.

5.2.1 Red IEEE30

La red IEEE30 ha sido descrita en el apartado 4.2.1.1. A modo de resumen tiene como características principales:

- 8 unidades de generación (2 centrales y 6 generadores síncronos)
- Red de transporte y distribución compuesta por 34 líneas que interconectan a 30 nudos. Existen 4 transformadores de potencia con tomas de regulación.
- El nudo oscilante o *slack* es el número uno.

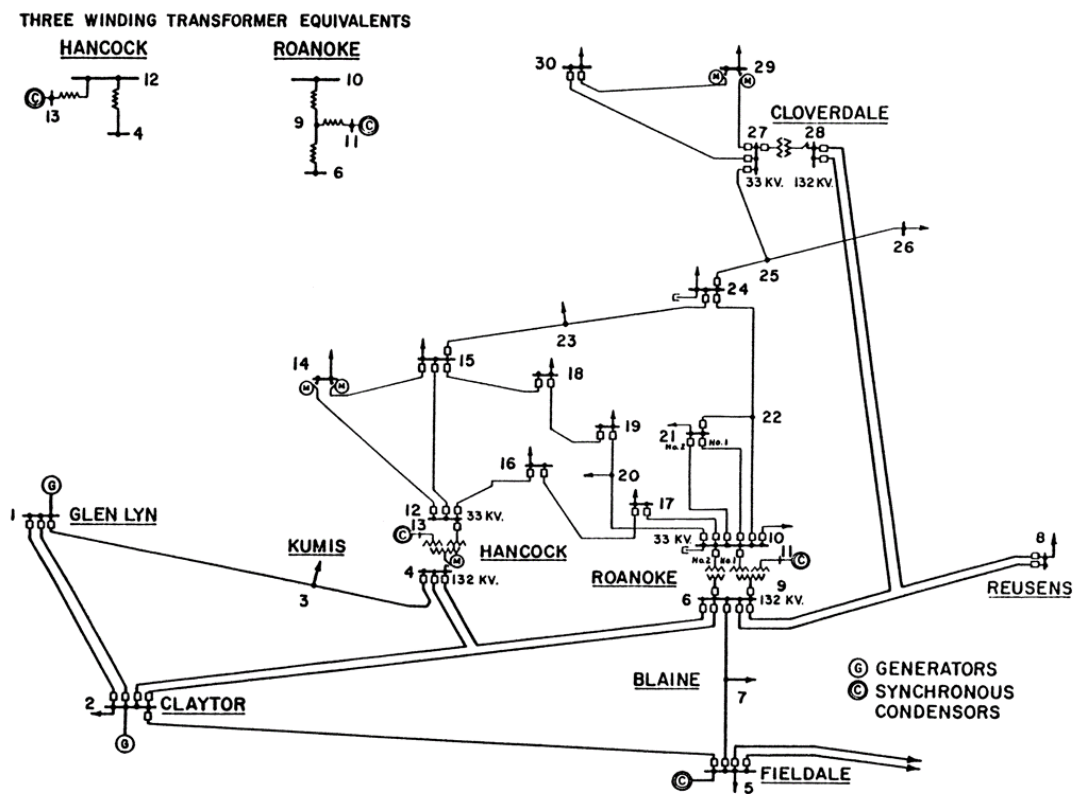


Figura 5.4 Red de potencia IEEE 30

5.2.1.1 PAES multi-objetivo

La optimización se realiza ahora teniendo en cuenta dos objetivos: el índice de desviación de tensión (IDT), relacionado con el nivel de tensión de la red, y las pérdidas de potencia en las líneas eléctricas como consecuencia del flujo de cargas por dicha red.

Los datos de partida son los mismos que en situaciones anteriores y se muestra una comparativa de las soluciones obtenidas por cada una de las variantes implementadas. En la figura 5.5 se muestran los resultados de 5 ejecuciones diferentes usando el algoritmo PAES. En ella se aprecian diferentes frentes de soluciones no dominadas, representativo del frente Pareto-óptimo (desconocido).




Figura 5.5 Frente de Pareto para el caso IEEE30 con 5 ejecuciones de PAES.

Los parámetros de trabajo fueron los de la tabla 5.1.

Iteraciones	Mutación	Escalón	Nº Escalones
10.000	20%	1%	11

Tabla 5.1 Parámetros en la ejecución de PAES para la red IEEE30

Las soluciones obtenidas permiten un gran margen de decisión a la hora de escoger la mejor estrategia para la red. Se consiguen encontrar soluciones que presentan un buen IDT y una pérdida de potencia más elevada, en contraposición a las soluciones donde el IDT es más alto a la vez que las pérdidas de potencia son menores.

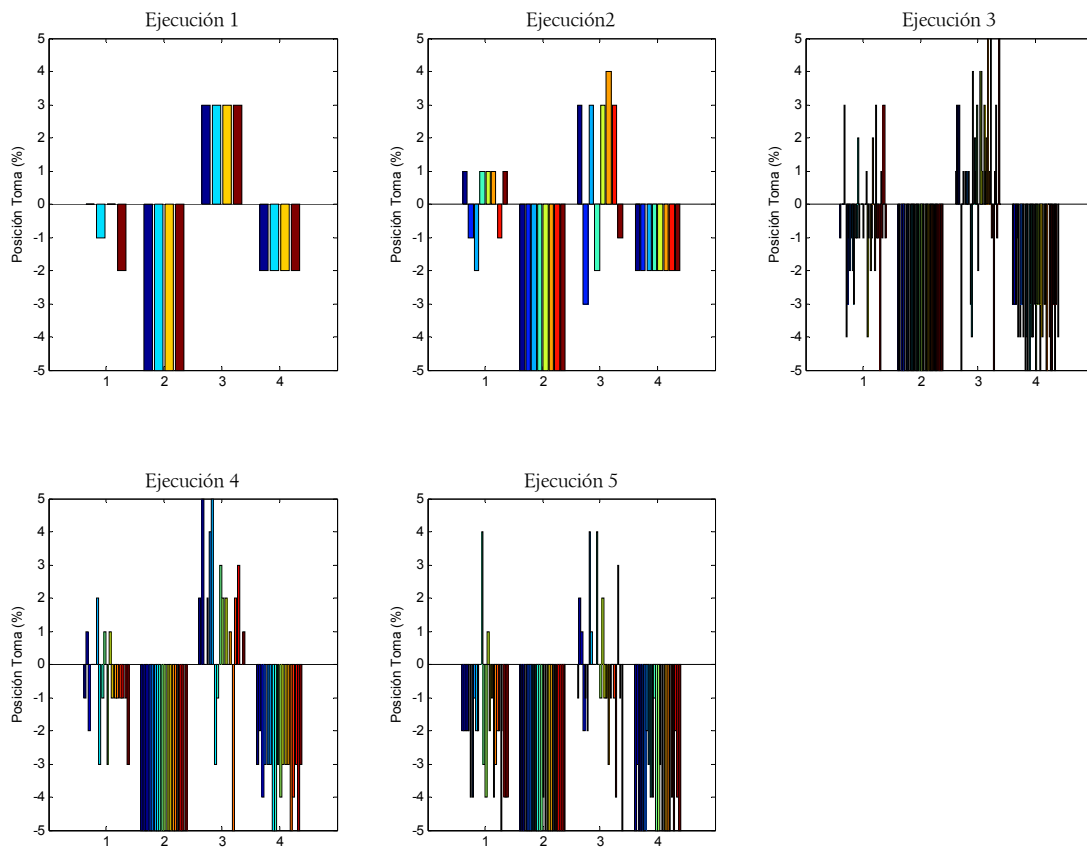


Figura 5.6 Posición de las tomas para varias ejecuciones de PAES en la red IEEE30

En la figura 5.6 se muestra la variación de las tomas en las ejecuciones realizadas. Debido a la aleatoriedad del algoritmo, y sobre todo a la elección en el individuo de partida, es posible que el frente de soluciones no dominadas no siempre esté muy poblado, aunque es posible garantizar mediante varias ejecuciones (o un número elevado de iteraciones) que dicho frente será homogéneo y, por tanto, habrá una gran diversidad de soluciones no dominadas.

Además de la versión inicial de PAES, se han implementado nuevas estrategias híbridas que han mostrado un comportamiento bastante efectivo. En la figura 5.7, figura 5.8 y figura 5.9 se muestran los resultados obtenidos por Annealing-PAES, Tabú-PAES y Annealing-Tabú-PAES, respectivamente. En ellas se aprecia como se consiguen frentes de soluciones no dominadas bien distribuidas que recogen bastante diversidad en las soluciones. Además, estas implementaciones requieren un menor número de iteraciones para conseguir el mismo frente que PAES.

Más adelante, se detallarán procedimientos para medir la bondad de los frentes de soluciones no dominadas en base a métricas específicas que permiten establecer

preferencias entre los diferentes frentes de soluciones atendiendo criterios como el porcentaje de soluciones de un frente que son dominadas por otros frentes, o la cercanía de dicho frente al frente Pareto-óptimo, que como hemos comentado no es conocido debido a que es imposible explorar todo el espacio de búsqueda. Estas métricas permiten hacerse una idea de lo buena que es una solución o ejecución frente a otras soluciones, y de esta forma, poder elegir convenientemente. Además, se detallará un procedimiento para el uso de una nueva métrica que permitirá seleccionar los mejores individuos de ejecuciones paralelas (o diferentes) y combinar un nuevo “super-frente” que domine a cualquier solución anterior.




Figura 5.7 Frente de Pareto para el caso IEEE30 con 5 ejecuciones de Annealing-PAES.




Figura 5.8 Frente de Pareto para el caso IEEE30 con 5 ejecuciones de Tabú-PAES.




Figura 5.9 Frente de Pareto para el caso IEEE30 con 5 ejecuciones de Annealing-Tabú-PAES

La distribución de las tomas para cada una de las ejecuciones anteriores se puede apreciar en la figura 5.10. Se observa como las soluciones obtenidas presentan una gran dispersión y cubren bastantes opciones de configuración en los transformadores. Obviamente, algunas presentan mejor característica desde el punto de vista del IDT y otras lo hacen desde el punto de vista de la pérdida de potencia. Cabe destacar el hecho de la similitud con los resultados mostrados en la figura 5.6.

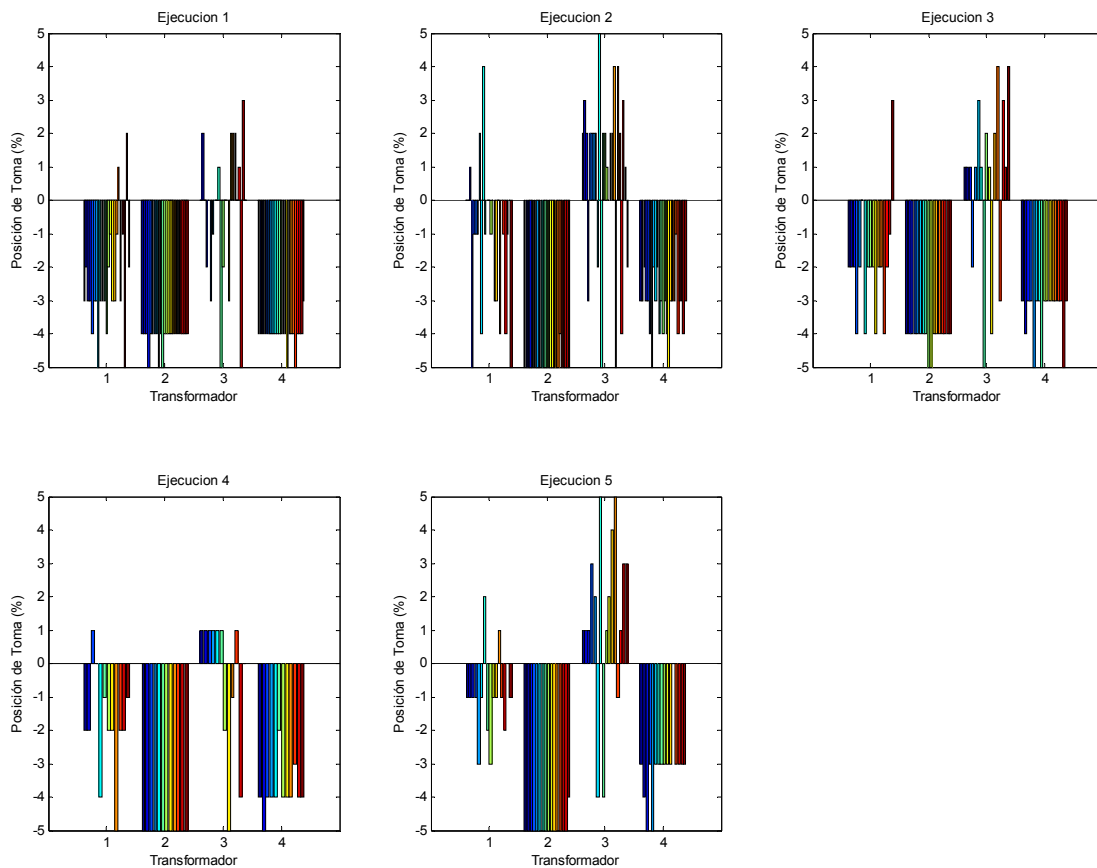


Figura 5.10 Posición de las tomas para varias ejecuciones de Annealing-Tabú-PAES en la red IEEE30

5.2.2 Red RTS

La red RTS fue descrita en el apartado 4.2.1.3, presentando como características más destacadas:

- 33 nodos de generación que agrupan a 99 unidades generadoras.

- Red compuesta por 104 líneas que interconectan a 73 nudos. Existen 16 transformadores de potencia con tomas de regulación.
- El nudo oscilante o *slack* es el número 113.

En la figura 4.26 se muestra el esquema de la red RTS.

5.2.2.1 PAES Multi-objetivo

Se vuelven a realizar las ejecuciones de los algoritmos implementados bajo las mismas premisas que se plantearon en la red IEEE30. Se busca optimizar dos objetivos a la vez para hallar el mejor frente de Pareto posible.

En primer lugar se muestran los resultados de 5 ejecuciones aleatorias usando el algoritmo PAES (ver figura 5.11). Se vuelve a apreciar como nuevamente se forma un buen frente de Pareto (incluyendo la solución mono-objetivo del AG).




Figura 5.11 Frente de Pareto para el caso RTS con 5 ejecuciones de PAES

Los parámetros de trabajo fueron los de la tabla 5.2.

Iteraciones	Mutación	Escalón	Nº Escalones
10.000	20%	1%	21

Tabla 5.2 Parámetros en la ejecución de PAES para la red RTS

En la figura 5.12 se muestran las posiciones de las tomas para una ejecución cualquiera del algoritmo.




Figura 5.12 Posición de las tomas para una ejecución aleatoria de PAES en la red RTS

En la figura 5.13, figura 5.14 y figura 5.15, se muestran las gráficas de resultados para los algoritmos Annealing-PAES, Tabú-PAES y Annealing-Tabú-PAES, respectivamente.

En dichas figuras se observa como el frente de soluciones no dominadas mejora con la técnica de búsqueda tabú, mientras que la técnica de enfriamiento simulado no presenta mejoras respecto a la implementación original de PAES.

En el siguiente apartado se detallan las métricas implementadas al objeto de comparar las bondades de cada método.




Figura 5.13 Frente de Pareto para el caso RTS con 5 ejecuciones de Annealing-PAES.




Figura 5.14 Frente de Pareto para el caso RTS con 5 ejecuciones de Tabú-PAES.




Figura 5.15 Frente de Pareto para el caso RTS con 5 ejecuciones de Annealing-Tabú-PAES.

5.3 Métricas implementadas

Evaluar un conjunto de diferentes técnicas de optimización de manera experimental conlleva, invariablemente, especificar formalmente la noción de rendimiento para poder establecer comparaciones significativas.

En el caso de la optimización multi-objetivo, la definición de calidad es más compleja que para los problemas de optimización de objetivo simple ya que la meta de la búsqueda en sí consiste en varios aspectos mientras que en la optimización de un solo objetivo sólo es necesario buscar aquella solución más próxima a las restricciones deseadas.

Habitualmente, las características que se buscan a la hora de encontrar un conjunto de soluciones no dominadas suelen ser:

- La distancia al frente óptimo del conjunto de soluciones no dominadas resultantes de la ejecución del algoritmo, debe minimizarse.

- Se debe buscar una buena distribución (en muchos casos uniforme) de las soluciones.
- La extensión del frente obtenido debe ser máxima. Para cada objetivo, se debería cubrir un rango de valores amplio por las soluciones obtenidas.

A lo largo de los años de investigación en esta área se han intentado formalizar conjuntos de métricas que, teniendo en cuenta los aspectos anteriores, indiquen numéricamente el mérito de un conjunto de soluciones de entrada.

Una primera aproximación consistió en una suma ponderada de los valores de los diferentes objetivos, aunque rápidamente se detectaron las desventajas de estos métodos. Las regiones no convexas contribuían más al aumento de la calidad que las convexas. Además, la distribución y la extensión del frente no era considerado. Esto último es importante porque frentes con igual distancia al óptimo de Pareto pueden presentar distribuciones totalmente diferentes.

Otra aproximación más reciente ha sido calcular el tamaño del área no dominada definida por las soluciones calculadas en el espacio objetivo. Ésta métrica ha sido bastante exitosa ya que se ha utilizado (y se sigue utilizando) en multitud de trabajos del sector. Ciertos autores consideran esta medida como el indicador escalar más apropiado ya que combina tanto la distancia de las soluciones al frente óptimo como su distribución. Si bien, aunque esto es considerado como una ventaja, también podemos verlo como un inconveniente si queremos categorizar el mérito de cada algoritmo en los diferentes aspectos separadamente.

En [Zitzler 99] y [Esb96, Fon96] se pueden encontrar discusiones acerca de algunas de las diferentes métricas propuestas.

Podría decirse que las métricas de rendimiento son difíciles de definir y probablemente no sea posible desarrollar una única métrica que permita categorizar todos los criterios de un modo significativo.

En este estudio se han considerado dos métricas, denotadas como C y S , que a continuación se detallan.

5.3.1 Métrica de cobertura

La métrica de cobertura, denotada normalmente como C , se centra en comparar dos conjuntos de soluciones, indicando cómo las soluciones de un frente dominan a las del otro, la cual podemos encontrar en [Zitzler 99].

La función C mapea el par ordenado (X', X'') al intervalo $[0,1]$, y muestra como las soluciones del frente X' cubren a las del frente X'' .

$$C(X', X'') := \frac{|\{a'' \in X'' : \exists a' \in X' : a' \prec a''\}|}{|X''|}$$

siendo:

- $X', X'' \subseteq X$ conjuntos de vectores de decisión.
- $|\cdot|$ es el operador cardinal, que indica el número de elementos de un conjunto.

Un valor de $C(X', X'') = 1$, significa que todas las soluciones en X'' son cubiertas por las soluciones en X' . Lo contrario, $C(X', X'') = 0$, representa la situación en la que ninguna de las soluciones en X'' es cubierta por las del conjunto X' .

Es importante señalar que deben considerarse tanto $C(X', X'')$ como $C(X'', X')$ ya que $C(X', X'')$ no tiene por qué ser igual a $C(X'', X')$ y tampoco se cumple que $C(X', X'')$ sea igual a $1 - C(X'', X')$.

5.3.2 Métrica de hipervolumen

La métrica de hipervolumen (S) evalúa, para cada frente de forma independiente, el área del espacio objetivo que dominada por cada frente de soluciones obtenido. En concreto, para el caso bi-objetivo que nos ocupa, la función $S(X')$ se definiría el porcentaje del área total del espacio objetivo que es dominado por las soluciones de un determinado frente. El área total del espacio objetivo está formado por el rectángulo delimitado por los puntos $(0,0)$ y $(\max\{f_1(x_i)\}, \max\{f_2(x_i)\})$, siendo $\max\{f_1(x_i)\}$ el valor máximo del índice de desviación de tensión de los frentes evaluados, y $\max\{f_2(x_i)\}$ el valor máximo de la pérdida de potencia de dichos frentes. Por tanto, si comparamos

varios frentes, obtendrá un mejor resultado aquel que obtenga el valor del hipervolumen mayor, ya que supondrá que es el que cubre un porcentaje mayor del área objetivo.

5.3.3 Aplicación de métricas a redes en estudio

Tras los resultados obtenidos en el apartado anterior, se muestran ahora las medidas de calidad o métricas implementadas para las redes IEEE30 y RTS. En ellas se aprecian los frentes óptimos obtenidos como resultado de varios lanzamientos consecutivos (dentro del mismo tipo de algoritmo) con un gran número de iteraciones, pero con la particularidad de que la población se ha ido reiniciando cada cierto número de iteraciones. Con esto se consigue realizar una especie de algoritmo “multistart”, comenzando con soluciones diferentes cada ejecución, constituyendo finalmente un frente que sea el resultado de los mejores individuos.

En la figura 5.16 se muestra el resultado de la comparativa entre los cuatro algoritmos implementados (PAES, A-PAES, T-PAES y AT-PAES) para la red IEEE30. En ella se puede observar como los 4 algoritmos implementados obtienen un frente situado, más o menos, en la misma franja del espacio de soluciones. Cada uno de los frentes ha sido el fruto de una única ejecución del algoritmo correspondiente, pero con varios reinicios de población en su transcurso. Esta técnica permite reducir bastante el componente de aleatoriedad en el algoritmo, de forma que se consiguen resultados más homogéneos.

En la tabla 5.3 y tabla 5.4 se pueden ver los resultados numéricos obtenidos para cada una de las dos métricas utilizadas, mientras que en la tabla 5.5 se muestra una posible ordenación o ranking según los valores obtenidos en dichas métricas. Se puede comprobar como para redes pequeñas-medianas, como la IEEE30, es PAES el que mejores resultados obtiene. Pese a que la métrica de hipervolumen indica que todos los métodos dominan un área similar del espacio de búsqueda (algo más del 1.8% en todos los casos), la métrica de cobertura si muestra una clara diferencia entre los diferentes obtenidos, observándose como, en media, PAES obtiene los mejores resultados dominando al 34,7% de las soluciones obtenidas por los otros frentes. Se debe aclarar que los valores de hipervolumen tan bajos (un 1.8%) es debido a que el área total del espacio objetivo está formado por el rectángulo delimitado por los puntos (0, 0) y (0.055, 5.76), por lo que el área cubierta es menor de la que pudiera parecer a simple vista por la escala

de las gráficas que se presentan. En el ranking total de la tabla 5.5 se observa como PAES constituye el mejor frente compromiso.




Figura 5.16 Comparativa entre PAES, A-PAES, T-PAES y AT-PAES para IEEE30

	PAES	A-PAES	T-PAES	AT-PAES	Media
PAES	-1,000	0,393	0,289	0,359	0,347
A-PAES	0,094	-1,000	0,184	0,205	0,161
T-PAES	0,094	0,250	-1,000	0,128	0,157
AT-PAES	0,094	0,393	0,158	-1,000	0,215

Tabla 5.3 Resultados experimentales para la métrica de cobertura en IEEE30

	PAES	A-PAES	T-PAES	AT-PAES
Hiper-volumen	0,01856	0,01808	0,01867	0,01801

Tabla 5.4 Resultados experimentales para la métrica de hipervolumen en IEEE30

	COBERTURA		HIPERVOLUMEN		Suma rankings	Ranking Total
	VALOR	RANKING	VALOR	RANKING		
PAES	0,347	1	0,01856	2	3	1
A-PAES	0,161	4	0,01808	3	7	4
T-PAES	0,157	3	0,01867	1	4	2
AT-PAES	0,215	2	0,01801	4	6	3

Tabla 5.5 Ranking de métricas para la red IEEE30

Una vez analizados los resultados obtenidos para la red IEEE30, pasamos a analizar la red RTS. Esta red es bastante más grande que la IEEE30, observándose un comportamiento diferente al de IEEE30. En concreto PAES ya no se comporta como en redes más pequeñas. En la figura 5.17 se presentan los resultados para los frentes de Pareto de los diferentes algoritmos multi-objetivo en la red RTS. En la tabla 5.6 y tabla 5.7 se muestran los valores numéricos para las métricas usadas, mientras que en la tabla 5.8 se presenta un ranking de los algoritmos en función de su comportamiento general, teniendo en cuenta ambas métricas. En este caso, Tabu-PAES obtiene el mejor resultado tanto en cobertura como hipervolumen. Cabe destacar que en este caso el valor numérico del hipervolumen es aun menor que en el caso de la red IEEE30 ya que la escala de pérdida de potencia (eje de ordenadas) es dos órdenes de magnitud mayor en RTS que en IEEE30, aunque esto no importa ya que todos los frentes son comparados haciendo uso del mismo área total del espacio objetivo.




Figura 5.17 Comparativa entre PAES, A-PAES, T-PAES y AT-PAES para RTS

	PAES	A-PAES	T-PAES	AT-PAES	Media
PAES	-1,000	0,385	0,267	0,412	0,355
A-PAES	0,238	-1,000	0,333	0,235	0,269
T-PAES	0,524	0,385	-1,000	0,294	0,401
AT-PAES	0,143	0,462	0,267	-1,000	0,291

Tabla 5.6 Resultados experimentales para la métrica de cobertura en RTS

	PAES	A-PAES	T-PAES	AT-PAES
Hiper-volumen	0,000749	0,000721	0,000758	0,000681

Tabla 5.7 Resultados experimentales para la métrica de hipervolumen en RTS

	COBERTURA		HIPERVOLUMEN		Suma rankings	Ranking Total
	VALOR	RANKING	VALOR	RANKING		
PAES	0,355	2	0,00075	2	4	2

A-PAES	0,269	4	0,00072	3	7	3=
T-PAES	0,401	1	0,00076	1	2	1
AT-PAES	0,291	3	0,00068	4	7	3=

Tabla 5.8 Ranking de métricas para la red RTS

5.3.3.1 PAES mono-objetivo

Dada la mejora obtenida por algunas versiones de PAES en el caso multi-objetivo, nos preguntamos sobre la posibilidad de su adaptación al caso mono-objetivo, por lo que hemos comparado su rendimiento con el obtenido con el algoritmo genético descrito analizado en el capítulo anterior. Los resultados obtenidos con esta técnica han sido mejores que los obtenidos con algoritmos genéticos. La figura 5.18 y la figura 5.19 muestran como el proceso de convergencia es mucho más rápido y se acaba encontrando el óptimo del problema con más facilidad ($IDT = 0,10618$). Se aprecia como se necesitan muchas menos evaluaciones para obtener el mismo resultado que con AG, de hecho, con AG se hacían del orden de 750 evaluaciones (50 individuos y 15 generaciones), mientras que ahora se consigue con menos de 100 la gran mayoría de las ejecuciones.

La tabla 5.9 ofrece una comparativa entre ambos algoritmos.

Algoritmo	IDT	Tiempo ejec (s)	Tomas
Algoritmo Genético	0.010618	16,3	[-2 -2 -2 -2]
PAES	0.010618	6,93	[-2 -2 -2 -2]

Tabla 5.9 Comparativa entre PAES y AG para IEEE30

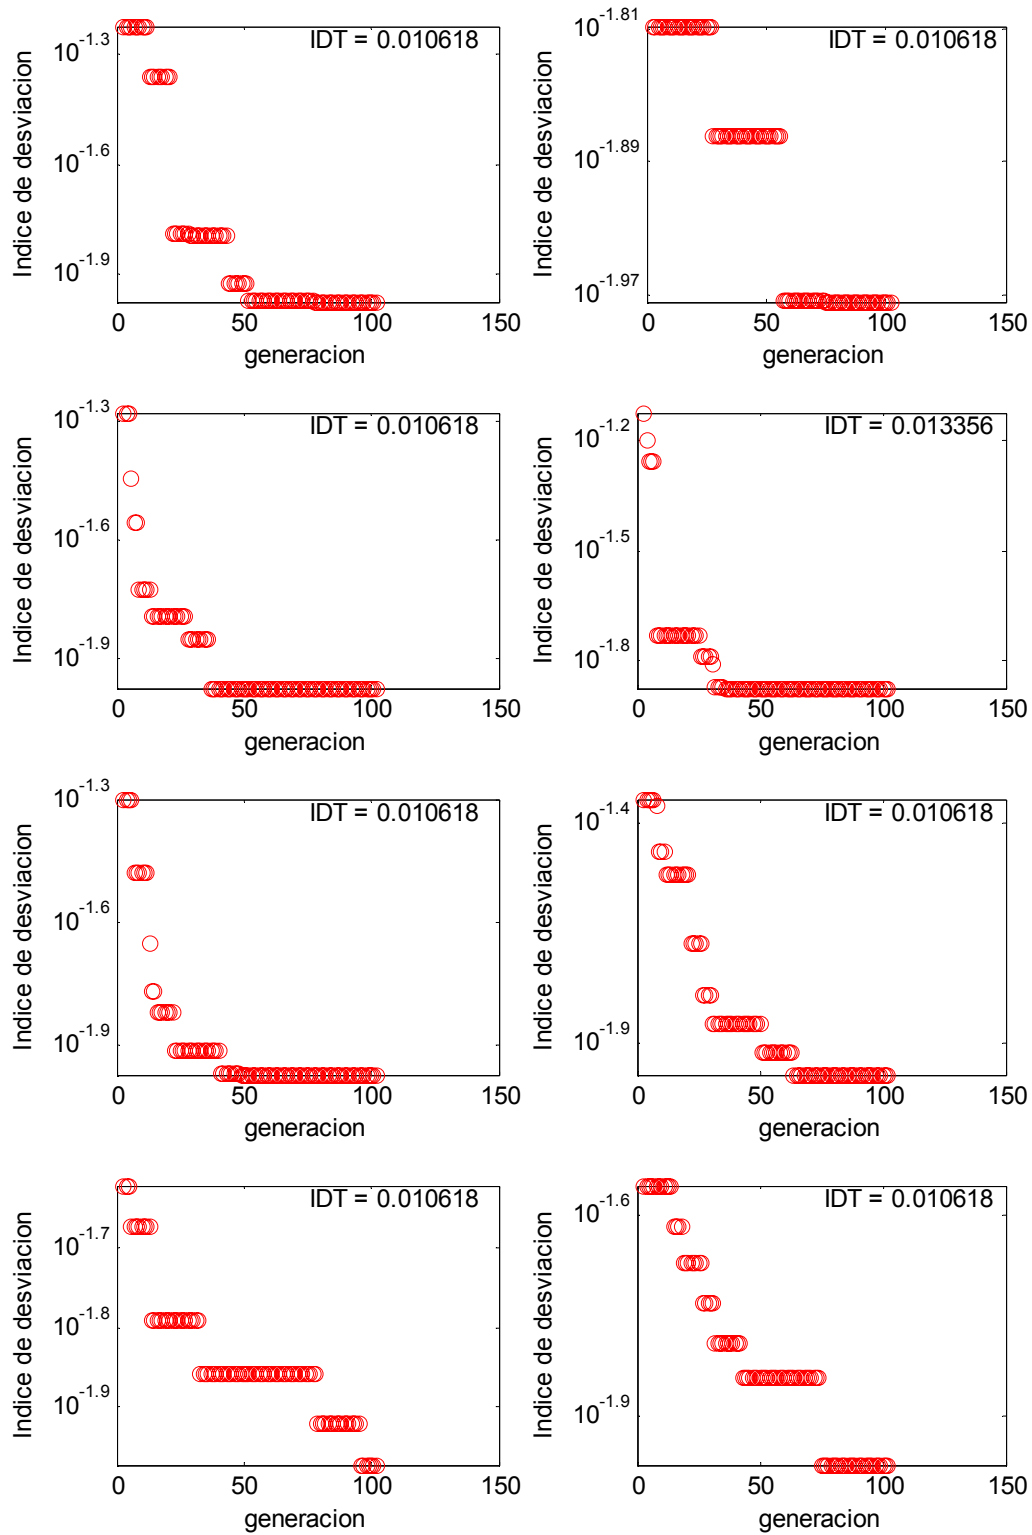


Figura 5.18 Ejecución de PAES mono-objetivo para la red IEEE30 (I)

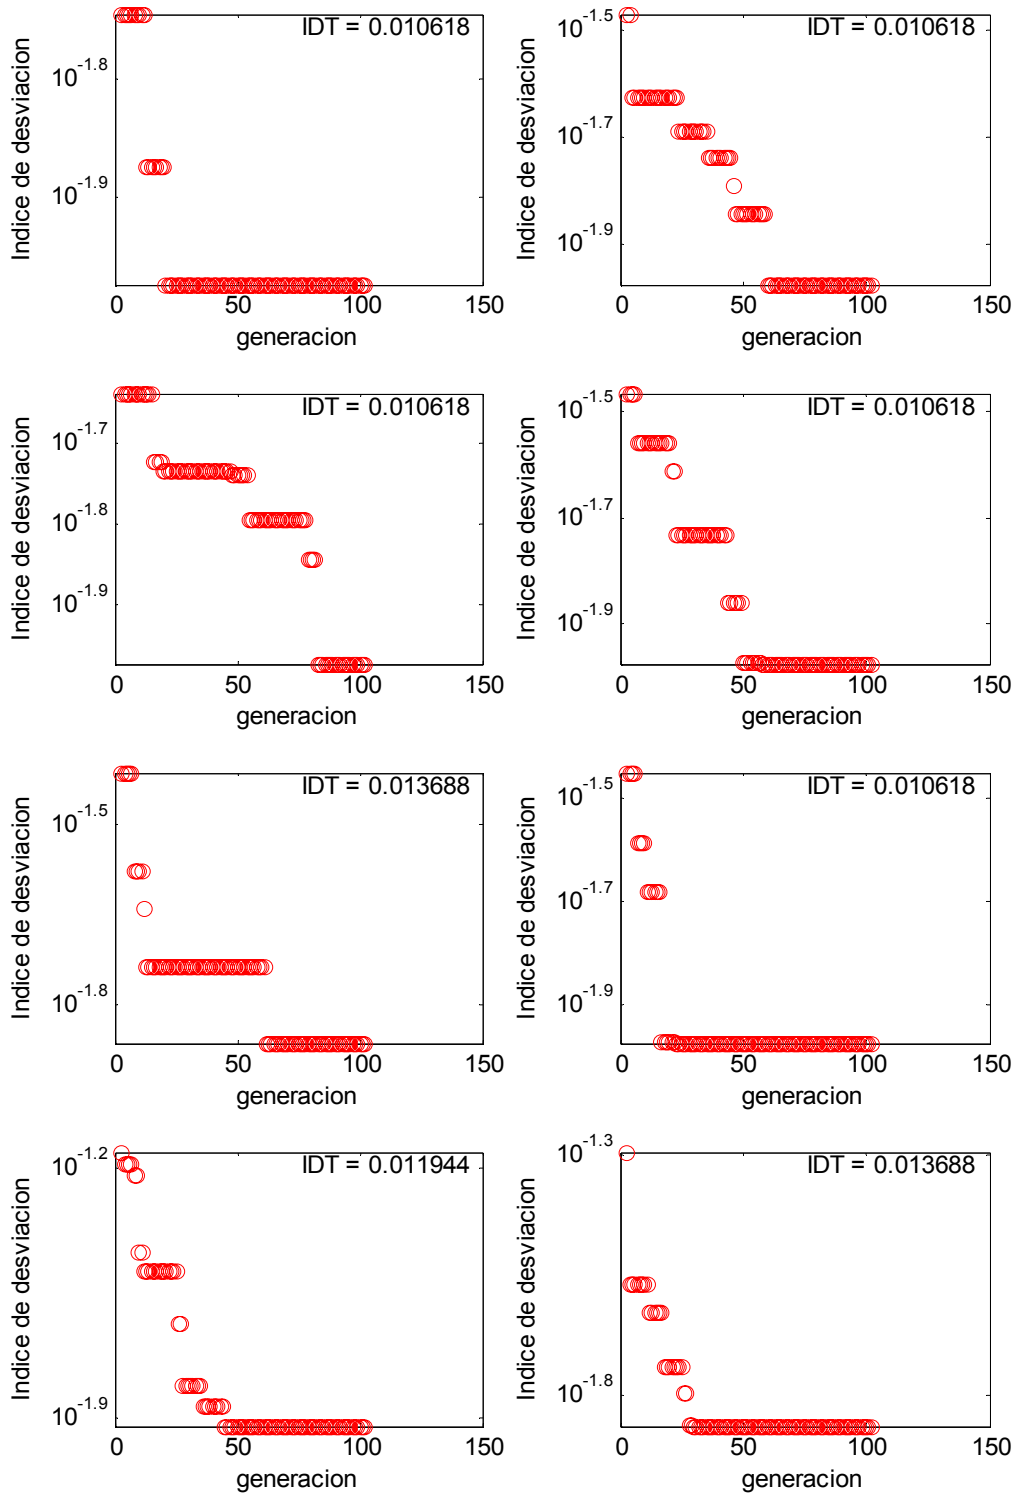


Figura 5.19 Ejecución de PAES mono-objetivo para la red IEEE30 (II)

La distribución de tensiones sería la misma que la que aparece en la figura 4.12.

A medida que la red se hace más grande, la técnica evolutiva (PAES mono-objetivo) tiene más problemas para encontrar el óptimo del problema, ya que le cuesta escapar de óptimos locales. Los resultados obtenidos con esta técnica no han sido mejores que los obtenidos con algoritmos genéticos. Aún así, la figura 5.18 muestra como el proceso de convergencia sigue siendo mucho más rápido y se acaba encontrando soluciones cercanas al valor obtenido por el AG. Se puede observar como sólo son necesarias unas 4.000 iteraciones para lograr soluciones cercanas al óptimo del AG (el cual necesitaba de 14.400).

En la tabla 5.10 se ofrece una comparativa sobre el comportamiento de ambos algoritmos para la Red RTS

Algoritmo	IDT							Tiempo ejec (s)								
Algoritmo Genético	0.012100							268								
PAES	0.012606							68								
	Tomas (%)															
Algoritmo Genético	3	9	10	0	-7	0	10	7	-3	-2	4	10	9	-2	-2	0
PAES	2	9	9	-1	-6	0	8	9	0	-6	3	9	10	1	-8	0

Tabla 5.10 Comparativa entre PAES y AG para RTS




Figura 5.20 Ejecución de PAES mono-objetivo para la red RTS

Capítulo 6

Conclusiones, aportaciones y líneas futuras de trabajo

En este último capítulo se incluye un resumen de la tesis y las conclusiones más relevantes del trabajo investigador. Asimismo se resaltan las contribuciones principales de la tesis, para concluir con las líneas futuras de investigación que se plantean a partir del mismo.

6.1 Resumen y Conclusiones

En esta tesis de doctorado se ha abordado el problema de optimización de tensiones nodales en redes eléctricas de distribución mediante el empleo de algoritmos evolutivos. El problema es de gran interés para las compañías eléctricas de distribución en cuanto que permite plantear escenarios de calidad en el perfil de tensión de la red a la vez que actuar sobre los elementos clave de la misma, todo ello con el fin de corregir las posibles desviaciones respecto de los valores nominales. También tiene un interés claro para los usuarios finales ya que permite la entrega de la energía en las mejores condiciones posibles, y así asegurar un correcto funcionamiento de los dispositivos eléctricos y electrónicos.

El problema de la corrección de tensiones ha sido tratado tradicionalmente de forma local y aislada en el conjunto de la red, de manera que no ha existido coordinación entre

los elementos encargados de actuar en los nodos para evitar los desvíos importantes de tensión. Entre los elementos que juegan un papel importantísimo, están los transformadores con cambiador de tomas, así como los condensadores síncronos, baterías de condensadores, compensadores estáticos o STATCOM¹³, etc.

En esta tesis se ha planteado una forma coordinada de trabajo que incluye a los transformadores con posibilidad de cambio en carga, como elementos centrales de trabajo. A través de este método se consigue que la red pueda estabilizarse en tensiones alrededor de los valores nominales de la misma.

Como trabajo añadido y mejora de la tesis, se ha planteado un escenario adicional multi-objetivo, mediante el cual se ha buscado una optimización no sólo de las tensiones nodales de la red, sino también de la potencia perdida en las líneas eléctricas. De esta forma, se han encontrado soluciones de compromiso en el *frente de Pareto* que reflejan diferentes posibilidades de actuación en la red, en función de decisores de alto nivel.

De manera lógica, la tesis se ha subdivido en capítulos que han tratado los diversos aspectos relacionados con el problema.

En el capítulo 2 se ha presentado de forma general, el método empleado para resolver el problema de la optimización de tensiones en redes eléctricas, así como una breve descripción de las técnicas matemáticas que han venido siendo utilizadas con anterioridad, es decir, técnicas basadas en optimización lineal. Se ha realizado una introducción a las técnicas clásicas de optimización para posteriormente describir las dos técnicas más relevantes pertenecientes a la computación evolutiva.

En el capítulo 3 se ha hecho un repaso al estado del arte existente en la optimización de tensiones en redes eléctricas. Se han analizado los métodos y técnicas usados en la actualidad, así como las mejoras y nuevas propuestas realizadas recientemente basadas en algoritmos evolutivos o convencionales que permiten abordar el problema de la optimización de tensiones

En el capítulo 4 se ha presentado la aplicación de un algoritmo genético a la resolución del problema de optimización de tensiones en redes de distribución eléctrica.

¹³http://ocw.uc3m.es/ingenieria-electrica/operacion-y-control-de-sistemas-electricos/II_OCSE_RT/node14.html/

Se mostraron las características del algoritmo genético desarrollado, haciendo hincapié en su estructura general y todas las particularidades y adaptaciones que han sido necesarias realizar para adaptarlo al este problema concreto. Posteriormente se describieron los distintos operadores que se han implementado en la resolución del problema. Se han presentado los casos estudiados y que han servido de base para la comprobación de las bondades del algoritmo desarrollado. Se han usado las redes estándar IEEE30, IEEE57 y la red RTS. Además, se presentaron los resultados obtenidos, en cada una de las redes, mostrando diferentes gráficas y tablas explicativas del proceso

En el capítulo 5 se detalló la nueva aportación basada en técnicas multi-objetivo que buscan minimizar otros factores además de la calidad en la tensión, como es la pérdida de potencia en las líneas. También se han presentado los casos estudiados usando las redes estándar IEEE30 y la red RTS. Además, se presentaron los resultados obtenidos, en cada una de las redes, mostrando diferentes gráficas y tablas explicativas del proceso.

Como conclusiones más interesantes del trabajo de tesis están:

1. **Consecución de perfiles de tensiones planos y cercanos a la tensión nominal.** La ejecución del algoritmo para cada una de las redes siempre ha encontrado una solución que permitía alcanzar tensiones nodales muy próximas a la tensión nominal de cada nodo. Puesto que no existe una solución exacta y conocida al problema, no es posible determinar si estamos en el óptimo, aunque sí que se consigue un perfil de tensiones casi plano respecto del nominal.
2. **Posiciones de las tomas.** Los transformadores con cambiadores de tomas sitúan dichas tomas de manera coordinada en aquella posición que lleva a la red a una situación de perfil óptimo. Fuera del ámbito de esta tesis queda el que las consignas sean enviadas por cualquier sistema de comunicación que se estime oportuno y que los accionadores automáticos realicen el ajuste necesario. La resolución del problema proporciona el escalón exacto que debe tener el cambiador gracias al uso de un algoritmo de base entera. Esto es una ventaja frente a otros planteamientos binarios o reales, donde el resultado puede dar lugar a posiciones infactibles o con necesidad de reparación.
3. **Tiempos de ejecución moderados.** Los resultados muestran que las ejecuciones en redes de tamaño como las IEEE probadas, no requieren de un gran gasto en tiempo de ejecución. Normalmente, no se necesita más allá de unos pocos minutos para resolver el problema en equipos de sobremesa, tipo PC, aunque

es posible conseguir mejoras sustanciales con el empleo de servidores dedicados más potentes.

4. **Posibilidad de coordinación de elementos.** Debido al enfoque natural realizado sobre el problema, la coordinación entre los diferentes elementos de la red permite obtener una solución mejor que si se actuara por separado en cada uno de los transformadores, tal y como sucede en la actualidad. En las instalaciones reales de hoy en día la regulación de la tensión sólo atiende a parámetros locales como son la tensión de entrada en el transformador AT/MT o MT/MT, corriente de salida, etc. Con el algoritmo propuesto se hace uso de información de toda la red, por lo que es posible coordinar las actuaciones a realizar y conseguir un mejor resultado global.
5. **Posibilidad de plantear escenarios de optimalidad en tensiones y potencia.** El uso de técnicas multi-objetivo ha permitido plantear nuevos escenarios de optimización, además del inicial referido a calidad de tensión. Concretamente, se han podido resolver los problemas propuestos considerando dos perspectivas opuestas como son la pérdida de potencia en las líneas y la calidad de tensión. Las parejas decisoras, resultado de la optimización, están disponibles para que cualquier agente de alto nivel pueda tomar decisiones sobre el estado más conveniente para la red, en función de criterios específicos o coyunturales.

6.2 Aportaciones realizadas

La principal aportación de la tesis es el desarrollo de un método para la maximización de la calidad de tensión en redes eléctricas de distribución.

Esta contribución general se concreta en las aportaciones que se detallan a continuación:

- Desarrollo de un algoritmo genético novedoso para la resolución del problema de optimización de tensiones en redes eléctricas. Los algoritmos genéticos se han empleado recientemente para resolver problemas relacionados con los sistemas de potencia debido a su flexibilidad en el modelado. Muchos de ellos han tenido que dedicar muchos recursos y tiempo de cómputo a la reparación de las soluciones debido a su infactibilidad. El algoritmo genético desarrollado supera estos problemas de convergencia debido a que todas las soluciones con

las que trabaja son soluciones factibles del problema, ya que se base en un población entera que refleja de forma unívoca cada una de las posiciones de los cambiadores y sólo una.

- Se contempla el trabajo coordinado y en tiempo real de todos los transformadores de la red. Este planteamiento novedoso permite que la red pueda ser gestionada de forma más eficiente desde el centro de control y, además, permite una actuación de conjunto para resolver actuaciones conflictivas o críticas en una determinada zona sin afectar a otras zonas colindantes o próximas. Por tanto, no es necesario mantener un planteamiento de trabajo basado en ajustes puntuales, geográficos o estacionales de las tomas de los cambiadores.
- Se ha implementado un nuevo algoritmo multi-objetivo que permite optimizar en tiempo real nuevas variables de importancia en la red eléctrica en cuestión. Este punto es una aportación relevante, ya que no se ha podido encontrar ningún estudio parecido en la literatura consultada. Este algoritmo está basado en la minimización del IDT y la minimización de las pérdidas de potencia en la red. La implementación fue realizada tomando como base la técnica conocida como PAES, modificándola posteriormente para añadir nuevas características que han mejorado el frente de soluciones.
- Estudio, formulación y resolución de la interrelación entre diversos aspectos de una red eléctrica como son la calidad de tensión, las pérdidas de energía y la vida útil de los cambiadores de tomas. Se ha experimentado y obtenido resultados, con la combinación de ciertos parámetros de interés en una red de potencia como los anteriormente comentados. Se ha podido comprobar como de manera habitual, la optimización de los mismos suele seguir caminos inversos, siendo mínimos unos cuando los otros son máximos y viceversa. La clarificación de esta interrelación permite al gestor de la red tener unas indicaciones claras de las actuaciones posibles que tiene al alcance para llevar a la red hacia unos estados u otros. Además, permite cuantificar claramente los costes o desviaciones de esos estados para un óptimo concreto.
- Se ha implementado la posibilidad de regulación en tiempo real de una red completa. Debido a que el algoritmo corre en unos pocos minutos, es posible realizar pasadas para cada periodo horario establecido y obtener las posiciones de las tomas de los cambiadores para ser enviadas por cualquier

método de control que se tenga establecido. Gracias a este planteamiento y a la capacidad de adquisición de datos en tiempo real de los diferentes consumos eléctricos (hoy en día es posible gracias a los modernos contadores eléctricos y a los equipos electrónicos instalados en las subestaciones eléctricas) se puede prescindir de las tradicionales sistemas de compensación de líneas basados en medidas puntuales de tensión y corriente a la entrada o salida de los transformadores.

- Se ha realizado un planteamiento y resolución horaria de la regulación de las tensiones eléctricas de una red de potencia. Para cada periodo horario se realiza una optimización del sistema para obtener el mejor índice de desviación de tensión (en el caso del algoritmo genético) o para obtener la mejor combinación de IDT y pérdidas de potencia (en el caso de algoritmo multi-objetivo).

6.3 Líneas futuras de investigación

A partir del análisis de los resultados presentados en esta tesis, se pueden sugerir las siguientes líneas futuras de trabajo

- Ampliación de las variables de control para tener en cuenta a los elementos reactivos (STATCOM, condensadores síncronos)
- Implementación de un tercer objetivo que tenga en cuenta la vida útil de los cambiadores de tomas, al objeto de minimizar el cambio inter-horario que pueda producirse durante la operación de los mismos
- Implementación paralela para mejora en sistemas de gran tamaño
- Coordinación con sistemas primarios de control de tensión
- Integración de la técnica con análisis de contingencias ($n-1$, $n-2$)
- Estudio de nuevas técnicas de optimización basadas en nuevos paradigmas heurísticos.

6.4 Publicaciones al amparo de la tesis

Los desarrollos e investigaciones efectuadas en el contexto de esta tesis doctoral, han dado lugar a las siguientes publicaciones (se citan sólo las más importantes) en revistas internacionales y congresos internacionales:

- F. G. Montoya, A. Espín, C. Gil y R. Baños. “Optimización de Tensión en Redes de Distribución utilizando Técnicas de Optimización Evolutiva”. *Inf. tecnol.*, 2006, vol.17, no.4, p.81-88. ISSN 0718-0764.
- R. Baños, C. Gil, J. Ortega, and F. G. Montoya, "A Parallel Multilevel Metaheuristic for Graph Partitioning." *Journal of Heuristics*. vol. 10: Kluwer Academic Publishers, 2004, pp. 315-336.
- R. Baños, C. Gil, J. Ortega, and F. G. Montoya, "Optimising Graph Partitions Using Parallel Evolution," *Lecture Notes in Computer Science*, vol. 2936, pp. 91-102, 2004.
- F. G. Montoya, F. Aznar, A. Espin, C. Gil, and R. Baños, "Nuevo método para la optimización de tensión en redes de distribución utilizando técnicas de optimización evolutiva," en el 8º Congresso luso Espanhol de Engenharia Electrotecnica. VilaMoura, Portugal, 2003.

Apéndice A

Tablas de entrada de datos

A.1 Datos de entrada para las redes en estudio

A.1.1 Red IEEE30

```

%%----- Power Flow Data -----%%
%% system MVA base
baseMVA = 100.0000;

%% bus data
bus = [
1  3  0.0    0.0    0.0 0.0    1  1.060  0.0    132 1  1.1 0.9;
2  2  21.7   12.7   0.0 0.0    1  1.043  0.0    132 1  1.1 0.9;
3  1  2.4    1.2    0.0 0.0    1  1.021  -7.96  132 1  1.1 0.9;
4  1  7.6    1.6    0.0 0.0    1  1.012  -9.62  132 1  1.1 0.9;
5  2  4.2    1.0    0.0 0.0    1  1.010  0.0    132 1  1.1 0.9;
6  1  0.0    0.0    0.0 0.0    1  1.010  -11.34 132 1  1.1 0.9;
7  1  22.8   10.9   0.0 0.0    1  1.002  -13.12 132 1  1.1 0.9;
8  2  0.0    0.0    0.0 0.0    1  1.010  0.0    132 1  1.1 0.9;
9  1  0.0    0.0    0.0 0.0    1  1.051  -14.38 1  1  1.1 0.9;
10 1  5.8    2.0    0.0 0.19  1  1.045  -15.97 33 1  1.1 0.9;
11 2  0.0    0.0    0.0 0.0    1  1.02  0.00  11 1  1.1 0.9;
12 1  11.2   7.5    0.0 0.0    1  1.057  -15.24 33 1  1.1 0.9;
13 2  0.0    0.0    0.0 0.0    1  1.01  0.0    11 1  1.1 0.9;
14 1  6.2    1.6    0.0 0.0    1  1.042  -16.13 33 1  1.1 0.9;
15 1  8.2    2.5    0.0 0.0    1  1.038  -16.22 33 1  1.1 0.9;
16 1  3.5    1.8    0.0 0.0    1  1.045  -15.83 33 1  1.1 0.9;
17 1  9.0    5.8    0.0 0.0    1  1.040  -16.14 33 1  1.1 0.9;
18 1  3.2    0.9    0.0 0.0    1  1.028  -16.82 33 1  1.1 0.9;
19 1  9.5    3.4    0.0 0.0    1  1.026  -17.00 33 1  1.1 0.9;
20 1  2.2    0.7    0.0 0.0    1  1.030  -16.80 33 1  1.1 0.9;
21 1  17.5   11.2   0.0 0.0    1  1.033  -16.42 33 1  1.1 0.9;
22 1  0.0    0.0    0.0 0.0    1  1.033  -16.41 33 1  1.1 0.9;
23 1  3.2    1.6    0.0 0.0    1  1.027  -16.61 33 1  1.1 0.9;
24 1  8.7    6.7    0.0 0.043 1  1.021  -16.78 33 1  1.1 0.9;
25 1  0.0    0.0    0.0 0.0    1  1.017  -16.35 33 1  1.1 0.9;
26 1  3.5    2.3    0.0 0.0    1  1.000  -16.77 33 1  1.1 0.9;
27 1  0.0    0.0    0.0 0.0    1  1.023  -15.82 33 1  1.1 0.9;
28 1  0.0    0.0    0.0 0.0    1  1.007  -11.97 132 1  1.1 0.9;
29 1  2.4    0.9    0.0 0.0    1  1.003  -17.06 33 1  1.1 0.9;
30 1  10.6   1.9    0.0 0.0    1  0.992  -17.94 33 1  1.1 0.9;
];

%% generator data
gen = [
1  0.0000  0.0000  700.0000  -700.0000  1.0000  100.0000
2  50.0000  0.0000  50.0000  -40.0000  1.0000  100.0000
5  0.0000  0.0000  40.0000  -40.0000  1.0000  100.0000
8  0.0000  0.0000  40.0000  -10.0000  1.0000  100.0000
11 0.0000  0.0000  24.0000  -6.0000  1.0000  100.0000
13 0.0000  0.0000  24.0000  -6.0000  1.0000  100.0000
];

```

```
%% branch data
branch = [
1  2  0.0192  0.0575  0.0528  0  0  0  0.0  0  1;
1  3  0.0452  0.1652  0.0408  0  0  0  0.0  0  1;
2  4  0.0570  0.1737  0.0368  0  0  0  0.0  0  1;
3  4  0.0132  0.0379  0.0084  0  0  0  0.0  0  1;
2  5  0.0472  0.1983  0.0418  0  0  0  0.0  0  1;
2  6  0.0581  0.1763  0.0374  0  0  0  0.0  0  1;
4  6  0.0119  0.0414  0.0090  0  0  0  0.0  0  1;
5  7  0.0460  0.1160  0.0204  0  0  0  0.0  0  1;
6  7  0.0267  0.0820  0.0170  0  0  0  0.0  0  1;
6  8  0.0120  0.0420  0.0090  0  0  0  0.0  0  1;
6  9  0.0      0.2080  0.0      0  0  0  1  0  1;
6  10 0.0     0.5560  0.0      0  0  0  1  0  1;
9  11 0.0     0.2080  0.0      0  0  0  0.0  0  1;
9  10 0.0     0.1100  0.0      0  0  0  0.0  0  1;
4  12 0.0     0.2560  0.0      0  0  0  1  0  1;
12 13 0.0     0.1400  0.0      0  0  0  0.0  0  1;
12 14 0.1231  0.2559  0.0      0  0  0  0.0  0  1;
12 15 0.0662  0.1304  0.0      0  0  0  0.0  0  1;
12 16 0.0945  0.1987  0.0      0  0  0  0.0  0  1;
14 15 0.2210  0.1997  0.0      0  0  0  0.0  0  1;
16 17 0.0524  0.1923  0.0      0  0  0  0.0  0  1;
15 18 0.1073  0.2185  0.0      0  0  0  0.0  0  1;
18 19 0.0639  0.1292  0.0      0  0  0  0.0  0  1;
19 20 0.0340  0.0680  0.0      0  0  0  0.0  0  1;
10 20 0.0936  0.2090  0.0      0  0  0  0.0  0  1;
10 17 0.0324  0.0845  0.0      0  0  0  0.0  0  1;
10 21 0.0348  0.0749  0.0      0  0  0  0.0  0  1;
10 22 0.0727  0.1499  0.0      0  0  0  0.0  0  1;
21 22 0.0116  0.0236  0.0      0  0  0  0.0  0  1;
15 23 0.1000  0.2020  0.0      0  0  0  0.0  0  1;
22 24 0.1150  0.1790  0.0      0  0  0  0.0  0  1;
23 24 0.1320  0.2700  0.0      0  0  0  0.0  0  1;
24 25 0.1885  0.3292  0.0      0  0  0  0.0  0  1;
25 26 0.2544  0.3800  0.0      0  0  0  0.0  0  1;
25 27 0.1093  0.2087  0.0      0  0  0  0.0  0  1;
28 27 0.0     0.3960  0.0      0  0  0  1  0  1;
27 29 0.2198  0.4153  0.0      0  0  0  0.0  0  1;
27 30 0.3202  0.6027  0.0      0  0  0  0.0  0  1;
29 30 0.2399  0.4533  0.0      0  0  0  0.0  0  1;
8  28 0.0636  0.2000  0.0428  0  0  0  0.0  0  1;
6  28 0.0169  0.0599  0.0130  0  0  0  0.0  0  1;

];
```

A.1.2 Red IEEE57

```

%%----- Power Flow Data -----%%
%% system MVA base
baseMVA = 100;

%% bus data
%bus_i type Pd      Qd      Gs Bs  area Vm      Va  baseKV  zone Vmax  Vmin
bus = [
  1  3  55      17      0  0  1  1.04      0  0  1  1.06  0.94;
  2  2  3       88      0  0  1  1.01     -1.18 0  1  1.06  0.94;
  3  2  41      21      0  0  1  0.985    -5.97 0  1  1.06  0.94;
  4  1  0        0      0  0  1  0.981    -7.32 0  1  1.06  0.94;
  5  1  13       4      0  0  1  0.976    -8.52 0  1  1.06  0.94;
  6  2  75       2      0  0  1  0.98     -8.65 0  1  1.06  0.94;
  7  1  0        0      0  0  1  0.984    -7.58 0  1  1.06  0.94;
  8  2  150      22      0  0  1  1.005    -4.45 0  1  1.06  0.94;
  9  2  121      26      0  0  1  0.98     -9.56 0  1  1.06  0.94;
  10 1  5        2      0  0  1  0.986   -11.43 0  1  1.06  0.94;
  11 1  0        0      0  0  1  0.974   -10.17 0  1  1.06  0.94;
  12 2  377      24      0  0  1  1.015   -10.46 0  1  1.06  0.94;
  13 1  18       2.3    0  0  1  0.979    -9.79 0  1  1.06  0.94;
  14 1  10.5     5.3    0  0  1  0.97     -9.33 0  1  1.06  0.94;
  15 1  22       5      0  0  1  0.988    -7.18 0  1  1.06  0.94;
  16 1  43       3      0  0  1  1.013    -8.85 0  1  1.06  0.94;
  17 1  42       8      0  0  1  1.017    -5.39 0  1  1.06  0.94;
  18 1  27.2     9.8    0  10 1  1.001   -11.71 0  1  1.06  0.94;
  19 1  3.3      0.6    0  0  1  0.97     -13.2  0  1  1.06  0.94;
  20 1  2.3      1      0  0  1  0.964   -13.41 0  1  1.06  0.94;
  21 1  0        0      0  0  1  1.008   -12.89 0  1  1.06  0.94;
  22 1  0        0      0  0  1  1.01     -12.84 0  1  1.06  0.94;
  23 1  6.3      2.1    0  0  1  1.008   -12.91 0  1  1.06  0.94;
  24 1  0        0      0  0  1  0.999   -13.25 0  1  1.06  0.94;
  25 1  6.3      3.2    0  5.9 1  0.982   -18.13 0  1  1.06  0.94;
  26 1  0        0      0  0  1  0.959   -12.95 0  1  1.06  0.94;
  27 1  9.3      0.5    0  0  1  0.982   -11.48 0  1  1.06  0.94;
  28 1  4.6      2.3    0  0  1  0.997   -10.45 0  1  1.06  0.94;
  29 1  17       2.6    0  0  1  1.01     -9.75  0  1  1.06  0.94;
  30 1  3.6      1.8    0  0  1  0.962   -18.68 0  1  1.06  0.94;
  31 1  5.8      2.9    0  0  1  0.936   -19.34 0  1  1.06  0.94;
  32 1  1.6      0.8    0  0  1  0.949   -18.46 0  1  1.06  0.94;
  33 1  3.8      1.9    0  0  1  0.947   -18.5  0  1  1.06  0.94;
  34 1  0        0      0  0  1  0.959   -14.1  0  1  1.06  0.94;
  35 1  6        3      0  0  1  0.966   -13.86 0  1  1.06  0.94;
  36 1  0        0      0  0  1  0.976   -13.59 0  1  1.06  0.94;
  37 1  0        0      0  0  1  0.985   -13.41 0  1  1.06  0.94;
  38 1  14       7      0  0  1  1.013   -12.71 0  1  1.06  0.94;
  39 1  0        0      0  0  1  0.983   -13.46 0  1  1.06  0.94;
  40 1  0        0      0  0  1  0.973   -13.62 0  1  1.06  0.94;

```

```

41 1 6.3 3 0 0 1 0.996 -14.05 0 1 1.06 0.94;
42 1 7.1 4.4 0 0 1 0.966 -15.5 0 1 1.06 0.94;
43 1 2 1 0 0 1 1.01 -11.33 0 1 1.06 0.94;
44 1 12 1.8 0 0 1 1.017 -11.86 0 1 1.06 0.94;
45 1 0 0 0 0 1 1.036 -9.25 0 1 1.06 0.94;
46 1 0 0 0 0 1 1.05 -11.89 0 1 1.06 0.94;
47 1 29.7 11.6 0 0 1 1.033 -12.49 0 1 1.06 0.94;
48 1 0 0 0 0 1 1.027 -12.59 0 1 1.06 0.94;
49 1 18 8.5 0 0 1 1.036 -12.92 0 1 1.06 0.94;
50 1 21 10.5 0 0 1 1.023 -13.39 0 1 1.06 0.94;
51 1 18 5.3 0 0 1 1.052 -12.52 0 1 1.06 0.94;
52 1 4.9 2.2 0 0 1 0.98 -11.47 0 1 1.06 0.94;
53 1 20 10 0 6.3 1 0.971 -12.23 0 1 1.06 0.94;
54 1 4.1 1.4 0 0 1 0.996 -11.69 0 1 1.06 0.94;
55 1 6.8 3.4 0 0 1 1.031 -10.78 0 1 1.06 0.94;
56 1 7.6 2.2 0 0 1 0.968 -16.04 0 1 1.06 0.94;
57 1 6.7 2 0 0 1 0.965 -16.56 0 1 1.06 0.94;

%% generator data
% bus Pg Qg Qmax Qmin Vg mBase status Pmax Pmin
gen = [
1 128.9 -16.1 200 -140 1.04 100 1 575.88 0;
2 0 -0.8 50 -17 1.01 100 1 100 0;
3 40 -1 60 -10 0.985 100 1 140 0;
6 0 0.8 25 -8 0.98 100 1 100 0;
8 450 62.1 200 -140 1.005 100 1 550 0;
9 0 2.2 9 -3 0.98 100 1 100 0;
12 310 128.5 155 -150 1.015 100 1 410 0;
];

%% branch data
% fbus tbus r x b rateA rateB rateC ratio angle status
branch = [
1 2 0.0083 0.028 0.129 9900 0 0 0 0 1;
2 3 0.0298 0.085 0.0818 9900 0 0 0 0 1;
3 4 0.0112 0.0366 0.038 9900 0 0 0 0 1;
4 5 0.0625 0.132 0.0258 9900 0 0 0 0 1;
4 6 0.043 0.148 0.0348 9900 0 0 0 0 1;
6 7 0.02 0.102 0.0276 9900 0 0 0 0 1;
6 8 0.0339 0.173 0.047 9900 0 0 0 0 1;
8 9 0.0099 0.0505 0.0548 9900 0 0 0 0 1;
9 10 0.0369 0.1679 0.044 9900 0 0 0 0 1;
9 11 0.0258 0.0848 0.0218 9900 0 0 0 0 1;
9 12 0.0648 0.295 0.0772 9900 0 0 0 0 1;
9 13 0.0481 0.158 0.0406 9900 0 0 0 0 1;
13 14 0.0132 0.0434 0.011 9900 0 0 0 0 1;
13 15 0.0269 0.0869 0.023 9900 0 0 0 0 1;
1 15 0.0178 0.091 0.0988 9900 0 0 0 0 1;
1 16 0.0454 0.206 0.0546 9900 0 0 0 0 1;
1 17 0.0238 0.108 0.0286 9900 0 0 0 0 1;
3 15 0.0162 0.053 0.0544 9900 0 0 0 0 1;
4 18 0 0.555 0 9900 0 0 0.97 0 1;

```



```

%% branch data
% fbus tbus r x b rateA rateB rateC ratio angle status
branch = [
  1 2 0.0083 0.028 0.129 9900 0 0 0 0 1;
  2 3 0.0298 0.085 0.0818 9900 0 0 0 0 1;
  3 4 0.0112 0.0366 0.038 9900 0 0 0 0 1;
  4 5 0.0625 0.132 0.0258 9900 0 0 0 0 1;
  4 6 0.043 0.148 0.0348 9900 0 0 0 0 1;
  6 7 0.02 0.102 0.0276 9900 0 0 0 0 1;
  6 8 0.0339 0.173 0.047 9900 0 0 0 0 1;
  8 9 0.0099 0.0505 0.0548 9900 0 0 0 0 1;
  9 10 0.0369 0.1679 0.044 9900 0 0 0 0 1;
  9 11 0.0258 0.0848 0.0218 9900 0 0 0 0 1;
  9 12 0.0648 0.295 0.0772 9900 0 0 0 0 1;
  9 13 0.0481 0.158 0.0406 9900 0 0 0 0 1;
  13 14 0.0132 0.0434 0.011 9900 0 0 0 0 1;
  13 15 0.0269 0.0869 0.023 9900 0 0 0 0 1;
  1 15 0.0178 0.091 0.0988 9900 0 0 0 0 1;
  1 16 0.0454 0.206 0.0546 9900 0 0 0 0 1;
  1 17 0.0238 0.108 0.0286 9900 0 0 0 0 1;
  3 15 0.0162 0.053 0.0544 9900 0 0 0 0 1;
  4 18 0 0.555 0 9900 0 0 0.97 0 1;
  4 18 0 0.43 0 9900 0 0 0.978 0 1;
  5 6 0.0302 0.0641 0.0124 9900 0 0 0 0 1;
  7 8 0.0139 0.0712 0.0194 9900 0 0 0 0 1;
  10 12 0.0277 0.1262 0.0328 9900 0 0 0 0 1;
  11 13 0.0223 0.0732 0.0188 9900 0 0 0 0 1;
  12 13 0.0178 0.058 0.0604 9900 0 0 0 0 1;
  12 16 0.018 0.0813 0.0216 9900 0 0 0 0 1;
  12 17 0.0397 0.179 0.0476 9900 0 0 0 0 1;
  14 15 0.0171 0.0547 0.0148 9900 0 0 0 0 1;
  18 19 0.461 0.685 0 9900 0 0 0 0 1;
  19 20 0.283 0.434 0 9900 0 0 0 0 1;
  21 20 0 0.7767 0 9900 0 0 1.043 0 1;
  21 22 0.0736 0.117 0 9900 0 0 0 0 1;
  22 23 0.0099 0.0152 0 9900 0 0 0 0 1;
  23 24 0.166 0.256 0.0084 9900 0 0 0 0 1;
  24 25 0 1.182 0 9900 0 0 1 0 1;
  24 25 0 1.23 0 9900 0 0 1 0 1;
  24 26 0 0.0473 0 9900 0 0 1.043 0 1;
  26 27 0.165 0.254 0 9900 0 0 0 0 1;
  27 28 0.0618 0.0954 0 9900 0 0 0 0 1;
  28 29 0.0418 0.0587 0 9900 0 0 0 0 1;
  7 29 0 0.0648 0 9900 0 0 0.967 0 1;
  25 30 0.135 0.202 0 9900 0 0 0 0 1;
  30 31 0.326 0.497 0 9900 0 0 0 0 1;
  31 32 0.507 0.755 0 9900 0 0 0 0 1;

```

32	33	0.0392	0.036	0	9900	0	0	0	0	1;
34	32	0	0.953	0	9900	0	0	0.975	0	1;
34	35	0.052	0.078	0.0032	9900	0	0	0	0	1;
35	36	0.043	0.0537	0.0016	9900	0	0	0	0	1;
36	37	0.029	0.0366	0	9900	0	0	0	0	1;
37	38	0.0651	0.1009	0.002	9900	0	0	0	0	1;
37	39	0.0239	0.0379	0	9900	0	0	0	0	1;
36	40	0.03	0.0466	0	9900	0	0	0	0	1;
22	38	0.0192	0.0295	0	9900	0	0	0	0	1;
11	41	0	0.749	0	9900	0	0	0.955	0	1;
41	42	0.207	0.352	0	9900	0	0	0	0	1;
41	43	0	0.412	0	9900	0	0	0	0	1;
38	44	0.0289	0.0585	0.002	9900	0	0	0	0	1;
15	45	0	0.1042	0	9900	0	0	0.955	0	1;
14	46	0	0.0735	0	9900	0	0	0.9	0	1;
46	47	0.023	0.068	0.0032	9900	0	0	0	0	1;
47	48	0.0182	0.0233	0	9900	0	0	0	0	1;
48	49	0.0834	0.129	0.0048	9900	0	0	0	0	1;
49	50	0.0801	0.128	0	9900	0	0	0	0	1;
50	51	0.1386	0.22	0	9900	0	0	0	0	1;
10	51	0	0.0712	0	9900	0	0	0.93	0	1;
13	49	0	0.191	0	9900	0	0	0.895	0	1;
29	52	0.1442	0.187	0	9900	0	0	0	0	1;
52	53	0.0762	0.0984	0	9900	0	0	0	0	1;
53	54	0.1878	0.232	0	9900	0	0	0	0	1;
54	55	0.1732	0.2265	0	9900	0	0	0	0	1;
11	43	0	0.153	0	9900	0	0	0.958	0	1;
44	45	0.0624	0.1242	0.004	9900	0	0	0	0	1;
40	56	0	1.195	0	9900	0	0	0.958	0	1;
56	41	0.553	0.549	0	9900	0	0	0	0	1;
56	42	0.2125	0.354	0	9900	0	0	0	0	1;
39	57	0	1.355	0	9900	0	0	0.98	0	1;
57	56	0.174	0.26	0	9900	0	0	0	0	1;
38	49	0.115	0.177	0.003	9900	0	0	0	0	1;
38	48	0.0312	0.0482	0	9900	0	0	0	0	1;
9	55	0	0.1205	0	9900	0	0	0.94	0	1;

A.1.3 Red RTS

```

%%----- Power Flow Data -----%%
%% system MVA base
baseMVA = 100.0000;

%% bus data
bus = [
1  2  108 22  0  0  1  1  0  138 1  1.1 0.9;
2  2  97  20  0  0  1  1  0  138 1  1.1 0.9;
3  1  180 37  0  0  1  1  0  138 1  1.1 0.9;
4  1  74  15  0  0  1  1  0  138 1  1.1 0.9;
5  1  71  14  0  0  1  1  0  138 1  1.1 0.9;
6  1  136 28  0  1  1  1  0  138 1  1.1 0.9;
7  2  125 25  0  0  1  1  0  138 1  1.1 0.9;
8  1  171 35  0  0  1  1  0  138 1  1.1 0.9;
9  1  175 36  0  0  1  1  0  138 1  1.1 0.9;
10 1  195 40  0  0  1  1  0  138 1  1.1 0.9;
11 1  0  0  0  0  1  1  0  230 1  1.1 0.9;
12 1  0  0  0  0  1  1  0  230 1  1.1 0.9;
13 3  300 54  0  0  1  1  0  230 1  1.1 0.9;
14 2  194 39  0  0  1  1  0  230 1  1.1 0.9;
15 2  317 64  0  0  1  1  0  230 1  1.1 0.9;
16 2  100 20  0  0  1  1  0  230 1  1.1 0.9;
17 1  0  0  0  0  1  1  0  230 1  1.1 0.9;
18 2  333 68  0  0  1  1  0  230 1  1.1 0.9;
19 1  181 37  0  0  1  1  0  230 1  1.1 0.9;
20 1  128 26  0  0  1  1  0  230 1  1.1 0.9;
21 2  0  0  0  0  1  1  0  230 1  1.1 0.9;
22 2  0  0  0  0  1  1  0  230 1  1.1 0.9;
23 2  0  0  0  0  1  1  0  230 1  1.1 0.9;
24 1  0  0  0  0  1  1  0  230 1  1.1 0.9;
25 2  108 22  0  0  1  1  0  138 1  1.1 0.9;
26 2  97  20  0  0  1  1  0  138 1  1.1 0.9;
27 1  180 37  0  0  1  1  0  138 1  1.1 0.9;
28 1  74  15  0  0  1  1  0  138 1  1.1 0.9;
29 1  71  14  0  0  1  1  0  138 1  1.1 0.9;
30 1  136 28  0  1  1  1  0  138 1  1.1 0.9;
31 2  125 25  0  0  1  1  0  138 1  1.1 0.9;
32 1  171 35  0  0  1  1  0  138 1  1.1 0.9;
33 1  175 36  0  0  1  1  0  138 1  1.1 0.9;
34 1  195 40  0  0  1  1  0  138 1  1.1 0.9;
35 1  0  0  0  0  1  1  0  230 1  1.1 0.9;
36 1  0  0  0  0  1  1  0  230 1  1.1 0.9;
37 2  265 54  0  0  1  1  0  230 1  1.1 0.9;
38 2  194 39  0  0  1  1  0  230 1  1.1 0.9;
39 2  317 64  0  0  1  1  0  230 1  1.1 0.9;
40 2  100 20  0  0  1  1  0  230 1  1.1 0.9;
41 1  0  0  0  0  1  1  0  230 1  1.1 0.9;
42 2  333 68  0  0  1  1  0  230 1  1.1 0.9;
43 1  181 37  0  0  1  1  0  230 1  1.1 0.9;
44 1  128 26  0  0  1  1  0  230 1  1.1 0.9;
45 2  0  0  0  0  1  1  0  230 1  1.1 0.9;
46 2  0  0  0  0  1  1  0  230 1  1.1 0.9;
47 2  0  0  0  0  1  1  0  230 1  1.1 0.9;
48 1  0  0  0  0  1  1  0  230 1  1.1 0.9;
49 2  108 22  0  0  1  1  0  138 1  1.1 0.9;
50 2  97  20  0  0  1  1  0  138 1  1.1 0.9;
51 1  180 37  0  0  1  1  0  138 1  1.1 0.9;

```

```

52 1 74 15 0 0 1 1 0 138 1 1.1 0.9;
53 1 71 14 0 0 1 1 0 138 1 1.1 0.9;
54 1 136 28 0 1 1 1 0 138 1 1.1 0.9;
55 2 125 25 0 0 1 1 0 138 1 1.1 0.9;
56 1 171 35 0 0 1 1 0 138 1 1.1 0.9;
57 1 175 36 0 0 1 1 0 138 1 1.1 0.9;
58 1 195 40 0 0 1 1 0 138 1 1.1 0.9;
59 1 0 0 0 0 1 1 0 230 1 1.1 0.9;
60 1 0 0 0 0 1 1 0 230 1 1.1 0.9;
61 2 265 54 0 0 1 1 0 230 1 1.1 0.9;
62 2 194 39 0 0 1 1 0 230 1 1.1 0.9;
63 2 317 64 0 0 1 1 0 230 1 1.1 0.9;
64 2 100 20 0 0 1 1 0 230 1 1.1 0.9;
65 1 0 0 0 0 1 1 0 230 1 1.1 0.9;
66 2 333 68 0 0 1 1 0 230 1 1.1 0.9;
67 1 181 37 0 0 1 1 0 230 1 1.1 0.9;
68 1 128 26 0 0 1 1 0 230 1 1.1 0.9;
69 2 0 0 0 0 1 1 0 230 1 1.1 0.9;
70 2 0 0 0 0 1 1 0 230 1 1.1 0.9;
71 2 0 0 0 0 1 1 0 230 1 1.1 0.9;
72 1 0 0 0 0 1 1 0 230 1 1.1 0.9;
73 1 0 0 0 0 1 1 0 230 1 1.1 0.9;

];

%% generator data
gen = [
1 172 28.2 80 -50 1.035 100 1 1000 0;
2 172 14 80 -50 1.035 100 1 1000 0;
7 240 51.6 180 0 1.025 100 1 1000 0;
13 285.3 122.1 240 0 1.02 100 1 1000 0;
14 0 13.7 200 -50 0.98 100 1 1000 0;
15 215 0.05 110 -50 1.014 100 1 1000 0;
16 155 25.22 80 -50 1.017 100 1 1000 0;
18 400 137.4 200 -50 1.05 100 1 1000 0;
21 400 108.2 200 -50 1.05 100 1 1000 0;
22 300 -29.76 96 -60 1.05 100 1 1000 0;
23 660 135.36 310 -125 1.05 100 1 1000 0;
25 172 28.2 80 -50 1.035 100 1 1000 0;
26 172 14 80 -50 1.035 100 1 1000 0;
31 240 51.6 180 0 1.025 100 1 1000 0;
37 285.3 122.1 240 0 1.02 100 1 1000 0;
38 0 13.7 200 -50 0.98 100 1 1000 0;
39 215 0.05 110 -50 1.014 100 1 1000 0;
40 155 25.22 80 -50 1.017 100 1 1000 0;
42 400 137.4 200 -50 1.05 100 1 1000 0;
45 400 108.2 200 -50 1.05 100 1 1000 0;
46 300 -29.76 96 -60 1.05 100 1 1000 0;
47 660 135.36 310 -125 1.05 100 1 1000 0;
49 172 28.2 80 -50 1.035 100 1 1000 0;
50 172 14 80 -50 1.035 100 1 1000 0;
55 240 51.6 180 0 1.025 100 1 1000 0;
61 285.3 122.1 240 0 1.02 100 1 1000 0;
62 0 13.7 200 -50 0.98 100 1 1000 0;
63 215 0.05 110 -50 1.014 100 1 1000 0;
64 155 25.22 80 -50 1.017 100 1 1000 0;
66 400 137.4 200 -50 1.05 100 1 1000 0;
69 400 108.2 200 -50 1.05 100 1 1000 0;
70 300 -29.76 96 -60 1.05 100 1 1000 0;
71 660 135.36 310 -125 1.05 100 1 1000 0;

];

```

```

%% branch data
branch = [
1  2  0.003  0.014  0.461  175 193 200 0  0  1;
1  3  0.055  0.211  0.057  175 208 220 0  0  1;
1  5  0.022  0.085  0.023  175 208 220 0  0  1;
2  4  0.033  0.127  0.034  175 208 220 0  0  1;
2  6  0.05  0.192  0.052  175 208 220 0  0  1;
3  9  0.031  0.119  0.032  175 208 220 0  0  1;
3  24 0.002  0.084  0  400 510 600 1  0  1;
4  9  0.027  0.104  0.028  175 208 220 0  0  1;
5  10 0.023  0.088  0.024  175 208 220 0  0  1;
6  10 0.014  0.061  2.459  175 193 200 0  0  1;
7  8  0.016  0.061  0.017  175 208 220 0  0  1;
7  27 0.042  0.161  0.044  175 208 220 0  0  1;
8  9  0.043  0.165  0.045  175 208 220 0  0  1;
8  10 0.043  0.165  0.045  175 208 220 0  0  1;
9  11 0.002  0.084  0  400 510 600 1  0  1;
9  12 0.002  0.084  0  400 510 600 1  0  1;
10 11 0.002  0.084  0  400 510 600 1  0  1;
10 12 0.002  0.084  0  400 510 600 1  0  1;
11 13 0.006  0.048  0.1  500 600 625 0  0  1;
11 14 0.005  0.042  0.088  500 600 625 0  0  1;
12 13 0.006  0.048  0.1  500 600 625 0  0  1;
12 23 0.012  0.097  0.203  500 600 625 0  0  1;
13 23 0.011  0.087  0.182  500 600 625 0  0  1;
13 39 0.01  0.075  0.158  500 600 625 0  0  1;
14 16 0.005  0.059  0.082  500 600 625 0  0  1;
15 16 0.002  0.017  0.036  500 600 625 0  0  1;
15 21 0.006  0.049  0.103  500 600 625 0  0  1;
15 21 0.006  0.049  0.103  500 600 625 0  0  1;
15 24 0.007  0.052  0.109  500 600 625 0  0  1;
16 17 0.003  0.026  0.055  500 600 625 0  0  1;
16 19 0.003  0.023  0.049  500 600 625 0  0  1;
17 18 0.002  0.014  0.03  500 600 625 0  0  1;
17 22 0.014  0.105  0.221  500 600 625 0  0  1;
18 21 0.003  0.026  0.055  500 600 625 0  0  1;
18 21 0.003  0.026  0.055  500 600 625 0  0  1;
19 20 0.005  0.04  0.083  500 600 625 0  0  1;
19 20 0.005  0.04  0.083  500 600 625 0  0  1;
20 23 0.003  0.022  0.046  500 600 625 0  0  1;
20 23 0.003  0.022  0.046  500 600 625 0  0  1;
21 22 0.009  0.068  0.142  500 600 625 0  0  1;
23 41 0.01  0.074  0.155  500 600 625 0  0  1;
25 26 0.003  0.014  0.461  175 193 200 0  0  1;
25 27 0.055  0.211  0.057  175 208 220 0  0  1;
25 29 0.022  0.085  0.023  175 208 220 0  0  1;

26 28 0.033  0.127  0.034  175 208 220 0  0  1;
26 30 0.05  0.192  0.052  175 208 220 0  0  1;
27 33 0.031  0.119  0.032  175 208 220 0  0  1;
27 48 0.002  0.084  0  400 510 600 1  0  1;
28 33 0.027  0.104  0.028  175 208 220 0  0  1;
29 34 0.023  0.088  0.024  175 208 220 0  0  1;
30 34 0.014  0.061  2.459  175 193 200 0  0  1;
31 32 0.016  0.061  0.017  175 208 220 0  0  1;
32 33 0.043  0.165  0.045  175 208 220 0  0  1;
32 34 0.043  0.165  0.045  175 208 220 0  0  1;
33 35 0.002  0.084  0  400 510 600 1  0  1;
33 36 0.002  0.084  0  400 510 600 1  0  1;
34 35 0.002  0.084  0  400 510 600 1  0  1;
34 36 0.002  0.084  0  400 510 600 1  0  1;
35 37 0.006  0.048  0.1  500 600 625 0  0  1;
35 38 0.005  0.042  0.088  500 600 625 0  0  1;
36 37 0.006  0.048  0.1  500 600 625 0  0  1;
36 47 0.012  0.097  0.203  500 600 625 0  0  1;

```

37	47	0.011	0.087	0.182	500	600	625	0	0	1;
38	40	0.005	0.059	0.082	500	600	625	0	0	1;
39	40	0.002	0.017	0.036	500	600	625	0	0	1;
39	45	0.006	0.049	0.103	500	600	625	0	0	1;
39	45	0.006	0.049	0.103	500	600	625	0	0	1;
39	48	0.007	0.052	0.109	500	600	625	0	0	1;
40	41	0.003	0.026	0.055	500	600	625	0	0	1;
40	43	0.003	0.023	0.049	500	600	625	0	0	1;
41	42	0.002	0.014	0.03	500	600	625	0	0	1;
41	46	0.014	0.105	0.221	500	600	625	0	0	1;
42	45	0.003	0.026	0.055	500	600	625	0	0	1;
42	45	0.003	0.026	0.055	500	600	625	0	0	1;
43	44	0.005	0.04	0.083	500	600	625	0	0	1;
43	44	0.005	0.04	0.083	500	600	625	0	0	1;
44	47	0.003	0.022	0.046	500	600	625	0	0	1;
44	47	0.003	0.022	0.046	500	600	625	0	0	1;
45	46	0.009	0.068	0.142	500	600	625	0	0	1;
49	50	0.003	0.014	0.461	175	193	200	0	0	1;
49	51	0.055	0.211	0.057	175	208	220	0	0	1;
49	53	0.022	0.085	0.023	175	208	220	0	0	1;
50	52	0.033	0.127	0.034	175	208	220	0	0	1;
50	54	0.05	0.192	0.052	175	208	220	0	0	1;
51	57	0.031	0.119	0.032	175	208	220	0	0	1;
51	72	0.002	0.084	0	400	510	600	1	0	1;
52	57	0.027	0.104	0.028	175	208	220	0	0	1;
53	58	0.023	0.088	0.024	175	208	220	0	0	1;
54	58	0.014	0.061	2.459	175	193	200	0	0	1;
55	56	0.016	0.061	0.017	175	208	220	0	0	1;
56	57	0.043	0.165	0.045	175	208	220	0	0	1;
56	58	0.043	0.165	0.045	175	208	220	0	0	1;
57	59	0.002	0.084	0	400	510	600	1	0	1;
57	60	0.002	0.084	0	400	510	600	1	0	1;
58	59	0.002	0.084	0	400	510	600	1	0	1;
58	60	0.002	0.084	0	400	510	600	1	0	1;
59	61	0.006	0.048	0.1	500	600	625	0	0	1;
59	62	0.005	0.042	0.088	500	600	625	0	0	1;
60	61	0.006	0.048	0.1	500	600	625	0	0	1;
60	71	0.012	0.097	0.203	500	600	625	0	0	1;
61	71	0.011	0.087	0.182	500	600	625	0	0	1;
62	64	0.005	0.059	0.082	500	600	625	0	0	1;
63	64	0.002	0.017	0.036	500	600	625	0	0	1;
63	69	0.006	0.049	0.103	500	600	625	0	0	1;
63	69	0.006	0.049	0.103	500	600	625	0	0	1;
63	72	0.007	0.052	0.109	500	600	625	0	0	1;
64	65	0.003	0.026	0.055	500	600	625	0	0	1;
64	67	0.003	0.023	0.049	500	600	625	0	0	1;
65	66	0.002	0.014	0.03	500	600	625	0	0	1;
65	70	0.014	0.105	0.221	500	600	625	0	0	1;
66	69	0.003	0.026	0.055	500	600	625	0	0	1;
66	69	0.003	0.026	0.055	500	600	625	0	0	1;
67	68	0.005	0.04	0.083	500	600	625	0	0	1;
67	68	0.005	0.04	0.083	500	600	625	0	0	1;
68	71	0.003	0.022	0.046	500	600	625	0	0	1;
68	71	0.003	0.022	0.046	500	600	625	0	0	1;
69	70	0.009	0.068	0.142	500	600	625	0	0	1;
73	21	0.012	0.097	0.203	500	600	625	0	0	1;
66	47	0.013	0.104	0.218	500	600	625	0	0	1;
71	73	0	0.009	0	722	893	893	1	0	1;

];

Apéndice B

Fundamentos matemáticos de los algoritmos genéticos

El principal problema que ha sufrido esta técnica para una completa aceptación entre la comunidad científica ha sido la ausencia de un fundamento matemático que caracterice de forma rigurosa las cualidades necesarias para cualquier técnica de optimización: (i) garantía de convergencia a la solución óptima, y (ii) tasa apropiada de convergencia hacia el óptimo.

Hasta hace poco, el único fundamento matemático sobre el que se basaba la aplicación de los algoritmos genéticos era el llamado “*Teorema de los esquemas*”. Este teorema no garantiza la convergencia hacia la solución óptima, tan sólo proporciona una cota, en cada generación, del número esperado de individuos con unas características determinadas (esquemas) y que son sometidos a unos determinados procesos de selección y mutación. Este teorema afirma que el número esperado de individuos con una medida de su calidad superior a la media aumenta exponencialmente, mientras que el número de individuos con una medida de calidad inferior a la media disminuye exponencialmente. Como se puede apreciar, este teorema no establece base matemática para asegurar que esta técnica obtiene la solución óptima y el algoritmo no queda atrapado en ningún óptimo local. Por otro lado, este teorema sólo es aplicable a algoritmos con codificación binaria y operadores de cruce y mutación específicos.

Durante los últimos años, ha habido un esfuerzo importante por parte de la comunidad científica para conseguir resultados más generales que los que proporciona el teorema de los esquemas. Como se ha mencionado anteriormente, un algoritmo genético es un proceso estocástico, fácilmente comparable con una cadena de Markov¹⁴. Recientemente, se ha conseguido un resultado relevante a través de la caracterización de un algoritmo genético como una cadena de Markov. Este resultado es la demostración de que un algoritmo genético converge, en el límite, con probabilidad 1 a la solución óptima. Esta demostración de convergencia asintótica supone un salto sustancial en el fundamento matemático de esta técnica de optimización, convirtiendo al algoritmo genético en una técnica de optimización algo más que heurística.

Una vez que se ha obtenido una prueba de convergencia global, sólo queda establecer la velocidad con que el algoritmo genético se acerca al óptimo, es decir, su tasa de convergencia.

A continuación se detallan las dos teorías que sirven de base matemática para explicar el funcionamiento de los algoritmos genéticos: (i) el teorema de los esquemas, y (ii) el análisis mediante cadenas de Markov.

B.1 Teorema de los esquemas

B.1.1 Concepto de esquema

Como ya se ha expuesto, en los algoritmos genéticos los individuos deben ser codificados mediante cadenas (s) de longitud finita (k). A cada uno de los componentes de esa cadena se le denomina gen, y puede adoptar valores de un conjunto predefinido $\{\Theta\}$. Cada uno de los valores de dicho conjunto se denomina alelo. Así pues, llamando S al espacio de todas las cadenas se cumple que:

$$\forall s \in S; s = (s_1, \dots, s_i, \dots, s_k) / \forall s_i, s_i \in \{\Theta\} \quad (\text{B.1})$$

¹⁴ Una cadena de Markov, que recibe su nombre del matemático ruso Andrei Markov, es una serie de eventos, en la cual la probabilidad de que ocurra un evento depende del evento inmediato anterior.

El tamaño del espacio de las cadenas será:

$$|S| = |\Theta|^k \quad (\text{B.2})$$

es decir, el número de cadenas posibles es igual al número de alelos elevado a la longitud de las cadenas. Mediante la introducción del concepto de esquema, es posible analizar cómo un algoritmo genético analiza el espacio de las cadenas o estructuras que representan las soluciones.

Un esquema podría definirse como un patrón de similitud entre un grupo de cadenas. Este patrón puede representar a todas las cadenas que se adaptan al patrón. Definiéndolo en sentido estricto se dirá que un esquema (H) es una cadena en la que sus componentes se definen sobre el conjunto $\{\Theta \cap \#\}$ siendo $\#$ un símbolo que representa cualquiera de los alelos de Θ . Así pues el tamaño del espacio de los esquemas es:

$$(|\Theta| + 1)^k \quad (\text{B.3})$$

Como ejemplo, el esquema de carácter binario $(0,\#, \#, 1,1,0)$, es representativo de las cadenas $(0,0,0,1,1,0)$, $(0,0,1,1,1,0)$, $(0,1,0,1,1,0)$ y $(0,1,1,1,1,0)$.

A partir de lo expuesto puede deducirse que para un espacio de cadenas de longitud k , cuyos elementos pueden tomar a valores diferentes:

- un esquema H que contenga n símbolos $\#$ representa a a^n cadenas.
- una cadena dada puede ser representada por 2^k esquemas distintos.
- en una población de P cadenas existen entre a^k y $P \times a^k$ esquemas distintos.

Dos caracterizadores fundamentales de un esquema son el orden y la longitud. Se denomina orden de un esquema $O(H)$ al número de componentes de la cadena diferentes de $\#$, es decir, fijados. Se denomina longitud de un esquema $\delta(H)$, a la diferencia entre las posiciones ocupadas por el primer y el último componente fijo (distintos de $\#$).

Como ejemplo, el esquema $(0,\#, \#, 1,1,0)$ es de orden 4 y de longitud 5.

Dado que ya es conocido que un esquema H que contenga n símbolos $\#$ representa a a^n cadenas, es fácil deducir que el número de cadenas representadas se puede calcular también como $a^{k-O(H)}$, es decir, cuanto mayor sea el orden del esquema a menos cadenas representará. El orden de un esquema será posteriormente empleado para deducir la probabilidad de supervivencia de un esquema frente al operador mutación. La longitud

del esquema es una medida de la compacidad de la representación, y se empleará para estimar la probabilidad de supervivencia del esquema frente a los cruces.

Analizando la evolución de los esquemas durante la ejecución de los algoritmos genéticos, John H. Holland dedujo dos resultados teóricos conocidos como el teorema fundamental de los algoritmos genéticos y el paralelismo implícito de los algoritmos genéticos.

B.1.1.1 Teorema fundamental o de Holland

Considérese una población de cadenas de tamaño p y de longitud k , en una generación g . Llámese $m(H, g)$ al número de cadenas de la población que se ajustan a un esquema H . El teorema de Holland, permite realizar una estimación del número de cadenas ajustadas a H que existirán en la siguiente generación de un *algoritmo genético básico*¹⁵, tras haber actuado los operadores genéticos básicos (selección, cruzamiento y mutación).

De forma simplificada puede expresarse que:

$$m(H, g + 1) = m(H, g)k_g k_s \quad (\text{B.4})$$

es decir, el número de cadenas representadas por el esquema H en una generación, será el de la generación anterior afectado por dos factores, el factor de crecimiento (k_g) y el factor de supervivencia (k_s). El factor de crecimiento mide la tendencia del esquema a aumentar su presencia en la población, estando relacionado con el operador selección. El factor de supervivencia mide la probabilidad de que el esquema sobreviva en la generación siguiente, estando relacionado con los operadores cruce y mutación.

El operador selección escoge a los individuos que se reproducirán en función su adaptación. En un algoritmo genético básico la selección se realiza por sorteo, por lo que:

¹⁵ El teorema fundamental se enuncia sobre un algoritmo genético propuesto por Goldberg, habitualmente denominado algoritmo genético básico (SGA). En un SGA la codificación de los individuos es binaria, la inicialización aleatoria, la selección por sorteo y el reemplazo inmediato. Los operadores genéticos son el cruzamiento y la mutación bit a bit. De manera ideal, se considera a los operadores cerrados (no pueden generar individuos no factibles) por lo que no existe tratamiento de individuos no válidos.

$$P(s, g) = \frac{\mu(s)}{\bar{\mu}} \quad (\text{B.5})$$

donde:

- $P(s, g)$ es la probabilidad de que la cadena s sea seleccionada con fines reproductivos en la generación g .
- $\mu(s)$ es la adaptación de la cadena s en la generación g .
- $\bar{\mu}$ es la adaptación media de todas las cadenas presentes en la población en la generación g .

De la misma manera, el número de cadenas representadas por un determinado esquema H que serán escogidas para la reproducción puede expresarse como:

$$m(H, g)_s = m(H, g) \frac{\mu(H)}{\bar{\mu}} \quad (\text{B.6})$$

donde:

- $m(H, g)_s$ es el número de cadenas representadas por un determinado esquema H que serán escogidas para la reproducción en la generación g .
- $m(H, g)$ es el número de cadenas representadas por un determinado esquema H que hay presentes en la población en la generación g .
- $\mu(H)$ es la adaptación media de las cadenas representadas por H en la generación g .
- $\bar{\mu}$ es la adaptación media de todas las cadenas presentes en la población en la generación g .

Así pues, el factor de crecimiento (k_g) se expresa como:

$$k_g = \frac{\mu(H)}{\bar{\mu}} \quad (\text{B.7})$$

Aunque un esquema sea seleccionado como reproductor, la aplicación de los operadores genéticos puede destruirlos, impidiendo que aparezcan en la generación siguiente. El factor de supervivencia (k_s) indica la probabilidad de supervivencia del esquema tras ser sometido a los operadores cruce y mutación. Su valor exacto es difícil de calcular, pero puede ser acotado analizando cómo actúan los operadores.

El cruce en un SGA es monopunto; se realiza escogiendo una posición (punto de cruzamiento) e intercambiando entre las cadenas progenitoras las subcadenas que quedan a cada lado del punto de cruzamiento. En un SGA el criterio de reemplazo empleado es el reemplazo inmediato, por el que la descendencia sustituye a los progenitores. De esta forma las cadenas seleccionadas para un cruce son sustituidas por las cadenas resultantes del cruce.

Es posible determinar la probabilidad de que las cadenas representadas por un esquema determinado H , sobrevivan al operador cruce apareciendo en la siguiente generación. Si k es la longitud de las cadenas, existen $k - 1$ posibles puntos de cruzamiento. Un punto de cruzamiento determinado provocará la ruptura del esquema, si se encuentra entre el primer y el último gen fijo (diferente de #) del esquema (figura B.1). Así pues, el número de posibles puntos de ruptura de H es $\delta(H)$, definido anteriormente como la longitud del esquema.

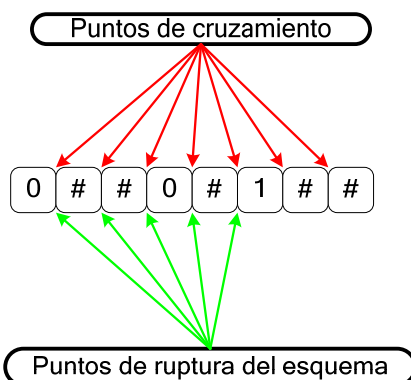


Figura B.1 Posibles puntos de ruptura de un esquema

La probabilidad de que una cadena sea sometida a cruzamiento es un parámetro del algoritmo denotado por P_c . Esto permite determinar la probabilidad de que un esquema sobreviva a la aplicación del operador cruzamiento y aparezca en la siguiente generación, siendo su valor:

$$P_s(H) \geq 1 - P_c \frac{\delta(H)}{k - 1} \quad (\text{B.8})$$

El otro operador a considerar en la supervivencia de los esquemas es la mutación. En los SGA, ésta se produce cambiando el valor de un determinado gen por otro alelo. Para que un determinado esquema H sobreviva, no debe alterarse el valor de ninguno de los genes fijos.

Así pues, la mutación no debe afectar a ninguno de los $O(H)$ elementos distintos de $\#$ del esquema. La probabilidad de que una cadena de la población mute vendrá dada por un parámetro del algoritmo denominado probabilidad de mutación (P_m).

Dado que cada esquema cuenta con $O(H)$ elementos fijos que no deben mutar, la probabilidad de que un determinado esquema sobreviva tras la mutación puede expresarse como:

$$P_m(H) = (1 - P_m)^{O(H)} \quad (\text{B.9})$$

Dado que la probabilidad de mutación suele muy inferior a la unidad ($P_m \ll 1$), la expresión anterior puede tomar la forma:

$$P_m(H) \approx 1 - P_m \cdot O(H) \quad (\text{B.10})$$

Combinando las expresiones obtenidas para el cruce y la mutación podemos estimar la capacidad de un esquema para sobrevivir a la aplicación de los operadores genéticos, es decir, k_s :

$$k_s \geq \left(1 - P_c \frac{\delta(H)}{k-1}\right) (1 - P_m \cdot O(H)) \approx 1 - P_c \frac{\delta(H)}{k-1} - P_m \cdot O(H) \quad (\text{B.11})$$

Conocidos los factores k_g y k_s , ya es posible estimar el número de cadenas representadas por un esquema H que existirán en la siguiente generación de un algoritmo genético básico:

$$m(H, g + 1) = m(H, g) k_g k_s \geq m(H, g) \frac{\mu(H)}{\bar{\mu}} \left[1 - P_c \frac{\delta(H)}{k-1} - P_m \cdot O(H)\right] \quad (\text{B.12})$$

donde:

- $m(H, g)$ es el número de cadenas de una población representadas por un determinado esquema H en la generación g .
- $\mu(H)$ es la adaptación media de las cadenas representadas por H en la generación g .
- $\bar{\mu}$ es la adaptación media de todas las cadenas presentes en la población en la generación g .
- P_c es la probabilidad de cruzamiento empleada en el algoritmo.
- $\delta(H)$ es la longitud del esquema H .

-
- k es la longitud de las cadenas que componen la población.
 - P_m es la probabilidad de mutación empleada en el algoritmo.
 - $O(H)$ es el orden del esquema H .

Esta expresión constituye el **Teorema Fundamental de los Algoritmos Genéticos**, que podría enunciarse diciendo, que tras la actuación de los operadores genéticos básicos sobre una población de cadenas en una generación g , el número de cadenas representadas por un esquema determinado (H) esperado en la generación $g+1$, viene dado por la expresión anterior.

A partir de lo expuesto pueden extraerse las siguientes conclusiones válidas en la práctica [Pérez 96]:

- La evolución de la presencia de un esquema en la población, es una progresión geométrica que depende del grado de adaptación de las cadenas representadas por el esquema (k_g), y de la longitud y del orden del mismo (k_s). Los esquemas con una adaptación relativa superior a la media ($k_g > 1$) evolucionarán aumentando su presencia en la población, disminuyendo la de los esquemas menos adaptados. Asimismo, los esquemas más cortos y de menor orden, harán que k_s se aproxime a 1, aumentando las probabilidades de supervivencia.
- La selección permite incrementar la presencia de esquemas bien adaptados en la población, reduciendo la presencia de los menos válidos. La selección no provoca la aparición de nuevos esquemas en la población.
- El operador cruce permite el intercambio de información entre individuos. La información con más probabilidad de compartirse es la que se presenta en forma de esquemas cortos y de bajo orden. Este operador puede provocar la aparición de nuevos esquemas en la población. Es el operador fundamental de los algoritmos genéticos.
- El operador mutación introduce variabilidad en la población. Puede provocar la aparición de nuevos esquemas y la desaparición de otros. Puede considerarse un operador secundario con respecto al cruce.

Los algoritmos genéticos exploran el espacio de soluciones mediante la yuxtaposición de esquemas bien adaptados, cortos y de bajo orden. A este tipo de esquemas se les denomina bloques constructivos [Pérez 96, Srinivas 94].

B.1.2 Paralelismo Implícito

Como se ha indicado anteriormente, cada cadena de una población de P cadenas de longitud k , puede ser representada por 2^k esquemas. Para que una cadena sea representada por un esquema, basta con que en cada componente el esquema tenga el mismo alelo que la cadena o bien un símbolo # (figura B.2).

En una población, cuyos elementos pueden tomar a valores diferentes, existen entre a^k y $P \times a^k$ esquemas distintos. Algunos de estos esquemas (sobre todo los bloques constructivos) serán procesados de modo útil, aumentando su presencia y sobreviviendo a la aplicación de los operadores genéticos.




Figura B.2 Esquemas representativos de una cadena de longitud cuatro.

Holland fue capaz de determinar, asumiendo una serie de hipótesis generales [Goldberg 89], que aunque en principio un algoritmo genético procesa sólo P cadenas en cada generación, se obtiene información útil de al menos P^3 esquemas, y por lo tanto de las cadenas por ellos representadas. Es decir, en el proceso evolutivo secuencial se estudian en cada paso P cadenas, pero simultánea y paralelamente, se estudian P^3 esquemas. Esta propiedad de búsqueda en paralelo, denominada paralelismo implícito, es la que proporciona mayor robustez a los algoritmos genéticos en comparación con otras técnicas de búsqueda ciega.

El planteamiento seguido por Holland para llegar a esta conclusión es el siguiente:

Dada una población de P cadenas sometidas a un SGA, es posible determinar la longitud de los esquemas $\delta(H)$ cuyo porcentaje de supervivencia sea uno concreto, por ejemplo, del 40%, mediante la expresión

$$1 - P_c \frac{\delta(H)}{k-1} - P_m \cdot O(H) = 0,4 \quad (\text{B.13})$$

Llamando k_p a dicha longitud, es posible afirmar que aquellos esquemas cuya longitud $\delta(H)$ sea menor o igual que k_p , tendrán un porcentaje de supervivencia mayor o igual a 40%, puesto que los esquemas de menor longitud tendrán mayores posibilidades de sobrevivir. A partir de esta premisa, Holland plantea la cuestión de determinar cuántos de esos esquemas con $\delta(H) \leq k_p$, son realmente procesados cada generación en una población de P cadenas.

Para poder establecer un estimador del límite inferior de la cantidad de esquemas procesados, Holland estudió el orden de los esquemas como característica que le sirviera para diferenciarlos y cuantificarlos. En primer lugar estableció el límite superior como

$$P \cdot 2^{k_p+1}(k - (k_p + 1) + 1) \quad (\text{B.14})$$

El número de esquemas de longitud $\delta(H) \leq k_p$ sigue una distribución binomial, por lo que la mitad de ellos poseerán un orden inferior a $(k_p+1)/2$ y la otra mitad, superior. Llamando P_p al número de estos últimos, es posible determinar que

$$P_p = \frac{P \cdot 2^{k_p+1}(k - (k_p + 1) + 1)}{2} = P \cdot 2^{k_p}(k - (k_p + 1) + 1) \quad (\text{B.15})$$

Así, P_p es un estimador que proporciona un límite inferior del número de esquemas de longitud $\delta(H) \leq k_p$ que se procesan en una población de P cadenas. Es un límite inferior dado que sólo considera aquellos esquemas cuyo orden es superior a $(k_p + 1)/2$. Si se da a P un valor adecuado, $P = 2^{k_p/2}$, se obtiene que

$$P_p = (k - (k_p + 1) + 1) \cdot P^3 \quad (\text{B.16})$$

indicador que depende del tamaño de la población al cubo.

B.1.3 Análisis mediante cadenas de Markov

Para analizar un algoritmo genético mediante cadenas de Markov se considera que el mismo opera sobre una población de soluciones con una medida determinada de su calidad, relacionada con la función objetivo a optimizar. Se usará alguna regla de selección para determinar los individuos que serán los padres de la nueva generación de soluciones. Esta selección se basa en la medida de calidad de los individuos. Además, también se considerarán distintos operadores que introduzcan diversidad en las poblaciones. Las nuevas soluciones obtenidas a partir de los operadores de selección y cruce (soluciones hijas) sustituyen a las soluciones de la población actual (soluciones padres). Este proceso se repite durante sucesivas generaciones hasta encontrar la solución óptima global o hasta cumplir un determinado criterio de convergencia.

Como se puede apreciar, este marco de referencia es lo suficientemente general para permitir incluir en él cualquier tipo de problema. No hay ningún motivo para limitarlo a una codificación binaria, ni se deben excluir los operadores de cruce distintos del cruce de un solo punto. Más importante aún, este marco es extensible a problemas con restricciones. Estas son las diferencias de partida de este análisis con respecto al del teorema de los esquemas.

Una cadena de Markov es un proceso estocástico invariante en el tiempo y sin memoria [Hillier 05]. Para cada posible estado del proceso, las probabilidades de transición entre estados no varían con las generaciones. Además, estas probabilidades sólo dependen del estado actual y no de estados anteriores (ausencia de memoria). Un algoritmo genético que cumpla los requisitos expuestos anteriormente se puede modelar mediante una cadena de Markov de dimensión finita. En la literatura técnica se pueden encontrar diversos intentos de analizar estos algoritmos mediante cadenas de Markov [Fogel 06, Davis 93].

Una cadena de Markov se caracteriza mediante un vector π y una matriz de transición P . El vector π es un vector fila en el que cada elemento representa la probabilidad de que la cadena se encuentre inicialmente en un estado determinado. Cada elemento (i,j) de la matriz de transición P representa la probabilidad de pasar del estado i al estado j en una única transición. Por lo tanto, el producto πP es otro vector fila en el que cada componente indica la probabilidad de estar en cada estado después de una transición. Finalmente, la probabilidad de estar en cada estado tras k transiciones viene dada por πP^k .

Para ilustrar el funcionamiento de las cadenas de Markov, a continuación se presenta un ejemplo sencillo. Considérese un sistema que posee dos estados, llamados 0 y 1, respectivamente. La probabilidad de estar inicialmente en el estado 0 es q , por lo que la probabilidad de estar inicialmente en el estado 1 es la complementaria, $1 - q$. Supóngase que el sistema cambia de estado aleatoriamente siguiendo la siguiente regla: si el sistema se encuentra en el estado 0 puede pasar al estado 1 con probabilidad p o quedarse en el estado 0 con probabilidad $1 - p$; si el sistema se encuentra en el estado 1 debe permanecer en ese estado. Este ejemplo puede representar el lanzamiento de una moneda, donde el estado 0 es la cara de la moneda y el estado 1 representa la cruz. Si ha salido cara, se vuelve a lanzar la moneda. La probabilidad de que salga cruz es p y de que vuelva a salir cara es $1 - p$. Si alguna vez sale cruz no se vuelve a lanzar la moneda, permaneciendo en el estado 1. La matriz de transición de esta cadena viene dada por

$$P = \begin{array}{cc|c} & \begin{array}{cc} 0 & 1 \end{array} & \text{Estados} \\ \begin{array}{c} 0 \\ 1 \end{array} & \begin{bmatrix} 1-p & p \\ 0 & 1 \end{bmatrix} & \begin{array}{c} 0 \\ 1 \end{array} \end{array} \quad (\text{B.17})$$

y el vector π es igual a:

$$\pi = [q \quad 1 - q] \quad (\text{B.18})$$

La matriz tras k transiciones es igual a:

$$P^k = \begin{bmatrix} (1-p)^k & 1 - (1-p)^k \\ 0 & 1 \end{bmatrix} \quad (\text{B.19})$$

Por último, la probabilidad de estar en cada estado tras k transiciones viene dada por πP^k :

$$\pi P^k = [q \quad 1 - q] \begin{bmatrix} (1-p)^k & 1 - (1-p)^k \\ 0 & 1 \end{bmatrix} = [q(1-p)^k \quad 1 - q(1-p)^k] \quad (\text{B.20})$$

En el análisis de un algoritmo genético mediante cadenas de Markov, los estados de la cadena se definen como cada posible configuración de una población. Si se supone una codificación binaria, n es el número de individuos de la población y m es la dimensión de cada individuo, el número de estados es 2^{nm} . Para casos realistas, donde n y m son elevados, el número de estados es extraordinariamente grande. A pesar de su dimensión, el número de estados es finito, por lo que la cadena de Markov es de dimensión finita.

Finalmente, otra propiedad que es necesaria para analizar un algoritmo genético mediante cadenas de Markov es la irreducibilidad de una cadena. Una cadena de Markov es irreducible si todos los estados se comunican entre sí. Dos estados i y j se comunican, si al menos hay un camino de i a j y viceversa.

A continuación se analizan algoritmos genéticos no elitistas y elitistas mediante cadenas de Markov.

B.1.4 Algoritmos genéticos no elitistas

Un algoritmo genético definido sólo con selección y cruce no es irreducible ya que hay estados absorbentes, es decir, estados que no se comunican con ningún otro estado. En este tipo de algoritmos un estado absorbente será aquél en el que todos los miembros de la población son idénticos. Bajo estas condiciones el operador cruce sólo produce individuos de la población original. Los estados restantes serán transitorios.

A medida que el número de iteraciones o generaciones avanza, las únicas transiciones posibles en una cadena de este tipo son: (i) transición a un estado absorbente, (ii) transición a un estado desde el que puede haber una transición a un estado absorbente con probabilidad no nula, y (iii) transición a un estado desde donde no hay posibilidad de llegar a un estado absorbente en un único paso. Por lo tanto, la matriz P se puede expresar como:

$$P = \begin{bmatrix} I_a & 0 \\ R & Q \end{bmatrix} \quad (\text{B.21})$$

donde I_a es una matriz identidad de tamaño $a \times a$ que representa a los estados absorbentes (a es el número de estados absorbentes), R es una submatriz de transición de tamaño $t \times a$ que describe las transiciones a un estado absorbente (t es el número de estados transitorios) y Q es una matriz de tamaño $t \times t$ que expresa las transiciones a estados transitorios.

El comportamiento de una cadena de este tipo cumple:

$$P^k = \begin{bmatrix} I_a & 0 \\ N_k R & Q^k \end{bmatrix} \quad (\text{B.22})$$

donde P^k es la matriz de probabilidades después de k transiciones, $N_k = I_t + Q + Q^2 + \dots + Q^{k-1}$, e I_t es la matriz identidad de tamaño $t \times t$.

Para analizar el comportamiento de esta cadena de Markov se van a definir una serie de conceptos, que serán útiles en posteriores demostraciones.

Norma de una matriz. Si A es un vector fila, su norma, $\|A\|$, se define como la suma de los valores absolutos de los elementos de A . Si A es una matriz, su norma, $\|A\|$, es el máximo de las normas de las filas de A . Por lo tanto:

$$\|A\| = \max_{1 \leq i \leq u} \sum_{j=1}^v |A_{ij}| \quad (\text{B.23})$$

donde A_{ij} es el elemento (i,j) , u es el número de filas y v es el número de columnas de la matriz A , respectivamente.

Esta norma, tal y como se ha definido, presenta las siguientes propiedades:

1. $|A_{ij}| \leq \|A\|$
2. $\|A + B\| \leq \|A\| + \|B\|$
3. $\|AB\| \leq \|A\| \cdot \|B\|$

para cualesquiera matrices cuadradas A y B .

Lema Para cualquier entero positivo n , existen las constantes $b > 0$ y r , $0 < r < 1$, tales que $\|Q^n\| \leq br^n$, siendo Q la submatriz definida en (B.21).

El marco matemático anterior permite establecer el siguiente teorema sobre la convergencia asintótica de la cadena de Markov correspondiente a un algoritmo genético.

Teorema (Convergencia asintótica). En el límite, cuando k tiende a infinito, se demuestra que [Goodman 06]:

$$\lim_{k \rightarrow \infty} P^k = \begin{bmatrix} I_a & 0 \\ (I_t - Q)^{-1} R & 0 \end{bmatrix} \quad (\text{B.24})$$

o igualmente que $Q^k \rightarrow 0$, $N^k \rightarrow (I_t - Q)^{-1}$ y la matriz $(I_t - Q)^{-1}$ existe.

Teorema (Probabilidad de absorción). En el límite, la probabilidad de absorción, es decir, de llegar a un estado absorbente es 1:

$$\lim_{k \rightarrow \infty} \Pr(\alpha \in A) = 1 \quad (\text{B.25})$$

Por lo tanto, para un número suficientemente grande de generaciones, la cadena llegará con probabilidad 1 a un estado absorbente. Sin embargo, hay que destacar que

hay una probabilidad no nula de que el estado absorbente al que se converja no sea óptimo, es decir, que no contenga la solución óptima, a no ser que todos los estados absorbentes sean globalmente óptimos.

En algoritmos de este tipo el número de estados absorbentes es 2^m (m es la longitud de los individuos), es decir, es el número de individuos distintos que se pueden obtener. Dado que el número total de estados es 2^{mn} , la densidad de estados absorbentes, $2^{m(1-n)}$, decrece exponencialmente con el tamaño de los individuos, pero a su vez el número real de estados absorbentes aumenta exponencialmente.

Si las transiciones entre estados tienen la misma probabilidad, el tiempo requerido para encontrar un estado absorbente también aumenta en el límite exponencialmente con el tamaño de los individuos. Cuando se encuentra un estado absorbente, la probabilidad de que sea globalmente óptimo disminuye en el límite exponencialmente con m (ya que disminuye la proporción entre el número de estados que contienen la solución óptima y el número total de estados). Para matrices de transición donde las probabilidades no son iguales, estas probabilidades determinan el tiempo medio de espera para alcanzar un estado absorbente (tiempo de absorción) y la probabilidad de encontrar un óptimo global frente a la probabilidad de converger a un óptimo local. Además, en el caso de que algún elemento (gen) de los individuos de la población sea fijado para todos ellos a un valor que no se encuentra en la solución óptima, dicha solución no se encontrará nunca.

Si se introduce el operador mutación, los estados absorbentes (definidos así sólo empleando el operador de cruce) pasan a ser estados transitorios. Por tanto, todos los estados de la cadena que contengan la solución óptima pueden ser agrupados en un único estado. El tiempo medio de llegada a este estado desde un estado transitorio cualquiera i se calcula mediante [Goodman 06]:

$$\tau_i = \sum_{j \in T} N_{ij} \quad (\text{B.26})$$

donde τ_i es el tiempo medio de llegada desde el estado i al estado que contiene la solución óptima, N_{ij} es el elemento (i,j) de la matriz $(I_t - Q)^{-1}$, y T es el conjunto de todos los estados transitorios.

Si la probabilidad de mutación es muy baja, predominará el efecto del operador cruce frente al de la mutación. El conjunto de estados así generados será muy parecido al conjunto de estados originados por un algoritmo donde sólo interviene el operador cruce. El operador mutación sólo serviría para evitar la pérdida de información que puede

impedir que se alcance la solución óptima. Por tanto, si se define un estado meta-estable como un estado absorbente de la cadena que caracteriza a un algoritmo genético basado exclusivamente en un operador cruce, el camino seguido por el algoritmo genético pasará por estados meta-estables donde esperará a que la mutación le permita pasar a otro estado meta-estable. Estas transiciones entre estados meta-estables pueden requerir un tiempo de espera muy alto dependiendo del número de elementos que deban ser mutados simultáneamente. Estos estados meta-estables están asociados con la convergencia prematura a un óptimo local, y los tiempos de espera dependen de las características del problema.

B.1.4.2 Algoritmos genéticos elitistas

Si se introduce el operador elitismo, es decir, en cada población se mantiene la mejor solución encontrada a lo largo de las generaciones, se demuestra que el algoritmo genético converge con probabilidad 1 a la solución óptima. Teniendo en cuenta este operador, se definen todos los estados que contienen la solución óptima como un único estado. De esta forma, la matriz de transiciones de la cadena de Markov resultante se puede expresar como:

$$P = \begin{bmatrix} 1 & 0 \\ R & Q \end{bmatrix} \quad (\text{B.27})$$

donde el 1 representa el único estado absorbente, R es una matriz de transición estrictamente positiva de tamaño $t \times 1$ y Q es una matriz de transición de tamaño $t \times t$. Sólo hay un estado absorbente, que incluye a todas las poblaciones que contienen la solución óptima, mientras que el resto de estados son transitorios.

La convergencia global asintótica es clara ya que cada estado transitorio alcanzará un estado absorbente. Esta matriz es un caso particular de la matriz de transición cuando no había operador elitista, por lo que, en el límite:

$$\lim_{k \rightarrow \infty} P^k = \begin{bmatrix} 1 & 0 \\ (I_t - Q)^1 R & 0 \end{bmatrix} \quad (\text{B.28})$$

Este resultado se puede resumir en el siguiente teorema, el cual hace uso de los teoremas enunciados en B.1.4.

Teorema (Probabilidad de absorción). Después de k generaciones, y cumpliendo que $k \rightarrow \infty$, un algoritmo genético con operador elitista llega a un estado α . La

probabilidad de que este estado sea el estado absorbente y, por lo tanto, contenga la solución óptima, es 1.

Como se ha visto mediante el análisis de Markov, la convergencia asintótica al óptimo global se puede garantizar con la única condición de incluir un operador que siempre mantenga la mejor solución de la población y un operador que permita obtener cualquier estado desde cualquier otro (o a través de estados intermedios).

Por otro lado, si el algoritmo se basa en un operador que no puede alcanzar todos los estados (operador de cruce típico) o un operador de selección que puede perder la mejor solución en cualquier generación (selección proporcional), la convergencia global asintótica no está garantizada.

Un ejemplo bastante aclaratorio de la aplicación de las cadenas de Markov se puede encontrar en [Arroyo 00]. El problema que se resuelve es una programación horaria de dos centrales y una hora y se emplea un algoritmo genético con un tamaño de la población igual a dos.

Bibliografía

1. [Miranda 94] V. Miranda, J. V. Ranito, and L. M. Proenca, "Genetic Algorithms in Optimal Multistage Distribution Network Planning," *Ieee Transactions on Power Systems*, vol. 9, pp. 1927-1933, Nov 1994.
2. [Arroyo 02] J. M. Arroyo and A. J. Conejo, "A parallel repair genetic algorithm to solve the unit commitment problem," *Ieee Transactions on Power Systems*, vol. 17, pp. 1216-1224, Nov 2002.
3. [Augugliaro 04] A. Augugliaro, L. Dusonchet, S. Favuzza, and E. R. Sanseverino, "Voltage regulation and power losses minimization in automated distribution networks by an evolutionary multiobjective approach," *Ieee Transactions on Power Systems*, vol. 19, pp. 1516-1527, Aug 2004.
4. [Furong 05] L. Furong, J. D. Pilgrim, C. Dabeedin, A. Chebbo, and R. K. Aggarwal, "Genetic algorithms for optimal reactive power compensation on the national grid system," *Power Systems, IEEE Transactions on*, vol. 20, pp. 493-500, 2005.
5. [Aznar 99] F. Aznar, "Automatización de la regulación de tensión en transformadores AT/BT al objeto de optimizar las tensiones en clientes de una red MT/BT.," in *Ingeniería Eléctrica*. vol. Ph. D. Valencia: Universidad Politécnica de Valencia, 1999.
6. [Ailleret 56] P. Ailleret, "L introduction de la mesure dans la notion de la qualité du service d une distribution d electricité, et son intérêt au point de vue de la conception des réseaux.," *Bulletion de la Société Française des Électriciens*, vol. 7, 1956.
7. [Dantzig 97] G. B. Dantzig and M. N. Thapa, *Linear programming*. New York: Springer, 1997.
8. [Gass 03] S. I. Gass, *Linear programming: methods and applications*. New York: Dover Publications, 2003.
9. [Wolpert 97] D. H. Wolpert and W. G. Macready, "No free lunch theorems for optimization," *Evolutionary Computation, IEEE Transactions on*, vol. 1, pp. 67-82, 1997.
10. [Kirkpatrick 83] S. Kirkpatrick, C. D. Gelatt, and M. P. Vecchi, "Optimization by Simulated Annealing," *Science*, vol. 220, pp. 671-680, 1983.
11. [Cantú-Paz 00] E. Cantú-Paz, *Efficient and accurate parallel genetic algorithms*. Boston, Mass.: Kluwer Academic Publishers, 2000.
12. [Fogel 66] L. J. Fogel, A. J. Owens, and M. J. Walsh, *Artificial intelligence through simulated evolution*. New York: Wiley, 1966.
13. [Fogel 99] L. J. Fogel, *Intelligence through simulated evolution : forty years of evolutionary programming*. New York: Wiley, 1999.
14. [Bäck 96] T. Bäck, *Evolutionary algorithms in theory and practice : evolution strategies, evolutionary programming, genetic algorithms*. New York: Oxford University Press, 1996.
15. [Rechenberg 73] I. Rechenberg, *Evolutionsstrategie; Optimierung technischer Systeme nach Prinzipien der biologischen Evolution*. Stuttgart-Bad Cannstatt: Frommann-Holzboog, 1973.

16. [Schwefel 77] H.-P. Schwefel, *Numerische Optimierung von Computer-Modellen mittels der Evolutionsstrategie : mit einer vergleichenden Einführung in die Hill-Climbing- und Zufallsstrategie*. Basel ; Stuttgart: Birkhäuser, 1977.
17. [Schwefel 81] H.-P. Schwefel, *Numerical optimization of computer models*. Chichester ; New York: Wiley, 1981.
18. [Goldberg 89] D. E. Goldberg, *Genetic algorithms in search, optimization, and machine learning*. Reading, Mass.: Addison-Wesley Pub. Co., 1989.
19. [Holland 75] J. H. Holland, *Adaptation in natural and artificial systems : an introductory analysis with applications to biology, control, and artificial intelligence*. Ann Arbor: University of Michigan Press, 1975.
20. [Buckles 86] B. P. Buckles and F. Petry, *Genetic algorithms*. Los Alamitos, Calif: IEEE Computer Society Press, 1986.
21. [Fogel 95] D. B. Fogel and I. N. N. Council, *Evolutionary computation : toward a new philosophy of machine intelligence*. New York: IEEE Press, 1995.
22. [Koza 03] J. R. Koza, *Genetic programming IV : routine human-competitive machine intelligence*. Norwell, Mass.: Kluwer Academic Publishers, 2003.
23. [Koza 99] J. R. Koza, *Genetic programming III : darwinian invention and problem solving*. San Francisco: Morgan Kaufmann, 1999.
24. [Koza 94] J. R. Koza, *Genetic programming II : automatic discovery of reusable programs*. Cambridge, Mass.: MIT Press, 1994.
25. [Koza 92] J. R. Koza, *Genetic programming : on the programming of computers by means of natural selection*. Cambridge, Mass.: MIT Press, 1992.
26. [van Laarhoven 87] P. J. M. van Laarhoven and E. H. L. Aarts, *Simulated annealing : theory and applications*. Dordrecht ; Boston; Norwell, MA, U.S.A.: D. Reidel; Sold and distributed in the U.S.A. and Canada by Kluwer Academic Publishers, 1987.
27. [Ronald 97] S. Ronald, "Robust encodings in genetic algorithms: a survey of encoding issues," *Proceedings of 1997 IEEE International Conference on Evolutionary Computation ICEC 97 Cat No 97TH8283*, pp. 43-8, 1997.
28. [Bramlette 91] M. F. Bramlette, "Initialization, Mutation and Selection Methods in Genetic Algorithms for Function Optimization," in *Proc. of the Fourth International Conference on Genetic Algorithms*, San Diego, CA, 1991, pp. 100-107.
29. [Grefenstette 87] J. J. Grefenstette and L. Davis, "'Incorporating problem specific knowledge into genetic algorithms'," in *"Genetic Algorithms and Simulated Annealing"*, Anonymous, Ed. "Los Altos": "Morgan Kaufmann", 1987, pp. "42-60".
30. [De Jong 75] K. A. D. De Jong, "An analysis of the behavior of a class of genetic adaptive systems," 1975.
31. [Baker 85] J. E. Baker, "Adaptive Selection Methods for Genetic Algorithms," in *Proc. of the International Conference on Genetic Algorithms and Their Applications*, Pittsburgh, PA, 1985, pp. 101-111.
32. [Whitley 89] D. Whitley, "The GENITOR Algorithm and Selection Pressure: Why Rank-Based Allocation," in *Proc. of the Third Int. Conf. on Genetic Algorithms*, San Mateo, CA, 1989, pp. 116-121.
33. [Baker 87] J. E. Baker, "Reducing Bias and Inefficiency in the Selection Algorithm," in *Proc. of the 2nd Intl Conf on GA*, 1987, pp. 14-21.
34. [Goldberg 90] D. E. Goldberg and K. Deb, "A Comparative Analysis of Selection Schemes Used in Genetic Algorithms," in *FOGA*, 1990, pp. 69-93.
35. [Booker 82] L. B. Booker, "Intelligent Behavior as an Adaptation to the Task Environment," Anonymous, Ed., 1982, p. 342.
36. [Brindle 81] A. Brindle and S. University of Alberta. Dept. of Computing, "Genetic algorithms for function optimization," in *Dept. of Computing Science*, Anonymous, Ed. Edmonton: University of Alberta, 1981, p. 193.

37. [Goldberg 90] D. E. Goldberg, "A note on Boltzmann tournament selection for genetic algorithms and population-oriented simulated annealing," *Complex Systems*, vol. 4, pp. 445-60, 1990.
38. [Wetzel 83] A. Wetzel, "Evaluation of the Effectiveness of Genetic Algorithms in Combinatorial Optimization," University of Pittsburgh, 1983.
39. [Brindle 81] A. Brindle and S. University of Alberta. Dept. of Computing, *Genetic algorithms for function optimization*. Edmonton: Dept. of Computing Science, University of Alberta, 1981.
40. [Dumitrescu 00] D. Dumitrescu, B. Lazzerini, L. C. Jain, and A. Dumitrescu, "*Evolutionary Computation*": "CRC Press International", 2000.
41. [Kuo 93] T. Kuo and S.-Y. Hwang, "A Genetic Algorithm with Disruptive Selection," in *Proc. of the Fifth Int. Conf. on Genetic Algorithms*, San Mateo, CA, 1993, pp. 65-69.
42. [Michalewicz 92] Z. Michalewicz, *Genetic algorithms + data structures = evolution programs*. Berlin ; New York: Springer-Verlag, 1992.
43. [Hillis 90] W. D. Hillis, "Coevolving Parasites Improve Simulated Evolution as an Optimization Procedure," *Physica D*, vol. 42, pp. 228-234, Jun 1990.
44. [Angeline 93] P. J. Angeline and J. B. Pollack, "Competitive Environments Evolve Better Solutions for Complex Tasks," in *Proc. of the Fifth Int. Conf. on Genetic Algorithms*, San Mateo, CA, 1993, pp. 264-270.
45. [Sebald 94] A. V. Sebald and J. Schlenzig, "Minimax Design of Neural-Net Controllers for Highly Uncertain Plants," *Ieee Transactions on Neural Networks*, vol. 5, pp. 73-82, Jan 1994.
46. [Bäck 91] T. Bäck and F. Hoffmeister, "Extended Selection Mechanisms in Genetic Algorithms," *Proceedings of the Fourth International Conference on Genetic Algorithms (ICGA' 91)*, pp. 92-99, 1991.
47. [Jones 95] T. Jones, "Crossover, Macromutationand, and Population-Based Search," in *ICGA*, 1995, pp. 73-80.
48. [Syswerda 89] G. Syswerda, "Uniform crossover in genetic algorithms," *Proceeding of the Third International Conference on Genetic Algorithms*, pp. 2-9, 1989.
49. [Eshelman 89] L. J. Eshelman, R. A. Caruana, and J. D. Schaffer, "Biases in the Crossover Landscape," in *Proceedings of the Third International Conference on Genetic Algorithms*, 1989, pp. 10-19.
50. [De Jong 91] K. A. De Jong and W. M. Spears, "An analysis of the interacting roles of population size and crossover in genetic algorithms," in *Lecture Notes in Computer Science; Parallel Problem Solving from Nature - Proceedings of 1st Workshop, PPSN 1*, Dortmund, Germany, 1991, pp. 38-47.
51. [Fogel 06] D. B. Fogel and I. N. N. Council, *Evolutionary computation : toward a new philosophy of machine intelligence*. Hoboken, N.J.: John Wiley & Sons, 2006.
52. [De Jong 93] K. A. De Jong, "Genetic Algorithms are not Function Optimizers," in *Foundations of Genetic Algorithms 2*, L. D. Whitley, Ed. San Mateo, CA: Morgan Kaufmann, 1993, pp. 5-17.
53. [Siedlecki 89] W. Siedlecki and J. Sklansky, "Constrained Genetic Optimization via Dynamic Reward-Penalty Balancing and Its Use in Pattern Recognition," in *Proceedings of the Third International Conference on Genetic Algorithms*, San Mateo, CA, 1989, pp. 141-150.
54. [Michalewicz 91] Z. Michalewicz and C. Janikow, "Handling Constraints in Genetic Algorithms," in *Proc. of the 4th Int. Conf. on Genetic Algorithms.*, 1991, pp. 151-157.
55. [Powell 93] D. Powell and M. M. Skolnick, "Using Genetic Algorithms in Engineering Design Optimization with Non-Linear Constraints," in *Proceedings of the 5th International Conference on Genetic Algorithms Urbana-Champaign, Illinois, USA, 1993*, pp. 424-431.

-
56. [Schoenauer 93] M. Schoenauer and S. Xanthakis, "Constrained GA Optimization," in *Proceedings of the Fifth International Conference on Genetic Algorithms*, San Mateo, CA, 1993, pp. 573-580.
 57. [Smith 93] A. E. Smith and D. M. Tate, "Genetic Optimization Using A Penalty Function," in *Proceedings of the Fifth International Conference on Genetic Algorithms (ICGA 93)*, San Mateo, California, 1993, pp. 499-505.
 58. [Richardson 89] J. T. Richardson, M. R. Palmer, G. E. Liepins, and M. Hilliard, "Some Guidelines for Genetic Algorithms with Penalty Functions," in *Proceedings of the Third International Conference on Genetic Algorithms*, 1989, pp. 191-197.
 59. [Kazarlis 96] S. A. Kazarlis, A. G. Bakirtzis, and V. Petridis, "A genetic algorithm solution to the unit commitment problem," *Power Systems, IEEE Transactions on*, vol. 11, pp. 83-92, 1996.
 60. [Horst 00] R. Horst, P. M. Pardalos, and N. V. Thoai, *Introduction to global optimization*, 2nd ed. Dordrecht ; Boston: Kluwer Academic Publishers, 2000.
 61. [Coello 00] C. A. C. Coello, "An updated survey of GA-based multiobjective optimization techniques," *Acm Computing Surveys*, vol. 32, pp. 109-143, Jun 2000.
 62. [Kalyanmoy 01] D. Kalyanmoy, *Multi-Objective Optimization using Evolutionary Algorithms*. Chichester: John Wiley & Sons, 2001.
 63. [Van Veldhuizen 03] D. A. Van Veldhuizen, J. B. Zydallis, and G. B. Lamont, "Considerations in engineering parallel multiobjective evolutionary algorithms," *Evolutionary Computation, IEEE Transactions on*, vol. 7, pp. 144-173, 2003.
 64. [Zitzler 99] E. Zitzler and L. Thiele, "Multiobjective evolutionary algorithms: A comparative case study and the Strength Pareto approach," *Ieee Transactions on Evolutionary Computation*, vol. 3, pp. 257-271, Nov 1999.
 65. [Rosenberg 67] R. S. Rosenberg, *Simulation of Genetic Populations with Biochemical Properties*, 1967.
 66. [Schaffer 85] J. D. Schaffer, "Multiple Objective Optimization with Vector Evaluated Genetic Algorithms," in *Proceedings of the 1st International Conference on Genetic Algorithms*. L. Erlbaum Associates Inc., 1985.
 67. [Zitzler 00] E. Zitzler, K. Deb, and L. Thiele, "Comparison of Multiobjective Evolutionary Algorithms: Empirical Results," *Evolutionary Computation*, vol. 8, pp. 173-195, 2000.
 68. [Kumar 03] R. Kumar and P. Rockett, "Evolutionary Multimodal Optimization Revisited," in *Genetic and Evolutionary Computation — GECCO 2003*, 2003, pp. 210-211.
 69. [Sareni 98] B. Sareni and L. Krahenbuhl, "Fitness sharing and niching methods revisited," *Evolutionary Computation, IEEE Transactions on*, vol. 2, pp. 97-106, 1998.
 70. [Hajela 92] P. Hajela and C. Y. Lin, "Genetic search strategies in multicriterion optimal design," *Structural Optimization*, pp. 99--107, 1992.
 71. [Czyzak 98] P. Czyzak and A. Jaszkievicz, "Pareto simulated annealing - a metaheuristic technique for multiple-objective combinatorial optimization," *Journal of Multi-Criteria Decision Analysis*, vol. 7, pp. 34-47, 1998.
 72. [Srinivas 94] N. Srinivas and K. Deb, "Multiobjective optimization using nondominated sorting in genetic algorithms," *Evolutionary Computation*, pp. 221--248, 1994.
 73. [Zitzler 01] E. Zitzler, M. Laumanns, and L. Thiele, "SPEA2: Improving the Strength Pareto Evolutionary Algorithm," 2001.
 74. [Deb 02] K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan, "A fast and elitist multiobjective genetic algorithm: NSGA-II," *Evolutionary Computation, IEEE Transactions on*, vol. 6, pp. 182-197, 2002.
 75. [Corne 00] D. W. Corne, J. D. Knowles, and M. J. Oates, "The Pareto Envelope-based Selection Algorithm for Multiobjective Optimization," in *Proceedings of the Parallel Problem Solving from Nature VI Conference*. Springer, 2000, pp. 839--848.

-
76. [Knowles 99] J. Knowles and D. Corne, "The Pareto archived evolution strategy: a new baseline algorithm for Pareto multiobjective optimisation," in *Evolutionary Computation, 1999. CEC 99. Proceedings of the 1999 Congress on*, 1999, p. 105.
77. [Knowles 03] J. D. Knowles and D. W. Corne, "Bounded Pareto archiving: Theory and practice," in *Multiple Objective Meta-Heuristics: Selected Papers, Springer LNES*: Springer, 2003, pp. 39--64.
78. [Corne 01] D. W. Corne, N. R. Jerram, J. D. Knowles, and M. J. Oates, "PESA-II: Region-based Selection in Evolutionary Multiobjective Optimization," in *Proceedings of the Genetic and Evolutionary Computation Conference (GECCO'01: Morgan Kaufmann Publishers*, 2001, pp. 283--290.
79. [E.L. Ulungu 99] J. T. E.L. Ulungu, P. H. Fortemps, D. Tuytens, "MOSA method: a tool for solving multiobjective combinatorial optimization problems." vol. 8, 1999, pp. 221-236.
80. [Hansen 97] M. P. Hansen, "Tabu search for multiobjective optimization: MOTS," in *Proceedings of the Thirteenth International Conference on Multiple Criteria Decision Making*: Springer-Verlag, 1997, pp. 6--10.
81. [Talbi 02] E. G. Talbi, "A Taxonomy of Hybrid Metaheuristics." vol. 8: Kluwer Academic Publishers, 2002, pp. 541-564.
82. [Knowles 00] J. D. Knowles and D. W. Corne, "M-PAES: a memetic algorithm for multiobjective optimization," in *Evolutionary Computation, 2000. Proceedings of the 2000 Congress on*, 2000, pp. 325-332 vol.1.
83. [Xiaolin 03] H. Xiaolin, H. Zhangcan, and W. Zhongfan, "Hybridization of the multi-objective evolutionary algorithms and the gradient-based algorithms," in *Evolutionary Computation, 2003. CEC 03. The 2003 Congress on*, 2003, pp. 870-877 Vol.2.
84. [Barichard 03] V. Barichard and J.-k. Hao, "Genetic Tabu Search for the Multi-objective Knapsack Problem," *Journal of Tsinghua Science and Technology*, vol. 8, pp. 8-13, 2003.
85. [Hidroeléctrica Española 82] Hidroeléctrica Española, "Reguladores de Tensión Bajo Carga en Transformadores AT/MT," San Agustín de Guadalix: Hidroeléctrica Española SA, 1982.
86. [Pozas 95] J. T. Pozas, "Regulación de Tensión bajo Carga en Transformadores," in *Seminario Control y Protección de Redes y Máquinas Eléctricas Valencia*: Iberdrola, 1995.
87. [ABB 05] ABB, "Cambiadores de Tomas en Carga tipo UB, Guía Técnica," ABB, 2005.
88. [ABB 05] ABB, "Cambiadores de Tomas en Carga tipo UZ, Guía Técnica," ABB, 2005.
89. [Reinhausen 06] M. Reinhausen, "Maschinenfabrik Reinhausen," On Load Tap Changer VACUTAP-VV, 2006.
90. [Pélissier 71] R. Pélissier, *Les Réseaux d'énergie électrique F*; Paris: Dunod, 1971.
91. [Sarinelli 86] R. Sarinelli, "Une nouvelle méthode pour le réglage de la tension: modèle ORTENS (A new method for voltage control: the ORTENS model)," *Bulletin de la Direction des études et recherches - Electricité de France. Série B, réseaux électriques, matériels électriques (Bull. Dir. étud. rech. - Electr. Fr., Sér. B réseaux électr. matér. électr.)*, vol. 2, pp. 5-8, 1986.
92. [Carpinelli 92] G. Carpinelli, D. Menniti, and A. Testa, "A criterion for the optimal regulation of transformers tap ratios in radial distribution networks," *Elektrie*, vol. 46, pp. 190-4, 1992.
93. [Curcio 91] G. Curcio, D. Menniti, A. Testa, and F. Tisato, "Voltage regulation in a HV/MV station by means of a real-time processing system," *Energia Elettrica*, vol. 68, pp. 217-29, 1991.
94. [Testa 93] A. Testa, G. Curcio, and D. Menniti, "Voltage regulation in MV/LV distribution substation in presence of nonhomothetic load," *Energia Elettrica*, vol. 70, pp. 32-8, 1993.

-
95. [Carbone 95] R. C. Carbone, R. Menniti, D. Sorrentino, N., "Distributed energy management system: la regolazione della tensione nelli reti MT/BT in tempo reale," *L energia elettrica*, 1995.
 96. [Sorrentino 94] N. Sorrentino, "Implementazione di un distributed energy management system nel caso della regolazione della tensione sulle linee MT/BT: il sistema di comunicazione." vol. Ph. D. Calabria: Università della Calabria, 1994.
 97. [Cesario 94] R. Cesario, "Implementazione di un distributed energy management system nel caso della regolazione della tensione sulle linee MT/BT: interface hardware" vol. Ph. D. Calabria: Università della Calabria, 1994.
 98. " " vol. Ph. D. Calabria: Università della Calabria, 1994.
 99. [Daeseok 95] R. Daeseok, H. Kita, J. Hasegawa, and K. Nishiya, "A study on the optimal voltage regulation methods in power distribution systems interconnected with dispersed energy storage and generation systems," in *Energy Management and Power Delivery, 1995. Proceedings of EMPD 95., 1995 International Conference on 1995*, pp. 702-707.
 100. [Hidroeléctrica Española 62] Hidroeléctrica Española, "Regulación de la tensión en las redes de distribución de energía eléctrica," Hidroeléctrica Española SA, 1962.
 101. [Cortinas Prieto 97] D. Cortinas Prieto, "La regulation de tension reeseaux publics de distribution d'électricite." vol. Ph. D. Paris: Université Pierre et Marie Curie (Paris VI), 1997.
 102. [Haida 91] T. Haida and Y. Akimoto, "Genetic algorithms approach to voltage optimization," in *Neural Networks to Power Systems, 1991., Proceedings of the First International Forum on Applications of 1991*, pp. 139-143.
 103. [Iba 94] K. Iba, "Reactive power optimization by genetic algorithm," *Power Systems, IEEE Transactions on*, vol. 9, pp. 685-692, 1994.
 104. [Ramos 04] R. Ramos, J. Vallejos, and B. Baran, "Multiobjective reactive power compensation with voltage security," in *Transmission and Distribution Conference and Exposition: Latin America, 2004 IEEE/PES 2004*, pp. 302-307.
 105. [Bridenbaugh 92] C. J. Bridenbaugh, D. A. DiMascio, and R. D Aquila, "Voltage control improvement through capacitor and transformer tap optimization," *Power Systems, IEEE Transactions on*, vol. 7, pp. 222-227, 1992.
 106. [Lu 95] F. C. Lu and Y. Y. Hsu, "Reactive Power Voltage Control in a Distribution Substation Using Dynamic-Programming," *Iee Proceedings-Generation Transmission and Distribution*, vol. 142, pp. 639-645, Nov 1995.
 107. [Son 00] K. M. Son, K. S. Moon, S. K. Lee, and J. K. Park, "Coordination of an SVC with a ULTC reserving compensation margin for emergency control," *Ieee Transactions on Power Delivery*, vol. 15, pp. 1193-1198, Oct 2000.
 108. [Kim 05] G. W. Kim and K. Y. Lee, "Coordination control of ULTC transformer and STATCOM based on an artificial neural network," *Ieee Transactions on Power Systems*, vol. 20, pp. 580-586, May 2005.
 109. [Wei 05] S. Wei and V. Vittal, "Corrective switching algorithm for relieving overloads and voltage violations," *Power Systems, IEEE Transactions on*, vol. 20, pp. 1877-1885, 2005.
 110. [Grigg 99] C. Grigg, P. Wong, P. Albrecht, R. Allan, M. Bhavaraju, R. Billinton, Q. Chen, C. Fong, S. Haddad, S. Kuruganty, W. Li, R. Mukerji, D. Patton, N. Rau, D. Reppen, A. Schneider, M. Shahidehpour, and C. Singh, "The IEEE Reliability Test System-1996. A report prepared by the Reliability Test System Task Force of the Application of Probability Methods Subcommittee," *Power Systems, IEEE Transactions on*, vol. 14, pp. 1010-1020, 1999.
 111. [Popovic 99] D. S. Popovic and R. M. Ciric, "A multi-objective algorithm for distribution networks restoration," *Ieee Transactions on Power Delivery*, vol. 14, pp. 1134-1141, Jul 1999.

-
112. [Knowles 02] J. D. Knowles, "Local-search and hybrid evolutionary algorithms for Pareto optimization," in *Department of Computer Science* Reading: University of Reading, 2002.
 113. [Aarts 89] E. H. L. Aarts and J. Korst, *Simulated annealing and Boltzmann machines : a stochastic approach to combinatorial optimization and neural computing*. Chichester [England] ; New York: Wiley, 1989.
 114. [Glover 97] F. Glover and M. Laguna, *Tabu search*. Boston: Kluwer Academic Publishers, 1997.
 115. [Pérez 96] A. Pérez, "Una introducción a la computación evolutiva," 1996.
 116. [Srinivas 94] M. Srinivas and L. M. Patnaik, "Genetic algorithms: a survey," *Computer*, vol. 27, pp. 17-26, 1994.
 117. [Hillier 05] F. S. Hillier and G. J. Lieberman, *Introduction to operations research*. Boston: McGraw-Hill Higher Education, 2005.
 118. [Davis 93] T. E. Davis and J. C. Principe, "A Markov Chain Framework for the Simple Genetic Algorithm," vol. 1, pp. 269-288, 1993.
 119. [Goodman 06] R. Goodman, *Introduction to stochastic models*. Mineola, N.Y.: Dover Publications, 2006.
 120. [Arroyo 00] J. M. Arroyo, "Modelos y Algoritmos para la explotación óptima de la generación en sistemas eléctricos centralizados y competitivos mediante algoritmos genéticos y programación lineal entera-mixta," in *Departamento de Ingeniería Eléctrica, Electrónica y Automática* Ciudad Real: Universidad de Castilla La Mancha, 2000.
 121. [Montoya06] F. G. Montoya, A. Espín, C. Gil y R. Baños. "Optimización de Tensión en Redes de Distribución utilizando Técnicas de Optimización Evolutiva". *Información Tecnológica*, 2006, vol.17, no.4, p.81-88. ISSN 0718-0764.
 122. [Baños04a] R. Baños, C. Gil, J. Ortega, and F. G. Montoya, "A Parallel Multilevel Metaheuristic for Graph Partitioning.", *Journal of Heuristics*, vol. 10, no.3, 2004, pp. 315-336.
 123. [Baños 04b] R. Baños, C. Gil, J. Ortega, and F. G. Montoya, "Optimising Graph Partitions Using Parallel Evolution," *Lecture Notes in Computer Science*, vol. 2936, pp. 91-102, 2004.
 124. [Montoya03] F. G. Montoya, F. Aznar, A. Espin, C. Gil, and R. Baños, "Nuevo método para la optimización de tensión en redes de distribución utilizando técnicas de optimización evolutiva," en el 8^o Congresso luso Espanhol de Engenharia Electrotecnica. VilaMoura, Portugal, 2003.
 125. [Baños03a] R. Baños, C. Gil, J. Ortega, F.G. Montoya: "Multilevel Heuristic Algorithm for Graph Partitioning", *Lecture Notes in Computer Science*, Springer-Verlag, vol. 2611, pp. 143-153, 2003.
 126. [Baños04c] R. Baños, C. Gil, J. Ortega, F.G. Montoya: "Parallel Heuristic Search in Multilevel Graph Partitioning". 12th Euromicro Conference on Parallel, Distributed and Network-based Processing. Published by the IEEE Computer Society Press, pp. 88-95. La Coruña (España). Febrero 2004.
 127. [Baños03b] R. Baños, C. Gil, J. Ortega, F.G. Montoya: "Partición en Grafos mediante Optimización Evolutiva Paralela". XIV Jornadas de Paralelismo, pp. 245-250. Leganés, 2003.
 128. [Marquez07] A.L. Márquez, R. Baños, C. Gil, F.G. Montoya: "Paralelización de Algoritmos Evolutivos Multi-objetivo utilizando el Modelo de Islas" XVIII Jornadas de Paralelismo, Zaragoza, Septiembre 2007
 129. [Baños04d] R. Baños, C. Gil, J. Ortega, F.G. Montoya: "PMSATS: Metaheurística Multinivel Paralela para Partición de Grafos". III Congreso Español de Metaheurísticas, Algoritmos Evolutivos y Bioinspirados, pp. 380-388. Cordoba, 2004.