

UNIVERSIDAD AUTONOMA DE NUEVO LEON

FACULTAD DE INGENIERIA MECANICA
Y ELECTRICA

DIVISION DE ESTUDIOS DE POST-GRADO



APLICACION DE LA TECNICA DE
ALGORITMOS GENETICOS AL PROBLEMA DE
DESPACHO ECONOMICO

TESIS

EN OPCION AL GRADO DE MAESTRO EN
CIENCIAS DE LA INGENIERIA ELECTRICA
CON ESPECIALIDAD EN POTENCIA

PRESENTA

ALFREDO OLACHEA AGUAYO

SAN NICOLAS DE LOS GARZA, N. L. DICIEMBRE 2003

TM
Z5853
.M2
FIME
2003
.04



1020149435

UNIVERSIDAD AUTONOMA DE NUEVO LEON

FACULTAD DE INGENIERIA MECANICA
Y ELECTRICA

DIVISION DE ESTUDIOS DE POST-GRADO



APLICACION DE LA TECNICA DE
ALGORITMOS GENETICOS AL PROBLEMA DE
DESPACHO ECONOMICO

TESIS

EN OPCION AL GRADO DE MAESTRO EN
CIENCIAS DE LA INGENIERIA ELECTRICA
CON ESPECIALIDAD EN POTENCIA

PRESENTA

ALFREDO OLACHEA AGUAYO

SAN NICOLAS DE LOS GARZA, N. L. DICIEMBRE 2003

980 868

TH
Z5853
.M2
FIHE
2003
.O4




FONDO
TESIS

UNIVERSIDAD AUTONOMA DE NUEVO LEON

FACULTAD DE INGENIERIA MECANICA Y ELECTRICA

DIVISION DE ESTUDIOS DE POSTGRADO



**APLICACIÓN DE LA TÉCNICA DE ALGORITMOS GENÉTICOS
AL PROBLEMA DE DESPACHO ECONÓMICO**

TESIS

**EN OPCION AL GRADO DE MAESTRO EN CIENCIAS
DE LA INGENIERIA ELECTRICA CON
ESPECIALIDAD EN POTENCIA**


PRESENTA

ALFREDO OLACHEA AGUAYO

UNIVERSIDAD AUTONOMA DE NUEVO LEON

FACULTAD DE INGENIERIA MECANICA Y ELECTRICA

DIVISION DE ESTUDIOS DE POSTGRADO



**APLICACIÓN DE LA TÉCNICA DE ALGORITMOS GENÉTICOS
AL PROBLEMA DE DESPACHO ECONÓMICO**

TESIS

**EN OPCION AL GRADO DE MAESTRO EN CIENCIAS
DE LA INGENIERIA ELECTRICA CON
ESPECIALIDAD EN POTENCIA**

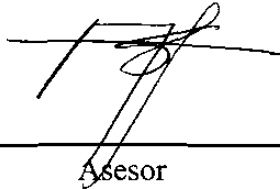
PRESENTA

ALFREDO OLACHEA AGUAYO

Universidad Autónoma de Nuevo León
Facultad de Ingeniería Mecánica y Eléctrica
Subdirección de Estudios de Postgrado

Los miembros de comité de tesis recomendamos que la tesis **APLICACIÓN DE LA TÉCNICA DE ALGORITMOS GENÉTICOS AL PROBLEMA DE DESPACHO ECONÓMICO**, realizada por el alumno Alfredo Olachea Aguayo, matrícula 1069304 sea aceptada para su defensa como opción al grado de Maestro en Ciencias de la Ingeniería Eléctrica con especialidad en Potencia.

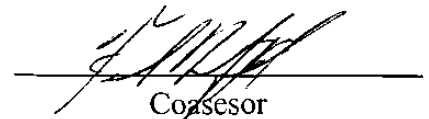
El Comité de Tesis



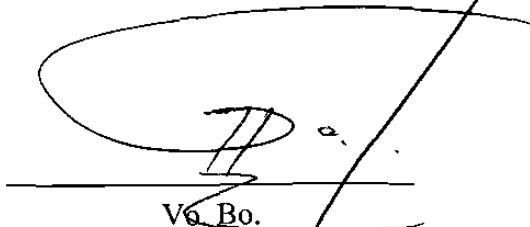
Asesor
Dr. Fernando Sánchez Tello



Coasesor
Dr. Rogelio Ramírez Barradas



Coasesor
Dr. Fernando Betancourt Ramírez



V. Bo.
Dr. Guadalupe Alan Castillo Rodríguez
División de Estudios de Postgrado

INDICE

Capitulo.	Pág.
1. INTRODUCCIÓN.	
1.1 Motivación.....	1
1.2 Justificación.....	2
1.3 Antecedentes.....	3
1.4 Objetivo.....	4
1.5 Contenido de la tesis.....	4
2. ALGORITMOS GENÉTICOS.	
2.1 Introducción.....	7
2.2 Algoritmos Genéticos.....	8
2.3 Algoritmo Genético Simple.....	10
2.3.1 Operador de Reproducción.....	11
2.3.2 Operador de Cruce.....	11
2.3.3 Operador de Mutación.....	14
2.3.4 Ciclo del Algoritmo Genético Simple.....	15
2.4 Parámetros Básicos del Algoritmo Genético.....	16
2.4.1 Tamaño de la Población.....	17
2.4.2 Número de Generaciones.....	17
2.4.3 Probabilidad de Cruce y Mutación.....	18
2.4.4 Tipo de Cruce.....	18
2.4.5 Intervalo de Aproximación.....	19
2.4.6 Número de Descendientes por Cruce.....	19
2.5 Técnicas Para el Mejoramiento en el Desempeño de los algoritmos Genéticos.....	20

2.5.1	Elitismo.....	20
2.5.2	Factores de Penalización.....	20
2.5.3	Factores de Prioridad.....	21
2.5.4	Diagrama de Flujo para un Algoritmo Genético con Elitismo, Factores de Prioridad y Factores de Penalización.....	22
3.	DESPACHO ECONÓMICO.	
3.1	Introducción.....	23
3.2	Concepto Básicos de Despacho Económico.....	24
3.3	Despacho Económico Clásico.....	24
3.4	Despacho Económico Incluyendo Pérdidas en la Red de Transmisión.....	27
3.5	Despacho Económico Incluyendo Restricciones.....	29
3.6	Despacho Económico Incluyendo Punto de Válvula en las Curvas de Costo.....	30
4.	APLICACIÓN DE LA TÉCNICA DE ALGORITMOS GENÉTICOS AL PROBLEMA DE DESPACHO ECONÓMICO.	
4.1	Introducción.....	33
4.2	Codificación.....	34
4.2.1	Codificación de Potencia Activa.....	34
4.2.2	Codificación de Costos Incrementales.....	35
4.3	Función de Evaluación.....	37
5.	SIMULACIÓN MANUAL DE UN ALGORITMO GENÉTICO.	
5.1	Introducción.....	44
5.2	Planteamiento de Problema.....	45
5.2.1	La Función de evaluación.....	45

5.2.2 Parámetros Básicos.....	47
5.2.3 Población Inicial.....	48
5.2.4 Reproducción.....	49
5.2.5 Cruce.....	50
5.2.6 Mutación.....	50
5.2.7 Resultados.....	51
5.3 Solución al problema planteado mediante un método matemático tradicional.....	53

6. FUNDAMENTOS MATEMÁTICOS DE LOS ALGORITMOS GENÉTICOS

6.1 Introducción.....	58
6.2 Esquemas y sus características.....	59
6.2.1 Orden de un esquema.....	60
6.2.2 Longitud de un esquema.....	61
6.3 Efecto de la reproducción en un esquema.....	62
6.4 Efecto del cruce en un esquema.....	63
6.5 Efecto de la mutación en un esquema.....	64
6.6 Procesamiento manual de esquemas.....	65

7. RESULTADOS.

7.1. Introducción.....	69
7.2 Análisis Paramétrico.....	70
7.2.1 Efecto del Tamaño de la Población.....	72
7.2.2 Efecto del Tipo de Cruce Empleado.....	74
7.2.3 Efecto del Número de Descendientes por Cruce.....	75
7.2.4 Efecto de la Probabilidad de Mutación.....	76
7.2.5 Efecto de la Probabilidad de Cruce.....	77
7.2.6 Efecto del Elitismo.....	78

7.2.7 Efecto de la Semilla Aleatoria.....	80
7.2.8 Efecto del Número de Generaciones.....	81
7.3 Solución al problema de despacho económico codificando potencia de generación.....	82
7.4 Resultados para otras funciones de evaluación.....	83
7.5 Solución al problema de despacho económico con restricción en líneas de transmisión.....	86
7.6 Solución al problema de despacho económico considerando puntos de válvula en las curvas de costo.....	88
7.7 Sistemas de gran escala.....	91
8. CONCLUSIONES.....	97
9. APORTACIONES.....	100
9. REFERENCIAS.....	101

INDICE DE FIGURAS.

Figura 2.1 Ciclo del algoritmo genético simple.....	15
Figura 2.2 Ciclo del AG con elitismo, factores de prioridad y penalización.....	22
Figura 3.1 Despacho económico clásico.....	25
Figura 3.2 Ciclo de un método tradicional de solución al problema de Despacho económico.....	26
Figura 3.3 Despacho económico considerando la red de transmisión.....	28
Figura 3.4 Ciclo de un método tradicional de solución al problema de despacho económico considerando la red de transmisión.....	28
Figura 3.5 Curva de costo y heat rate con puntos de válvula.....	31
Figura 3.6 Curva de costo y heat rate linealizada.....	31
Figura 3.7 Comparativo de curva de costo linealizada y con punto de válvula..	32
Figura 4.1 Función de evaluación.....	40
Figura 5.1 Sistema de prueba 1.....	45
Figura 5.2 Cromosoma de 15 bits.....	48
Figura 7.1 Sistema de prueba 2.....	70
Figura 7.2 Efecto del tamaño de la población.....	73
Figura 7.3 Efecto del tipo de cruce empleado.....	74
Figura 7.4 Efecto del número de descendientes por cruce.....	75
Figura 7.5 Efecto de la probabilidad de mutación.....	76
Figura 7.6 Efecto de la probabilidad de cruce.....	77
Figura 7.7 Efecto del elitismo.....	78
Figura 7.8 Efecto de la semilla aleatoria.....	80
Figura 7.9 Proceso de convergencia para codificación de potencia.....	82
Figura 7.10 Proceso de convergencia utilizando la función de evaluación 7.2...	84
Figura 7.11 Proceso de convergencia utilizando la función de evaluación 7.3...	85
Figura 7.12 Proceso de convergencia para el caso con restricción en líneas.....	87
Figura 7.13 Proceso de convergencia considerando puntos de válvula en las curvas de costo de los generadores.....	90
Figura 7.14 Proceso de convergencia para el sistema eléctrico de la CFE.....	91

INDICE DE TABLAS.

Tabla 5.1 Datos de generadores del sistema de la Fig. 5.1.....	45
Tabla 5.2 Población inicial.....	48
Tabla 5.3 Resultados de la primera generación.....	51
Tabla 5.4 Resultados de la segunda generación.....	52
Tabla 5.5 Resultados de la tercera generación.....	66
Tabla 6.1 Valores de los esquemas en la población inicial.....	67
Tabla 6.2 Valores de los esquemas en la segunda generación.....	70
Tabla 7.1 Red de transmisión del sistema de prueba 2.....	71
Tabla 7.2 Datos de curvas de costo para generadores del sistema de prueba 2..	71
Tabla 7.3 Límites de generación para generadores del sistema de prueba 2.....	72
Tabla 7.4 Solución de Despacho Económico para el sistema de prueba 2 utilizando PSS/OPF.....	72
Tabla 7.5 Solución encontrada en la generación veintitrés.....	79
Tabla 7.6 Solución encontrada en la generación diez.....	79
Tabla 7.7 Solución para semilla aleatoria 1000.....	81
Tabla 7.8 Solución para semilla aleatoria 300.....	81
Tabla 7.9 Solución codificando potencia.....	82
Tabla 7.10 Solución utilizando la función de evaluación 7.2.....	83
Tabla 7.11 Solución utilizando la función de evaluación 7.3.....	84
Tabla 7.12 Líneas restringidas, flujo de potencia del Caso Base y Máximo Permitido en megawatts.....	86
Tabla 7.13 Solución con restricción en líneas.....	87
Tabla 7.14 Solución obtenida utilizando PSS/OPF.....	87
Tabla 7.15 Datos de curva de costo para generadores.....	88
Tabla 7.16 Límites de generación para generadores.....	88
Tabla 7.17 Solución considerando puntos de válvula en las curvas de costo de los generadores.....	90
Tabla 7.18 Datos de curva de costo para generadores del Sistema Noroeste de CFE.....	92

Tabla 7.19 Solución de Despacho Económico para el Sistema Noroeste de CFE Mediante Algoritmos Genéticos.....	92
Tabla 7.20 Solución de Despacho Económico para el Sistema Noroeste de CFE con PSS/OPF.....	93
Tabla 7.21 Flujo normal y límite para enlace norte-sur del sistema Noroeste.....	94
Tabla 7.22 Solución de despacho económico con restricción en líneas para el sistema Noroeste de CFE mediante Algoritmos Genéticos.....	94
Tabla 7.23 Solución de despacho económico con restricción en líneas para el sistema Noroeste de CFE mediante PSS/OPF.....	95

RESUMEN

APLICACIÓN DE LA TÉCNICA DE ALGORITMOS GENÉTICOS AL PROBLEMA DE DESPACHO ECONÓMICO

Publicación No. _____

Alfredo Olachea Aguayo, M.C. en Ing. Eléctrica

Facultad de Ingeniería Mecánica y Eléctrica

Universidad Autónoma de Nuevo León, 2003

Profesor Asesor: Dr. Fernando Sánchez Tello, Ph. D.

El presente trabajo presenta la aplicación de la técnica de optimización de Algoritmos Genéticos a la solución del problema de Despacho Económico en las siguientes versiones; sin pérdidas, con pérdidas, restricción en líneas de transmisión y considerando puntos de válvula en la curva de costo de los generadores para sistemas de potencia pequeños (sistema con pocos generadores a despachar) y sistemas de gran escala. Se comparan resultados del Algoritmo Genético con soluciones obtenidas a partir de métodos convencionales de solución.

Se analiza el comportamiento del Algoritmo Genético y el efecto de sus parámetros básicos. En particular se evalúa el impacto del tamaño de la población, número de generaciones, tipo de cruce, elitismo, número de descendientes, semilla aleatoria y probabilidad de cruce y mutación.

En la aplicación de la técnica de Algoritmos Genéticos se prueba la efectividad de distintas funciones de evaluación propuestas así como de los métodos de codificación utilizados. Se presta especial atención al proceso de convergencia de los problemas resueltos y la exactitud de las soluciones encontradas.

Se muestra el fundamento matemático de los Algoritmos Genéticos y se resuelve un problema mostrando paso a paso el funcionamiento de dicha técnica.

CAPITULO 1

INTRODUCCIÓN

1.1 Motivación.

El análisis de los sistemas de potencia combina una gran complejidad computacional y notables características no lineales con un alto requerimiento de condiciones operativas optimas. Los métodos matemáticos tradicionales utilizados para este análisis, por un lado, solo ofrecen una aproximación a las soluciones reales ya que imponen restricciones en el modelado de los elementos del sistema las cuales repercuten en la solución final; y por otro lado, presentan los siguientes problemas de funcionamiento para problemas de optimización cuando:

- ✓ La dimensión del espacio de solución es grande o se requiere mayor exactitud, el tiempo de búsqueda tiende a incrementarse.

- ✓ El espacio de solución presenta muchos picos (espacio multimodal), existe el peligro de perder por completo el mínimo global.
- ✓ El espacio de solución es demasiado fino, el tiempo para determinar el punto inicial crece exponencialmente con el número de parámetros a optimizar.
- ✓ Se tienen varios mínimos locales, tienden a quedarse "atorados" sin importar el paso de búsqueda, no necesariamente en el mínimo global [3].

En el problema de optimización de Despacho Económico, donde el principal objetivo es programar la salida de potencia de las unidades generadoras en línea para satisfacer la demanda a un mínimo costo, las restricciones impuestas por los métodos matemáticos tradicionales en las curvas de costo de las máquinas ocasionan que se obtenga solo una aproximación en la minimización. Si consideramos el costo total de generación de un sistema de potencia real, será evidente que evitar cualquier restricción en el modelado de las funciones de costo se traducirá en un ahorro significativo.

Los métodos de optimización conocidos como métodos de inteligencia artificial, a diferencia de los métodos matemáticos estrictos, no imponen restricciones en el modelado de los elementos implícitos en el problema, ya que tienen la aparente habilidad de adaptarse a las no-linealidades y discontinuidades comúnmente encontradas en los sistemas físicos, además muestran buenas características de funcionamiento en problemas con espacio de solución multimodal [3].

1.2 Justificación.

- Disponer de una herramienta alterna, flexible y eficiente en la solución del problema de Despacho Económico ante diversas condiciones del sistema de potencia, que asegure, por comparación con las soluciones actuales, el despacho de generación al menor costo.
- Evaluar la técnica de algoritmos genéticos aplicada al problema de Despacho Económico en distintos sistemas de potencia de prueba y a un sistema de la

Comisión Federal de Electricidad (CFE), utilizando diferentes combinaciones de parámetros básicos y métodos de codificación.

- Comparar la solución de Despacho Económico por la técnica de Algoritmos Genéticos y los métodos tradicionales de programación dinámica y el método del gradiente con la finalidad de comprobar la eficiencia y exactitud del algoritmo propuesto.
- Desarrollar una herramienta de apoyo a través de una interfaz gráfica que permita seguir a detalle el comportamiento del algoritmo genético en cada situación y facilitar el proceso de análisis del algoritmo

1.3 Antecedentes.

La búsqueda de métodos de optimización que proporcionen resultados más precisos y con mejores características de convergencia en la solución del problema de Despacho Económico, ha motivado el desarrollo de trabajos que emplean nuevas técnicas de programación como las de inteligencia artificial, dentro de los que destacan los Algoritmos Genéticos. David C. Walters y Gerald B. Sheble [1] presentaron, en la década de los 90's, un trabajo en el que utilizan la técnica de Algoritmos Genéticos para la solución del problema de Despacho Económico codificando potencia de salida de las máquinas, y en el que aprovechando las cualidades de esta técnica, introducen el efecto de punto de válvula en las curvas de costo de los generadores. Años más tarde, Gerald B. Sheble y Kristin Britting [9] realizan un trabajo en el que se presenta un algoritmo basado en genética natural para resolver el problema de Despacho Económico con características similares al anterior y en el que además se analizan técnicas para el mejoramiento del desempeño de dicho algoritmo. Un año después, Po-Hung Chen y Hong-Chan Chang [10] presentan un nuevo trabajo sobre el tema, en el que se propone una técnica de codificación de costo incremental que hace al algoritmo más eficiente en la solución del problema de Despacho Económico en sistemas de potencia de gran

escala, donde incluyen también el efecto de punto de válvula en las curvas de costo de los generadores.

1.4 Objetivos.

- Resolver el problema de despacho económico mediante la utilización de un programa de cómputo basado en el método de inteligencia artificial conocido como algoritmos genéticos.
- Las variantes del problema de Despacho Económico que se analizarán son; despacho económico clásico, despacho económico considerando pérdidas en la red de transmisión considerando el efecto de punto de válvula en las funciones de costo para cada unidad generadora y con restricción en líneas de transmisión.
- Analizar las características de convergencia del método de Algoritmos Genéticos y el efecto de sus parámetros básicos.
- Establecer un procedimiento de sintonización de parámetros del Algoritmo Genético.
- Analizar diversas técnicas de codificación y evaluación para mejorar la eficiencia de búsqueda del algoritmo genético básico.

1.5 Contenido de la tesis.

El presente trabajo consta de ocho capítulos. En el capítulo uno se presenta una introducción donde se define el planteamiento del problema, el objetivo buscado, los límites del estudio, la hipótesis, la justificación del trabajo y la metodología a seguir durante el desarrollo del mismo. Se presenta también una breve reseña de los trabajos antes realizados sobre el tema.

En el capítulo dos se abordan los conceptos básicos de los algoritmos genéticos, en particular, el algoritmo genético simple y se definen cada uno de los operadores genéticos que utiliza como base de su funcionamiento. Se define también el conjunto de parámetros básicos que intervienen en los algoritmos genéticos tales como población, intervalo de aproximación, probabilidad de cruce y mutación etc., los cuales determinan las características de convergencia del algoritmo. Por último, se muestran algunas técnicas utilizadas para mejorar el desempeño de los algoritmos.

En el capítulo tres se describen los conceptos básicos del problema de despacho económico y se muestran las particularidades de algunas de sus variantes, que se utilizarán posteriormente en la evaluación del desempeño del algoritmo genético.

En el capítulo cuatro se presentan y analizan las funciones utilizadas para la aplicación de los algoritmos genéticos al problema de despacho económico y los distintos métodos de codificación usados en su estudio y evaluación.

En el capítulo cinco se presenta el desarrollo matemático completo de la solución de un problema de despacho económico clásico utilizando algoritmos genéticos, donde se muestra a detalle el efecto de sus operadores básicos.

En el capítulo seis se presentan los fundamentos matemáticos de los Algoritmos Genéticos y cómo es que estos llevan a cabo la búsqueda de la mejor solución al problema planteado, guiados por el valor fitness o nivel de aptitud asignado por la función de evaluación.

En el capítulo siete se presentan tablas comparativas que muestran soluciones obtenidas a partir de algoritmos genéticos y métodos tradicionales, con la finalidad de comprobar el buen funcionamiento de los algoritmos genéticos y su precisión. Se presentan también gráficas, obtenidas mediante la interfaz gráfica desarrollada en Matlab®, para cada caso en particular que ilustran, generación a generación, el desarrollo del proceso de convergencia. Una gráfica típica de este estudio es la de desviación de

potencia y costos totales de generación. Se analizan detalladamente cada caso y se presentan las conclusiones pertinentes del estudio.

En el capítulo ocho, se presentan las conclusiones generales y particulares acerca del trabajo desarrollado. Se establecen las aportaciones del trabajo y las contribuciones principales de la presente investigación. También se lista una serie de recomendaciones para trabajos futuros.

CAPITULO 2

ALGORITMOS GENÉTICOS

2.1 Introducción.

La aplicación de los algoritmos genéticos ha recibido recientemente gran atención de los investigadores en el área de inteligencia artificial. En la literatura actual se reconoce que los algoritmos genéticos pueden proporcionar herramientas poderosas en el campo de la optimización [3]. Se ha comprobado que estos algoritmos pueden encontrar soluciones aproximadas a problemas de gran complejidad mediante un proceso de evolución simulada. Se dice evolución simulada debido a que estos algoritmos utilizan una técnica de búsqueda basada en mecanismos de selección y genética natural.

2.2 Algoritmos genéticos.

Los algoritmos genéticos son algoritmos de búsqueda basados en mecanismos de selección y genética natural que siguen un proceso de evolución, similar al que se lleva a cabo en la naturaleza. Evolución que es simulada por medio de ciertas operaciones propias del algoritmo [3].

Los algoritmos genéticos utilizados como técnica de optimización muestran buenas características de funcionamiento, específicamente cuando se trata de problemas con espacios de solución multimodal dado que a diferencia de los métodos tradicionales, es un método que busca en muchos puntos o posibles soluciones del espacio de solución simultáneamente (búsqueda en paralelo), lo cual reduce significativamente las probabilidades de que se queden atorados en mínimos locales durante el proceso de búsqueda. Adicionalmente, no necesitan de información auxiliar para funcionar apropiadamente, ya que solo requieren conocer la factibilidad o beneficio implícito de cada punto del espacio de solución explorado para guiar su búsqueda. Por otro lado, los algoritmos explotan recursos de codificación de una forma muy general y como resultado rebasan las restricciones de otros métodos (existencia de derivadas, continuidad, etc.). Estos algoritmos utilizan reglas de transición probabilísticas para guiar su búsqueda hacia regiones del espacio de solución que se espera tengan mejores características [3].

En suma, son estos cuatro aspectos los que hacen de los algoritmos genéticos un método de búsqueda y optimización robusto característica principal que los distingue de los métodos matemáticos tradicionales.

A continuación se listan estos aspectos:

1. Los algoritmos genéticos buscan simultáneamente de entre muchos puntos ó soluciones, no en un solo punto ó dirección.

2. Los algoritmos genéticos utilizan una función objetivo o función de evaluación, no evaluadores intrínsecos.
3. Los algoritmos genéticos no manejan el conjunto de parámetros del problema, realizan una codificación de estos.
4. Los algoritmos genéticos utilizan reglas de transición probabilísticas no determinísticas.

Los algoritmos genéticos tienen una amplia gama de aplicación como consecuencia de dos aspectos fundamentales:

- Su implementación computacional es bastante simple y provee un poderoso mecanismo de búsqueda.
- Son esquemas muy robustos que pueden ser aplicados en un amplio rango de problemas de optimización.

En algoritmos genéticos se utiliza una terminología particular para designar a cada elemento o proceso que participa y tienen su contraparte en genética natural. Es necesario conocer dicha terminología para comprender como funcionan los algoritmos genéticos como técnica de optimización.

Para resolver un problema de optimización, cualquiera que este sea, mediante la aplicación de algoritmos genéticos, primeramente se tiene que codificar el conjunto de parámetros del problema. Esto se puede hacer, por ejemplo, utilizando código binario para codificar el valor de cada parámetro y formar una cadena de n números de 1's y 0's conocido como cromosoma. Este cromosoma representa una posible solución al problema y equivale a un punto en el espacio de solución.

El algoritmo inicia creando aleatoriamente un conjunto de cromosomas de similares características (mismo número de bits) que se conoce como población inicial. A cada elemento o cromosoma de la población inicial a su vez se le conoce como individuo.

Como se puede ver, la población inicial no es mas que una parte del espacio de solución del problema donde se iniciará la búsqueda y donde también puede o no encontrarse la solución óptima del problema.

A continuación, se evalúa a cada individuo de la población mediante una función definida previamente conocida como función objetivo o función de evaluación, que asigna un valor de aptitud ó fitness a cada individuo. Se puede pensar en el valor fitness como una medida de utilidad, factibilidad o beneficio implícito en cada individuo (cada solución propuesta), de modo que un individuo que tenga un valor alto de fitness representa una solución cercana al óptimo. En otras palabras, la función de evaluación mide el valor de la solución que representa cada individuo. La complejidad de la función de evaluación dependerá de la complejidad del problema.

En seguida, los individuos de la población son sometidos a un proceso de selección basado en el valor fitness individual conocido como reproducción, que lleva a cabo el operador de reproducción. Los individuos seleccionados realizan intercambio de información entre sí como una especie de apareamiento que da como resultado la formación de un nuevo individuo o un par de ellos y que pasarán a formar parte de una segunda población. Este proceso se realiza mediante una operación conocida como operador de cruce.

Por último, los nuevos individuos son manipulados de forma tal que algunos resultan con "pequeñas" modificaciones en su estructura. De esto último se encarga el operador de mutación. A continuación se detallan los operadores.

2.3 Algoritmo genético simple.

El Algoritmo genético básico utilizado en muchos problemas prácticos se compone fundamentalmente de tres operadores:

1. Reproducción.

2. Cruce.
3. Mutación.

2.3.1 Operador de reproducción

La reproducción es un proceso inicial donde todos los individuos de la población son evaluados por medio de la función objetivo para identificar aquellos con valores altos de fitness para hacer copias de estos y quedar en espera de la acción del operador de cruce, mientras que el resto de la población permanece sin cambios esperando ser sustituida por los futuros descendientes de su propia generación.

Es evidente que la función de evaluación es quien decide quién sobrevive en cada generación, por ser el valor fitness el medio por el cual se hace la discriminación para la selección de individuos. Esto significa que los individuos con un fitness alto tienen mayor probabilidad de contribuir con al menos un descendiente para la siguiente generación.

En suma, se puede decir que el operador de reproducción con todo lo que implica, no es más que una versión artificial de la selección natural o Teoría Darwiniana de "La supervivencia del mejor".

En la naturaleza por ejemplo, una especie con un fitness alto sería aquella mejor adaptada al medio ambiente y con características que le permitan sortear todas las adversidades que se le presenten. Es decir, con probabilidades altas de sobrevivir en un medio hostil hasta su etapa de reproducción.

2.3.2 Operador de cruce

Una vez terminado el proceso de reproducción, inicia el operador de cruce. Es a través de este operador que los individuos con mejor fitness elegidos de la población intercambian información para crear nuevos individuos o descendientes que se espera

sean mejores y que formarán parte de la población de la siguiente generación, sustituyendo a los individuos de la población que quedaron fuera durante la reproducción.

En este trabajo se analizarán únicamente dos técnicas diferentes que se han utilizado para implementar el operador de cruce. La primera es conocida como cruce de un solo punto (single point crossover), que consiste primeramente en elegir aleatoriamente dos individuos del grupo (cromosomas padres) y un número entero k entre 1 y el número de bits que forman la cadena o individuo menos uno (para el caso de codificación binaria). Posteriormente se realiza un intercambio de información entre individuos basado en el índice k . Por ejemplo, para los individuos A y B, si $k = 4$ y la longitud de la cadena es cinco.

Individuo A = 0 1 1 0 * 1

Individuo B = 1 1 0 0 * 0

Los individuos intercambian la información de la cadena que se ubica delante del índice k , con esto se crean dos nuevos individuos o descendientes para la siguiente generación.

Individuo A' = 0 1 1 0 0

Individuo B' = 1 1 0 0 1

Otro tipo de cruce utilizado es conocido como cruce uniforme, el cual en lugar de crear descendientes directamente a partir de los padres los hace a través de una cadena de bits obtenida aleatoriamente o máscara de características similares a las cadenas de bits a cruzar. La máscara indica si los bits de la cadena que formará al primer descendiente se obtienen de uno u otro padre. Por ejemplo, si el primer bit de la máscara es 1, el primer padre da el primer bit al descendiente. Por lo contrario, si este es 0

entonces el segundo padre será el que done su primer bit al descendiente. Para crear un segundo descendiente se sigue otra vez el procedimiento, solo que ahora si el primer bit de la máscara es el 1, el primer bit lo donará el segundo padre y si es 0 lo donará el primer padre. Ejemplo:

Máscara = 1 0 1 0 0

Padre1 = 0 0 0 0 1

Padre2 = 1 1 1 0 0

Primer descendiente = 0 1 0 0 0

Segundo descendiente = 1 0 1 0 1

Se dice que a través de este operador se produce un intercambio de información entre individuos con el único objetivo de crear mejores individuos para futuras generaciones.

A pesar de su simplicidad, son los operadores previos la base de los algoritmos genéticos, ya que es a través de estos que se realiza un intercambio de información entre los mejores individuos de cada generación.

Probablemente, a primera vista esto sea un poco confuso, dado que los métodos descritos antes solo muestran un intercambio o formación de cadenas de bits a partir de un par de cadenas de bits previamente seleccionadas. Pero si vemos a cada individuo o cadena de bits como un potencial portador de ideas o elementos que pueden solucionar parte del problema, donde cada idea esta codificada en forma de número binario, en particular de un bit del cromosoma, el intercambio de bits entre cromosomas toma sentido. Esto podría entenderse de una manera tan simple como si un grupo de personas estuvieran tratando de resolver un determinado problema, donde cada persona tiene sus ideas muy particulares de cómo solucionar el problema (que muy posiblemente no sea

una solución óptima). Así es que se juntan en pares para intercambiar ideas, en donde los especialistas en la materia o mejores preparadas (fitness alto) serán las más concurridas para intercambiar ideas. Como consecuencia de este constante intercambio de ideas, alguna persona del grupo encuentra la solución óptima al problema. Lo anterior nos dice que los algoritmos genéticos explotan eficientemente información histórica, tratando siempre de crear a partir de las mejores soluciones conocidas más y mejores soluciones a un problema específico.

2.3.3 Operador de mutación.

El operador de mutación participa con un rol secundario en algoritmos genéticos. La utilidad de este operador se manifiesta cuando la aplicación de los dos operadores anteriores conduce a la pérdida de información potencialmente útil. Este operador actúa sobre todos los individuos de la población, cambiando la información de los elementos de la cadena de bits siguiendo reglas de transición probabilística.

Por ejemplo, considere el primer individuo en la población,

Individuo = 1 0 1 1 0 0

Se analiza el primer elemento de la cadena y si una probabilidad de cambio resulta positiva para este elemento, este se modifica. Esto se repite para todos los elementos de la cadena. Si para todos los elementos restantes la probabilidad resulta negativa, el individuo sometido al operador de mutación ahora será:

Individuo1' = 0 0 1 1 0 0

Se dice que este operador juega un rol secundario ya que al igual que sucede en la naturaleza, la mutación se da muy pocas veces, es decir con una probabilidad muy baja. Se dice que para obtener buenos resultados en la aplicación de algoritmos genéticos se

debe llevar a cabo una mutación por cada cien elementos (bits) sometidos al operador. Esto es, con una probabilidad de 0.01 [4].

2.3.4 Ciclo del algoritmo genético simple.

A continuación se muestra el diagrama de flujo del algoritmo genético simple.

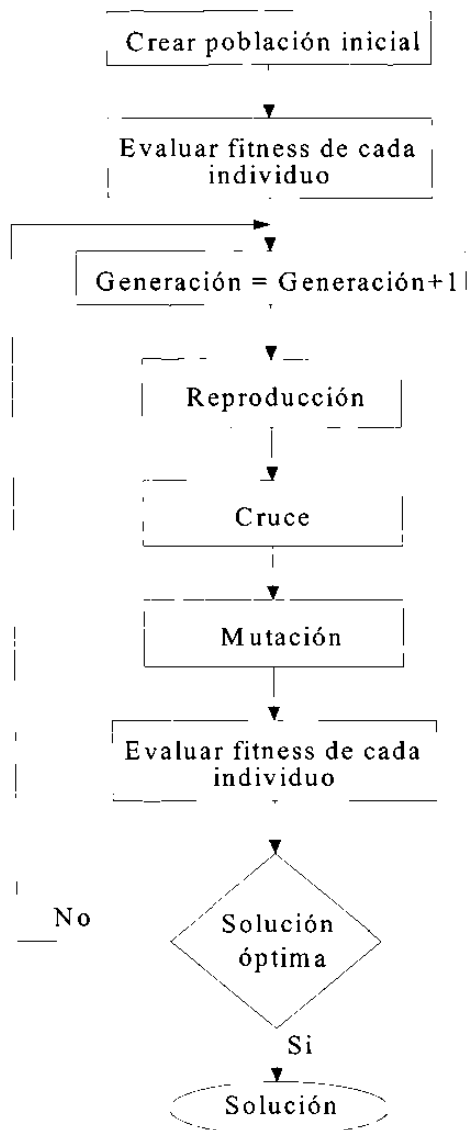


Figura 2.1 Ciclo del algoritmo genético simple.

El proceso inicia cuando se crea la población inicial, después a cada individuo se le asigna su valor fitness por medio de la función de evaluación. Entonces se tiene la primera generación. A continuación se aplica el operador de reproducción, donde se seleccionan los mejores individuos de la generación que serán sometidos al operador de cruce para obtener los nuevos individuos o descendientes que formarán parte de la nueva población. Una vez que se tienen los nuevos individuos se aplica el operador de mutación para posteriormente evaluar su fitness y determinar si se ha encontrado la solución óptima. Si se encontró la solución en la primera generación (iteración), se muestra y se termina la búsqueda. Por el contrario, si aún no se ha encontrado la solución óptima, se continua la búsqueda reiniciando el ciclo con el operador de reproducción para seleccionar los mejores individuos de la nueva generación formado por la descendencia de la generación anterior. El ciclo se repetirá hasta que se haya encontrado la solución óptima o hasta que se cumpla un determinado número de generaciones.

2.4 Parámetros básicos del algoritmo genético.

En algoritmos genéticos se manejan algunos parámetros, conocidos como parámetros de control, los cuales determinan la eficiencia de su proceso de convergencia y la calidad de la solución al problema planteado. Estos parámetros son:

1. Tamaño de la población.
2. Número de generaciones.
3. Probabilidad de cruce y mutación.
4. Tipo de cruce.
5. Intervalo de aproximación.
6. Número de descendientes.

2.4.1 Tamaño de la población

Antes de iniciar con el proceso iterativo de los algoritmos genéticos y una vez que se tiene la función de evaluación y codificado el problema en forma de cromosoma, se debe especificar el tamaño de la población a utilizar, que es la que determina la cantidad de individuos y en consecuencia, la variedad del espacio de solución del algoritmo genético.

La selección del tamaño de la población está fuertemente ligada con el intervalo de aproximación o longitud del cromosoma, de tal forma que, entre mayor sea la longitud del cromosoma, mayor tendrá que ser el tamaño de la población. Lo anterior dado que si se tiene un cromosoma de longitud n codificado en forma de una cadena de 1's y 0's se tendrá un espacio de solución de tamaño 2^n , de donde se tiene que si se aumenta la longitud del cromosoma 1 unidad, se tendrá un espacio de solución de tamaño 2^{n+1} , lo cual significa que tendremos un espacio mayor de búsqueda, por lo que al elegir un tamaño de población relativamente pequeño, en cierta forma se desaprovecha el potencial de búsqueda en paralelo, una de las características relevantes de los algoritmos genéticos.

De cualquier manera, el número de individuos en una población puede variar en un amplio margen dependiendo de la complejidad del problema a resolver, solo debe tomarse en cuenta que entre mayor sea el tamaño de la población, mayor será el tiempo de ejecución del algoritmo.

2.4.2 Número de generaciones.

Como se mencionó en el punto anterior, la continuidad del ciclo iterativo de un algoritmo genético depende de haber encontrado la solución óptima o simplemente de satisfacer el número de generaciones determinadas inicialmente (iteraciones). Como se sabe, el algoritmo genético realiza una búsqueda de la mejor solución entre generación y generación esperando que la calidad de los individuos mejore en el transcurso de las

generaciones. Puede suceder que el proceso de convergencia sea muy lento, en otras palabras, que el mejoramiento de los individuos a través de las generaciones sea mínimo, por tanto, si elegimos un número de generaciones reducido seguramente no se permitirá al algoritmo encontrar la solución óptima. Por otro lado, si eligiéramos un número grande de generaciones, hay más posibilidades de que se alcance la solución óptima pero el tiempo de ejecución también se incrementará. Si aunado a esto, el tamaño de la población también es grande, el tiempo de ejecución crecerá aún más. Utilizar un criterio de convergencia puede ayudar a solucionar en parte este problema. Sin embargo, el número de generaciones necesarias para alcanzar la solución es función de la complejidad del problema y la aplicación de los operadores básicos del algoritmo genético (cruce y mutación).

2.4.3 Probabilidad de cruce y mutación.

La magnitud de la probabilidad con que se apliquen los operadores de cruce y mutación impactan considerablemente la convergencia de los algoritmos genéticos, ya que son estos operadores la base de dichos algoritmos. Como se mencionó antes, el operador de cruce es el que promueve el intercambio de información entre individuos, por lo que si se maneja una baja probabilidad en este operador, el intercambio de información será mínimo y como consecuencia el proceso de convergencia será lento. Por otra parte, si el operador de mutación, el cual modifica la estructura de los cromosomas, utiliza una probabilidad alta de mutación, se corre el riesgo de perder material genético potencialmente útil, aunque en ocasiones utilizar una alta probabilidad de mutación puede ser de utilidad como se verá en la sección de resultados.

2.4.4 Tipo de cruce.

El tipo de cruce empleado impacta directamente la calidad y el número de generaciones requeridas para alcanzar una solución. Esto como consecuencia de las variantes que existen entre uno y otro tipo de cruce, en otras palabras, la forma en que se lleva a cabo el intercambio de información entre individuos.

Aunque el intercambio de información entre individuos se lleve a cabo prácticamente de manera aleatoria, el tipo de cruce elegido para determinado problema influye definitivamente en el proceso de convergencia. Mientras que para algunos casos el cruce uniforme puede que sea el mejor, para otros el de un solo punto puede que lo sea y no se descarta la posibilidad de que en algunos otros casos funcionen los dos tipos de cruce. No obstante, esto únicamente se puede determinar a través de pruebas y experiencias sobre el problema que estemos trabajando.

Algo que sí está claro es que en general conviene utilizar una longitud de cromosoma pequeño para tratar de minimizar las posibles pérdidas de bloques de información útil durante el cruce, sobre todo cuando se utiliza cruce de un solo punto.

2.4.5 Intervalo de aproximación.

Este parámetro se refiere al número de bits utilizados para codificar el conjunto de parámetros del problema. De aquí que por ejemplo para codificación binaria la exactitud de la solución es función del intervalo de aproximación empleado. Este parámetro tiene una implicación directa en la carga computacional por la cantidad de memoria requerida por el algoritmo

2.4.6 Número de descendientes por cruce.

El número de descendientes por cruce determina la variedad del espacio de solución entre generaciones y en cierta forma también el camino a seguir en la búsqueda de la solución óptima; ya que por ejemplo, si se tienen dos descendientes por cruce, el camino que tome la convergencia estará definido en gran parte por los mejores individuos de las primeras generaciones. Mientras que cuando se tiene un solo descendiente por cruce, existe mayor diversidad de individuos para la siguiente generación. Esto se cumple tanto para cruce uniforme como para cruce de un solo punto.

2.5 Técnicas para mejorar el desempeño de los algoritmos genéticos.

Con el afán de mejorar el desempeño de los algoritmos genéticos, en lo que se refiere a la calidad de las soluciones encontradas y reducir los tiempos de ejecución, adicionalmente a lo ya visto hasta este momento, se aplican algunas técnicas especiales, tales como el elitismo y los factores de penalización entre otras. Dichas técnicas por lo general están muy relacionadas con el fitness de los individuos en la población.

2.5.1 Elitismo.

El proceso de reproducción consiste en seleccionar de la población inicial los mejores individuos (con alto fitness), que posteriormente serán sometidos a los operadores de cruce y mutación, donde muy probablemente serán modificadas las estructuras de los cromosomas padres por la acción de los operadores.

Con el fin de evitar la pérdida del mejor individuo de cada generación, se hace una copia de este, que pasará intacta a la próxima generación, es decir, no participará en el proceso de cruce ni mutación. A esto se le llama elitismo.

Para cada problema particular se tendrá que definir el número de copias élite por generación; esto es, cuantos de los diferentes mejores individuos pasarán intactos a la siguiente generación.

2.5.2 Factores de penalización.

En lo que respecta a los factores de penalización, es una técnica más directa que actúa modificando el valor fitness de todos los individuos de cada generación a través de una modificación directa en la función de evaluación, con el único objetivo de hacer una mejor discriminación de los individuos durante el proceso de reproducción y así apresurar la evolución de los individuos generación tras generación.

Por ejemplo, una manera sencilla de aplicar factores de penalización estaría dada por una variable (*Cte*) en la función de evaluación:

$$F(\%err) = (1 - \%err + Cte) \quad (0.1)$$

Se podría condicionar el valor de la variable *Cte* para que cuando el porcentaje de error sea mayor de 0.5, ésta tome el valor de 0.3, de tal forma que el fitness para el individuo evaluado se reduzca y en el momento de la reproducción sea descartado fácilmente como posible cromosoma padre. Por otro lado, cuando el porcentaje de error sea menor de 0.5 pero mayor de 0.2 por ciento, que la variable *Cte* tome el valor de 0.1, de tal forma que su valor fitness se vea afectado solo un poco y sea más eficaz la selección de los individuos durante la reproducción. Así se asegura que únicamente los mejores individuos de cada generación sean seleccionados durante el proceso de reproducción.

2.5.3 Factores de prioridad.

Esta técnica, al igual que las dos anteriores, modifica el valor fitness de los individuos, solo que lo hace de manera diferente. Esta técnica se aplica en funciones de evaluación un poco más elaboradas, es decir, compuestas de más de un elemento o subfunción de costo. Su finalidad es la de modificar la función de evaluación de forma tal que uno de los elementos de la función tenga prioridad o mayor peso que él o los otros elementos que componen la función y así, el valor fitness del individuo evaluado, esté definido en mayor parte por el elemento prioritario.

Por ejemplo, para una función de evaluación del tipo:

$$F(err1, err2) = (1 - \%err1) + (1 - \%err2) * (fp) \quad (0.2)$$

Si la variable fp se define con un valor mayor que uno, es obvio que el valor que tome la función estará dominado por el valor que tenga $(1-\%err2)$, mientras que el elemento $(1-\%err1)$ afectará en menor medida el resultado final de la función.

2.5.4 Ciclo de un algoritmo genético con elitismo, factores de prioridad y factores de penalización.

A continuación se muestra un diagrama de flujo para un algoritmo genético que incluye elitismo y una función de evaluación con factores de prioridad y penalización.

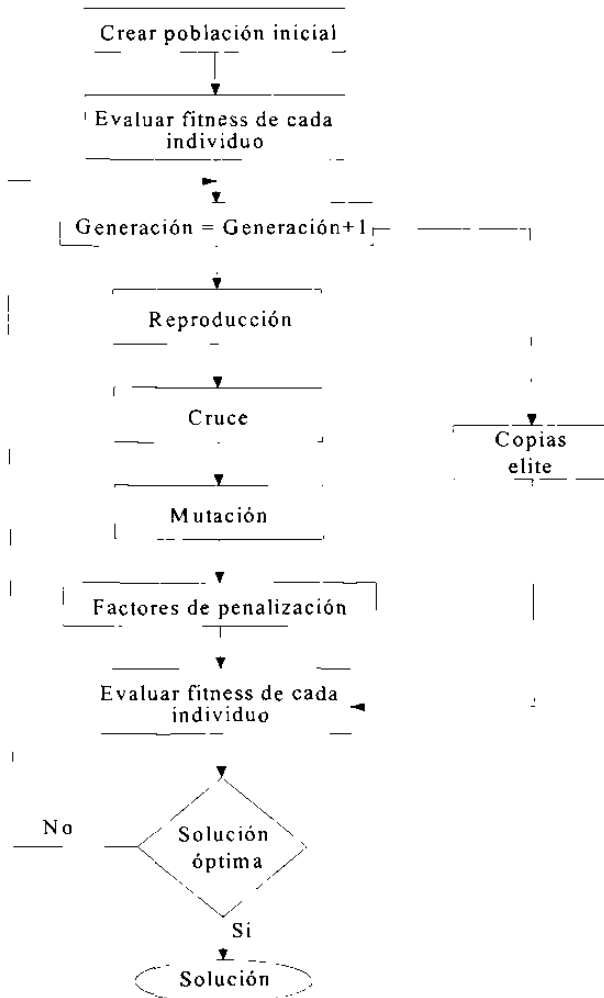


Figura 2.2 Algoritmo genético con elitismo, factores de prioridad y penalización.

CAPITULO 3

DESPACHO ECONÓMICO

3.1 Introducción.

La operación económica de un sistema eléctrico de potencia es muy importante para obtener los mayores beneficios del capital que se invierte. Por tanto, el principal objetivo en su operación es satisfacer la demanda de potencia al mínimo costo, tomando en cuenta la seguridad y confiabilidad de la red.

Los costos de producción de un sistema de potencia se pueden dividir en dos tipos; el primero se considera como costo fijo, y representa los costos de mantenimiento y personal, el segundo es un costo variable y corresponde al costo del combustible. En este capítulo se describen aspectos relacionados con este último, así como el impacto de la red de transmisión y las restricciones asociadas.

3.2 Conceptos básicos de despacho económico.

El problema de despacho económico consiste en minimizar el costo instantáneo de producción de energía que satisfaga una determinada demanda, con un conjunto de generadores disponibles definidos previo despacho. Para esto se debe considerar las limitaciones físicas de los equipos que intervienen, de las cuales en este trabajo solo se incluyen límites en generadores y líneas de transmisión.

Las funciones de costo o curvas entrada-salida de generadores que se utilizaran en este trabajo son del tipo cuadráticas y cuadráticas considerando discontinuidades de punto de válvula como las que se muestran a continuación [1].

$$F_i(P_i) = a_i P_i^2 + b_i P_i + c_i \quad (0.1)$$

$$F_i(P_i) = a_i P_i^2 + b_i P_i + c_i + \left| e_i \text{Sen} \left(f_i (P_{i_{\min}} - P_i) \right) \right| \quad (0.2)$$

Donde:

a_i, b_i, c_i, e_i y f_i = constantes.

P_i = potencia real generada por la máquina i .

$P_{i_{\min}}$ = limite inferior de generación para el generador i .

3.3 Despacho económico clásico.

El problema fundamental de despacho económico consiste en minimizar el costo de generación de n máquinas sujetas a la restricción de la demanda, es decir que la suma de las potencias generadas debe ser igual a la potencia de demanda; lo cual se expresa como sigue:

$$\text{Min} \left(\sum_{i=1}^n F_i(P_i) \right) \quad (0.3)$$

Sujeto a:

$$\sum_{i=1}^n P_i - P_d = 0 \quad (0.4)$$

$$P_{\min} < P_i < P_{\max} \quad (0.5)$$

Donde:

$F_i(P_i)$ = costo de generación de la máquina i .

P_i = potencia real generada por la máquina i .

P_d = demanda de potencia real.

P_{\max} = potencia de salida máxima de la unidad i .

P_{\min} = potencia de salida mínima de la unidad i .

La restricción mostrada por la ecuación (0.5) representa los límites máximo y mínimo de los generadores. Como es evidente, el despacho económico clásico no considera los efectos del sistema de transmisión. Por simplicidad, asumiremos que la potencia generada y de demanda está concentrada en un solo nodo.




Figura 3.1 Despacho económico clásico.

El punto de operación óptimo del sistema se tiene cuando los costos incrementales de todos los generadores son iguales (criterio de optimización).

$$\lambda_1 = \lambda_2 = \lambda_3 = \dots = \lambda_n \quad (0.6)$$

$$\lambda_i = \frac{dF_i(P_i)}{dP} = 2a_i P_i + b_i \quad (0.7)$$

Donde:

λ_i = es el costo incremental de la máquina i.

a_i, b_i = constantes de la función de costo de la máquina i.

A continuación se muestra el algoritmo de solución, para este caso, utilizado por los métodos tradicionales de solución [11]:

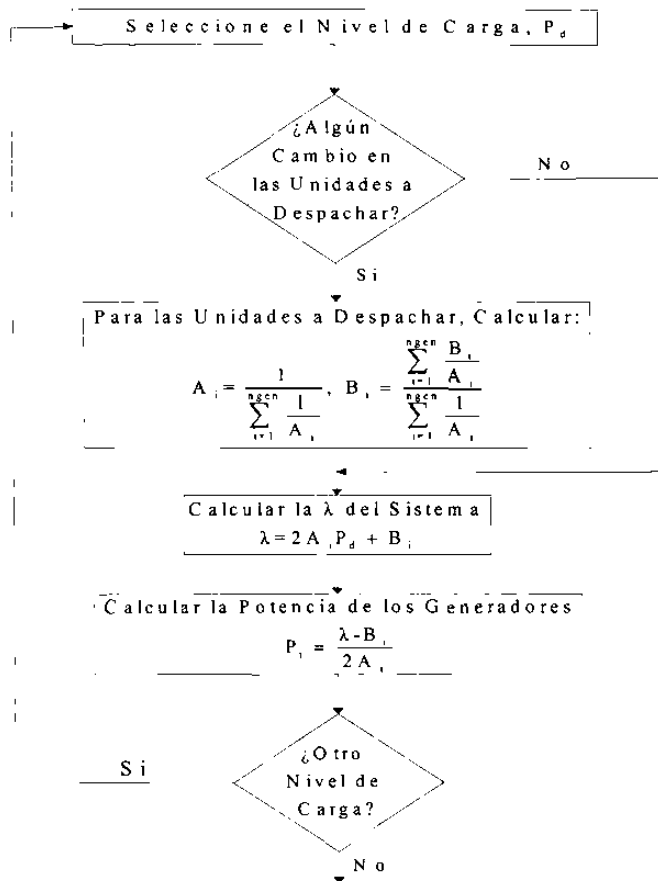


Figura 3.2 Ciclo de un método tradicional de solución al problema de despacho económico.

3.4 Despacho económico incluyendo pérdidas en la red de transmisión.

El efecto que se tiene al incluir la red de transmisión en el problema de despacho de potencia es que tendremos que considerar las pérdidas que esta ocasiona, de modo que además de satisfacer la demanda de potencia activa de las cargas habrá que incluir dichas pérdidas. Con esta restricción el problema se plantea como:

$$\text{Min} \left(\sum_{i=1}^n F_i(P_i) \right) \quad (0.8)$$

Sujeto a:

$$\sum_{i=1}^n P_i - P_d - P_l = 0 \quad (0.9)$$

$$P_{\min} \leq P_i \leq P_{\max} \quad (0.10)$$

Donde

P_l = Pérdidas de potencia real.

El criterio de optimización para este caso cambia. El punto óptimo de operación se alcanza cuando el producto del costo incremental y el factor de penalización (FP) de cada máquina son iguales entre sí en todo el sistema.

$$FP_1 \lambda_1 = FP_2 \lambda_2 = FP_3 \lambda_3 = \dots = FP_n \lambda_n \quad (0.11)$$

$$FP_i = \frac{1}{1 - \frac{\partial P_l}{\partial P_i}} \quad (0.12)$$

$\partial P_i / \partial P_i =$ es una medida de la sensibilidad de la pérdidas totales en la red de transmisión con respecto a P_i .




Figura 3.3 Despacho económico considerando la red de transmisión.

Algoritmo de solución utilizado por los métodos tradicionales de solución [11]:

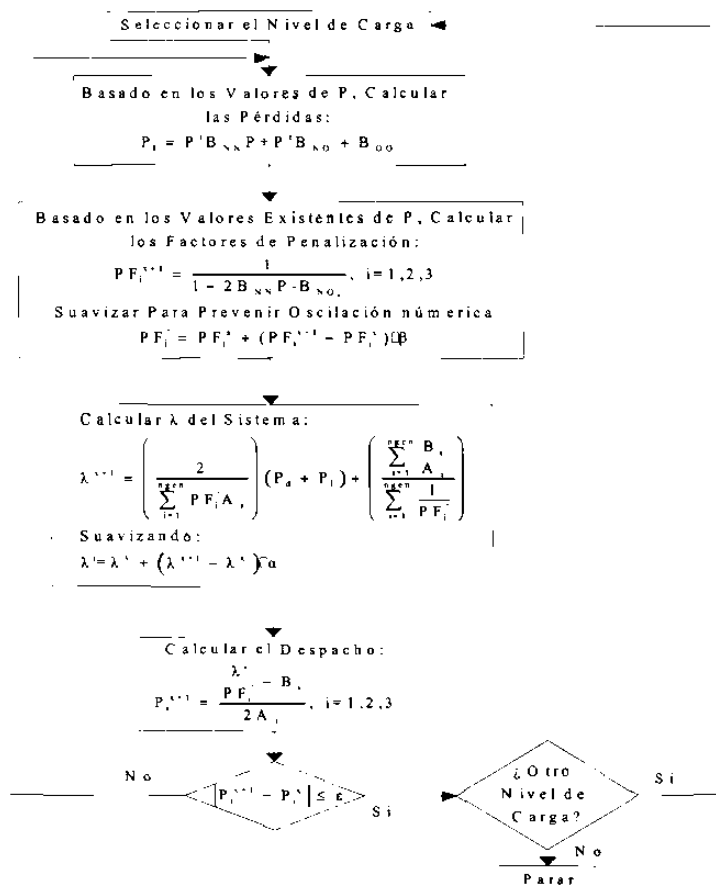


Figura 3.4 Ciclo de un método de solución tradicional al problema de despacho económico considerando la red de transmisión.

3.5 Despacho económico incluyendo restricciones.

En ocasiones, las condiciones de operación de un sistema de potencia y las características de su red de transmisión provocan que las condiciones para el despacho óptimo de energía se modifiquen. Tal es el caso de las restricciones de transmisión de potencia que presentan algunas líneas o enlaces entre dos áreas. Restricciones que en ocasiones se imponen con el fin de mantener el sistema bajo condiciones seguras de operación.

Considerando esta restricción en líneas tendríamos:

$$\text{Min} \left(\sum_{i=1}^n F_i(P_i) \right) \quad (0.13)$$

Sujeto a:

$$\sum_{i=1}^n P_i - P_d - P_{ll} = 0 \quad (0.14)$$

$$P_{\min} \leq P_i \leq P_{\max} \quad (0.15)$$

$$F_i \leq F_{\max} \quad (0.16)$$

Donde:

F_{imax} = Límite máximo de potencia activa través de la línea de transmisión.

El punto óptimo de operación para este caso es similar al del punto anterior.

3.6 Despacho económico considerando punto de válvula en las curvas de costo.

Las máquinas térmicas presentan ciertas restricciones de funcionamiento adicionalmente a los límites de generación ya mencionados. Dichas restricciones se refieren a un fenómeno termodinámico que se produce durante la apertura de válvulas para aumentar la potencia mecánica suministrada a la turbina conocido como punto o puntos de válvula. Se les llama así haciendo referencia a su curva entrada salida, obtenida mediante pruebas conocidas como de “heat run”, donde estos puntos se encuentran distribuidos a intervalos definidos por la apertura de válvulas. Esto se ilustra en la Figura 3.5.

Se sabe que las máquinas térmicas al pasar por dichos puntos en su recorrido a través de su característica entrada salida durante el proceso de subir carga tienen problemas de vibración en la caldera, lo cual debe evitarse.

La Figura 3.5 muestra una curva entrada salida para una máquina térmica tomando en cuenta el efecto de puntos de válvula y la curva “heat rate” (Razón de cambio de calor o energía calorífica respecto a la energía eléctrica de salida en Btu/Kwh) y su consecuente efecto termodinámico. Se puede observar como durante la apertura de válvulas (a partir de la segunda válvula) se da un cambio abrupto en la energía calorífica causante de las vibraciones.




Figura 3.5. Curva de costo y heat rate con puntos de válvula.

Los métodos tradicionales de solución para el problema de despacho económico utilizan una aproximación de la curva mostrada en la Figura 3.5 ignorando el efecto de los puntos de válvula, lo cual se ilustra en la Figura 3.6 ya que el método así lo requiere (convexidad de la curva entrada salida), por lo que solamente brindan una aproximación a la solución real lo cual no es deseable [2].




Figura 3.6. Curva de costo y heat rate linealizada.

Como se puede ver de la curva entrada salida de la Figura 3.5, el costo de generación para cualquier punto fuera de los puntos de válvula de la curva resultará más alto que si

utilizamos una curva que ignore dicho efecto. Esto por la función que se está utilizando en su representación ecuación (0.2). Se considera, sin embargo, que esta representa mejor el comportamiento real de una máquina térmica.




Figura 3.7. Comparativo de curvas de costo linealizada y con puntos de válvula.

Para la solución del problema de despacho económico considerando punto de válvula en las curvas de costo, aplican los mismos criterios de optimalidad anteriores, con la variante de utilizar la ecuación (0.2) que incluyan dicho efecto (0.2), en lugar de la ecuación (0.1).

CAPITULO 4

APLICACIÓN DE LA TÉCNICA DE ALGORITMOS GENÉTICOS AL PROBLEMA DE DESPACHO ECONÓMICO

4.1 Introducción.

El problema de despacho económico para un sistema de potencia real es sin duda un problema complejo de optimización, para el cual cualquier mejora en su solución representa un ahorro considerable económicamente hablando. De aquí la importancia de que las soluciones propuestas por los métodos que se utilicen estén lo más cerca posible del punto óptimo de operación real.

Uno de estos métodos son los algoritmos genéticos. Sin embargo, la calidad de las soluciones obtenidas a partir de este método depende en gran medida de la

representación o de la codificación que se haga del problema en forma de cromosoma y de la correcta evaluación de dichos cromosomas mediante una bien estructurada función de evaluación. En el presente capítulo se analizará estos dos aspectos fundamentales.

4.2 Codificación.

Como ya se mencionó antes, la aplicación de la técnica de algoritmos genéticos requiere primeramente que se codifiquen los parámetros del problema en forma de cromosoma, a partir del cual se crea la población inicial de modo que cada cromosoma represente una posible solución al problema.

Para el caso del problema en estudio, el despacho económico de carga, las posibles soluciones o la solución al problema no es más que un esquema de generación de un conjunto de generadores en línea durante el estudio. Una opción inicial sería codificar la potencia activa generada por cada máquina. Sin embargo, al codificar un problema para búsqueda genética el programador solo está limitado por su imaginación [3].

En este trabajo se utilizarán dos técnicas distintas de codificación. Una que codifique la potencia activa despachada por cada generador y otra, que aprovechando el criterio de optimalidad propuesto por técnicas tradicionales de solución que dice que el punto óptimo de operación es aquel en el que los costos incrementales de todas y cada una de las máquinas en línea son iguales, codifique costos incrementales del sistema. En ambas técnicas se incluye el caso donde se considera la red de transmisión y los factores de penalización.

4.2.1 Codificación de potencia activa.

Para este caso, la codificación consiste en la conversión decimal a binario del valor de potencia activa generada en cada máquina. Así, cada generador se modela por una cadena binaria de n bits de longitud representando su potencia generada. Un cromosoma

o individuo se forma colocando en serie las cadenas individuales de todos los generadores.

De modo que para conocer la potencia total generada por el sistema solo habrá que decodificar la cadena de bits de cada máquina y sumar los valores obtenidos. Por ejemplo, para el caso donde se tenga un sistema con tres máquinas y la solución propuesta por el algoritmo sea,

$$P_{g1}=25.0 \quad P_{g2}=45.0 \quad P_{g3}=50.0$$

Si se considera una demanda de potencia de 120.0 megawatts, despreciando las pérdidas en el sistema, al utilizar una cadena de 10 bits para codificar cada generador, tendremos un cromosoma como el siguiente:

$$\begin{array}{cccccccccccc}
 0 & 0 & 0 & 0 & 0 & 1 & 1 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 1 & 0 & 1 & 1 & 0 & 1 & 0 & 0 & 0 & 0 & 1 & 1 & 0 & 0 & 1 & 0 \\
 I & & & & & P_{g1} & & & & I & & & & & P_{g2} & & & & & I & & & & & & & & & & P_{g3} & & & I
 \end{array}$$

Que decodificado y sumado resulta 120.0 Mw.

4.2.2 Codificación de costos incrementales.

La codificación de costos incrementales se basa en el criterio de optimalidad para el problema de despacho económico clásico que dice que el punto óptimo de operación se alcanza cuando los costos incrementales de todas y cada una de las máquinas son iguales.

Con esto, se abre la posibilidad de buscar este punto de operación directamente, satisfaciendo también las demás restricciones. De esta forma, el algoritmo únicamente propondrá soluciones basadas en un mismo valor de costo incremental para todas las máquinas.

Por ejemplo, para el caso donde se codifiquen costos incrementales utilizando un cromosoma de 15 bits de longitud, una solución propuesta por el algoritmo sería

0 0 1 0 0 1 0 0 0 1 0 0 0 1 1

λ_{sis}

Que representa un valor de 2.1759 (λ_{act}). Valor que se obtuvo decodificando el cromosoma de la siguiente manera:

Primeramente se calcula un valor de costo incremental normalizado.

$$\lambda_{nm} = \sum_{i=1}^{15} x_i 2^i \quad (0.17)$$

Donde:

x_i = valor del bit de la posición i (1 ó 0).

Posteriormente el costo incremental real se calcula como:

$$\lambda_{\text{act}} = \lambda_{\text{min}} + \lambda_{nm} (\lambda_{\text{max}} - \lambda_{\text{min}}) \quad (0.18)$$

Donde:

λ_{min} y λ_{max} representan los costos incrementales máximo y mínimo del sistema respectivamente.

Cuando la potencia calculada para algún generador a partir de λ_{act} rebase sus límites máximo o mínimo ($P_{\text{máx}}$, P_{min}), se fija la generación al valor límite más cercano al obtenido mediante dicho cálculo. Es decir, si el valor de generación obtenido viola o sobrepasa el límite superior, se ignora el valor propuesto y se fija la generación al valor

máximo permitido ($P_{\text{máx.}}$). En consecuencia, el costo incremental del generador será distinto al costo incremental del sistema. En cierta forma se independiza de este. Sin embargo esto no afecta los resultados. Existe también la posibilidad de codificar costos incrementales individuales siguiendo un procedimiento similar al aplicado en la codificación de potencia activa.

4.3 Función de evaluación.

En algoritmos genéticos para poder evaluar cada una de los individuos o soluciones propuestas es necesario decodificar la información contenida en sus cadenas de bits, tal como se hizo en los puntos anteriores, decodificar las cadenas de bits a valores reales de potencia generada o costo incremental respectivamente.

Una vez obtenidos los valores reales de potencia de generación o costos incrementales es posible evaluar el nivel de aptitud para la solución que se propone analizando cómo esta satisface las restricciones impuestas por el problema y asignarle un valor representativo a dicho nivel de aptitud.

La asignación del nivel de aptitud para cada individuo en algoritmos genéticos se hace a través de la función de evaluación. Al igual que el método de codificación está definida por el programador. A continuación se presentan los métodos de evaluación que se siguen en este trabajo para las distintas funciones de evaluación utilizadas.

Para el caso de la primera función de evaluación [9]:

$$Fit = sf_1 (1 - \%lerr_p)^{sp_1} + sf_2 (1 - \%lerr_\lambda)^{sp_2} \quad (0.19)$$

Donde:

sf 's = Ponderación de la restricción.

$sp's$ = Ponderación de la restricción en la población.

El método de evaluación es el siguiente:

Para el caso de codificación de potencia activa, se decodifica el cromosoma a valores de potencia activa generada por cada máquina y a partir de estos valores de potencia se verifica si el individuo o solución propuesta satisface las restricciones impuestas y los costos incrementales entre máquinas son iguales (solo en el caso de no tener ninguna máquina limitada) y determinar si es el punto óptimo de operación, lo cual se indica a continuación:

La desviación de cada individuo a la restricción de potencia (l_{errp}) se establece como:

$$l_{errp} = \left| \sum_{i=1}^n P_i - P_d \right| \quad (0.20)$$

El criterio de optimización establece costos incrementales iguales en todos los generadores.

$$\lambda_{g1} = \lambda_{g2} = \lambda_{g3} = \dots = \lambda_n \quad (0.21)$$

Se incluye un nuevo término para calcular la magnitud del error de cada individuo respecto a su promedio, definido por:

$$\lambda_{avg} = \frac{\sum_{i=1}^n \lambda_i}{ngen} \quad (0.22)$$

$$\lambda_{err} = \sum_{i=1}^n \left| \lambda_{avg} - \lambda_i \right| \quad (0.23)$$

Donde:

λ_{err} = error de lambda.

λ_{avg} = costo incremental promedio del individuo.

λ_i = costo incremental del generador i .

n_{gen} = número de generadores.

λ_{err} nos permite conocer el grado en el que el individuo evaluado satisface el criterio de optimización.

Como el algoritmo realiza una comparación entre todos los individuos de la población para elegir a los mejores, es necesario obtener los valores de l_{err} y λ_{err} de cada individuo con respecto al resto de la población. Como resultado tendremos una función de evaluación basada en porcentajes.

$$\%lerr = \frac{inderr - err_{\min}}{err_{\max} - err_{\min}} \quad (0.24)$$

Donde:

$\%lerr$ = por ciento de error en la restricción con respecto al resto de la población.

$inderr = \lambda_{err} l_{err}$.

err_{\max} = máximo error de la población.

err_{\min} = mínimo error de la población.

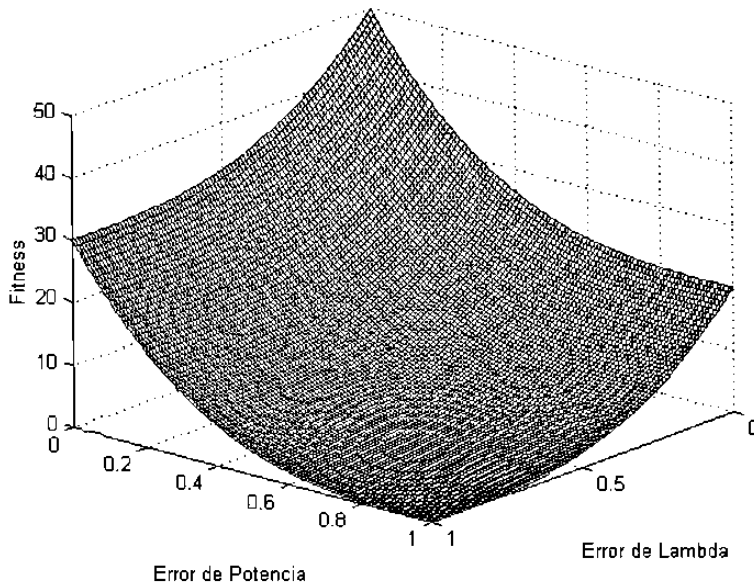


Figura 4.1. Función de Evaluación (Fitt).

La Figura 4.1 muestra la grafica de la función de evaluación muestra el espacio de solución propuesto para el problema, en donde la mejor solución se encuentra en las coordenadas $(x, y, z)=(0,0,50)$ equivalente a satisfacer la demanda de potencia (x) al mínimo costo (y). El valor de 50 se obtuvo al utilizar un valor de 30 para sf_1 y 20 para sf_2 que equivale según la estructura de la función Fitt a dar prioridad a la restricción de potencia, lo cual no significa perder de vista el objetivo de minimizar costo, significa mejorar el proceso de convergencia. Se consideró también un valor de 3 para los sp 's con la finalidad de atenuar la pendiente entre puntos del espacio de solución y alcanzar convergencia.

Como es evidente en la evaluación, se utilizó codificación de potencia activa. No obstante, es posible usar codificación de costos incrementales apoyándose en las funciones de costo incremental para obtener el valor de potencia generada por máquina. En general es posible utilizar ambos tipos de codificación para cualquier método de evaluación.

Para el caso de la función:

$$Fit = \frac{1}{\left(1 + c \left(\frac{DP}{P_d}\right)\right)} \quad (0.25)$$

$$DP = \sum_{i=1}^n P_i - P_d \quad (0.26)$$

Donde:

c = constante.

DP = desviación de potencia.

El valor fitness estará afectado inversamente proporcional por la magnitud de la desviación de potencia, donde el valor máximo de fitness será 1.0, y se alcanzará cuando la desviación de potencia sea cero. El valor de la constante “ c ” ayudará a ponderar el efecto de dicha desviación y tendrá efectos similares al de los coeficientes sp 's de la función analizada anteriormente.

En los casos donde se involucran un número de generadores relativamente grande la función de evaluación incluirá un término de minimización de costo de generación con el que se dará mayor peso o valor fitness a los individuos que satisfagan las restricciones impuestas que impliquen un menor costo. La función incluyendo el término de minimización es la siguiente:

$$Fit = sf_1 \left(1 - 0.1 \left(\frac{DP}{factor}\right)\right)^{sp_1} + sf_2 \left(\frac{C_{max} - C_{ind}}{C_{max}}\right)^{sp_2} \quad (0.27)$$

Donde:

C_{max} = costo máximo de operación en la generación.

C_{min} = costo mínimo de operación en la generación.

$factor$ = factor de ponderación de la desviación de potencia.

C_{ind} = costo total de generación del individuo evaluado.

Para este caso también se utiliza la desviación de potencia en uno de los términos de la función de evaluación (Fit), donde para el mejor de los casos este aportará un 90% del valor de sf_1 . El segundo término evalúa los costos totales de generación para cada individuo y lo compara contra el costo mayor de generación obtenido en la población (C_{max}) y lo pondera contra este mismo, donde aportará mayor valor a la función de evaluación aquel individuo con menor costo.

La razón de dicha modificación es que, para estos casos, las funciones anteriores presentaban un proceso de convergencia un poco más lento.

Para los casos en que se consideren restricciones en líneas de transmisión se monitorea el flujo de potencia a través de la línea restringida y en su caso se evalúa la violación de la restricción. La forma en que se evalúa dicha restricción es incluyendo un término extra en la función de evaluación, modifiquen estas de la siguiente forma:

$$Fit = sf_1 \left[(1 - \%lerr_p) \right]^{sp_1} + sf_2 \left[(1 - \%lerr_\lambda) \right]^{sp_2} + sf_3 (1 - Diflu)^{sp_3} \quad (0.28)$$

$$Fit = sf_1 \left(\frac{1}{\left(1 + c \left(\frac{DP}{P_d} \right) \right)} \right)^{sp_1} + sf_2 (1 - Diflu)^{sp_2} \quad (0.29)$$

$$Fit = sf_1 \left(1 - 0.1 \left(\frac{DP}{factor} \right) \right)^{sp_1} + sf_2 \left(\frac{C_{max} - C_{ind}}{C_{max}} \right)^{sp_2} + sf_3 (1 - Diflu)^{sp_3} \quad (0.30)$$

$$Diflu = \left| \left(\frac{|Flujo(i)| - F\lim(i)}{F\lim(i)} \right) \right| \quad (0.31)$$

Donde:

$Diflu$ = Violación de flujo ponderado por la línea.

$Flujo(i)$ = Flujo medido por la línea i .

$Flim(i)$ = Flujo límite por la línea i .

Donde el término adicional monitorea el flujo a través de la línea restringida comparándolo con el valor límite y ponderando dicho violación para conocer la magnitud de esta respecto al límite. Para el mejor de los casos se espera que $diflu$ sea cero y se agregue valor a la función de evaluación en proporción a sf .

En los casos en que se considere punto de válvula en las funciones de costo, lo único que se modifica es precisamente la función entrada-salida, mediante la cual se evaluará el costo de generación por máquina de los distintos esquemas de generación propuestos durante la búsqueda.

$$F_i(P_i) = a_i P_i^2 + b_i P_i + c_i + |e_i \text{Sen}(f_i (P_{\text{min}} - P_i))| \quad (0.32)$$

Donde:

e_i, f_i = Constantes de la función de costo de la máquina i .

CAPITULO 5

SIMULACIÓN MANUAL DE UN ALGORITMO GENÉTICO.

5.1 Introducción.

En esta sección se realizará la simulación manual de un algoritmo genético aplicado a un problema de despacho económico, donde es posible ver a detalle el funcionamiento de los tres operadores que intervienen en el algoritmo genético básico y evaluar su proceso de convergencia.

Para este caso los parámetros del problema a codificar serán los costos incrementales normalizados del sistema. Se utilizará una cadena de 15 bits de longitud en código binario (1's y 0's).

5.2 Planteamiento del problema.

A continuación se muestran los datos del sistema de prueba donde se resuelve el problema de despacho económico básico utilizando algoritmos genéticos.




Figura 5.1. Sistema de prueba 1.

Tabla 5.1. Datos de generadores del sistema de la Fig. 5.1.

Unidad	a	b	c	P _{min}	P _{máx}
1	0.006	2	140	25	100
2	0.0075	1.5	120	35	100
3	0.007	1.8	80	50	100

5.2.1 La función de evaluación.

Como se mencionó, los parámetros del problema se codificarán en forma de una cadena de números binarios de 15 bits de longitud como la que se muestra en la Figura 5.2.

0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
 x_1 x_2 x_3 x_4 x_5 x_6 x_7 x_8 x_9 x_{10} x_{11} x_{12} x_{13} x_{14} x_{15}

Figura 5.2 Cromosoma de 15 bits.

Para evaluar el valor fitness de cada individuo es necesario primeramente decodificar la información contenida en su cadena de bits. Para hacer esto utilizaremos la ecuación (5.1), con la cual obtendremos el valor de costo incremental normalizado propuesto por cada individuo como posible solución.

$$\lambda_{nm} = \sum_{i=1}^{15} (x_i * 2^i) \quad (5.1)$$

Una vez decodificada la información, se calcula el valor fitness siguiendo el procedimiento que se muestra a continuación.

Primeramente se calcula el costo incremental real mediante:

$$\lambda_{act} = \lambda_{min} + \lambda_{nm} (\lambda_{max} - \lambda_{min}) \quad (5.2)$$

$\lambda_{m\acute{a}x}$ y $\lambda_{m\acute{i}n}$ corresponden a los costos incrementales máximo y mínimo del sistema respectivamente y se obtienen calculando los costos incrementales de todas las máquinas conectadas al sistema considerando sus respectivas potencias máximas y mínimas de generación.

Enseguida se calculan las potencias de generación de cada máquina conectada al sistema para el costo incremental λ_{act} como sigue:

$$P(i) = \frac{\lambda_{act} - b(i)}{2a(i)} \quad (5.3)$$

$i=1,2,\dots$, número de máquinas conectadas al sistema.

Una vez obtenido esto, se calcula la potencia total de generación:

$$P_{tg}(j) = \sum_{i=1}^{ngen} (P(i)) \quad (5.4)$$

$j=1,2,\dots$, número de individuo en la población.

A continuación se calcula el balance generación-demanda, cuya diferencia llamaremos DP .

$$DP(j) = |P_{tg}(j) - \text{Carga}| \quad (5.5)$$

Donde Carga es la potencia total de demanda del sistema.

Por último, se calcula el valor fitness para cada individuo en la población con la siguiente función de evaluación:

$$Fit(j) = \frac{1}{1 + c * \left(\frac{DP(j)}{\text{Carga}} \right)} \quad (5.6)$$

$$0 \leq Fit \leq 1$$

Donde c es una constante entera positiva y cumple la función de ponderar el valor de $Fit(j)$ en función de la desviación de potencia (DP).

Este procedimiento se repite para cada individuo en la población.

5.2.2 Parámetros básicos.

Para este problema en particular los valores de nuestros parámetros básicos serán:

Población=20

Generaciones=10

Intervalo de aproximación=32768 (2^{15})

Tipo de cruce= cruce de un solo punto

Número de descendientes=2

Probabilidad de cruce=0.8

Probabilidad de mutación=0.1

Como la simulación se va a hacer manualmente no se requiere del valor de semilla aleatoria para inicializar nuestro algoritmo.

5.2.3 Población inicial.

La población inicial se crea aleatoriamente. Se forman 20 distintas cadenas de 15 bits cada una.

Tabla 5.2 Población inicial.

1.-	1	0	0	1	0	0	1	1	1	0	1	0	0	1	0
2.-	0	1	0	0	0	1	0	0	0	1	1	0	0	0	0
3.-	0	0	0	0	1	1	0	1	1	1	0	0	0	1	0
4.-	1	1	1	0	1	0	0	1	1	0	1	1	1	1	1
5.-	0	1	0	0	1	0	0	0	0	1	1	0	1	1	1
6.-	1	0	1	1	1	0	0	0	0	1	1	0	1	0	0
7.-	1	0	1	1	0	1	0	1	1	0	0	1	0	0	1
8.-	0	1	1	0	1	0	1	1	1	1	0	0	0	1	1
9.-	1	0	0	0	0	1	1	1	0	1	0	0	1	1	1
10.-	1	0	0	1	0	0	1	1	0	1	0	1	0	0	0
11.-	1	0	0	1	1	1	0	1	1	0	1	0	0	0	0
12.-	1	0	0	1	1	0	1	0	0	1	0	0	1	0	1
13.-	1	1	1	0	1	0	1	1	1	0	1	0	0	1	0
14.-	0	1	1	0	0	1	0	1	1	0	1	0	1	1	0
15.-	1	0	1	0	0	1	0	0	0	1	1	0	1	1	1

16.-	1	0	1	0	0	1	0	1	0	0	1	1	0	1	0
17.-	0	1	1	0	0	1	0	0	1	1	0	0	1	1	0
18.-	0	1	1	1	1	0	0	0	1	0	1	1	1	0	0
19.-	0	1	1	0	1	0	1	1	1	0	0	1	1	0	1
20.-	0	0	0	0	0	0	1	1	1	0	1	0	1	1	0

5.2.4 Reproducción.

Para iniciar el proceso de reproducción, se calculan los fitness de todos los individuos en la población, para posteriormente elegir únicamente los más aptos. Esto último se hace siguiendo el procedimiento descrito a continuación.

Se calcula el porcentaje del fitness total que representa el individuo evaluado.

$$\%fit(j) = \frac{Fit(j)}{\sum_{i=1}^{\#ind.} Fit(i)} \quad (5.7)$$

Como es de esperarse los individuos con más alto porcentaje tendrán mayor probabilidad de ser seleccionados durante la reproducción.

Se calcula el número de veces que cada individuo es seleccionado durante la reproducción.

$$nselec(j) = \frac{Fit(j)}{Fit_{prom}} \quad (5.8)$$

Donde $nselec(j)$ es el número de veces que se selecciona el individuo j durante la reproducción o número de copias que se tendrá del individuo j para la acción de los operadores de cruce y mutación.

5.2.5 Cruce.

El tipo de cruce que se va a utilizar es el cruce de un solo punto.

Ejemplo:

```
Individuo A 0 1 0 0 0 1 0 | 0 0 1 1 0 0 0 0
Individuo B 0 1 1 0 1 0 1 | 1 1 0 0 1 1 0 1
```

Con $k=7$

```
Individuo A' 0 1 0 0 0 1 0 1 1 0 0 1 1 0 1
Individuo B' 0 1 1 0 1 0 1 0 0 1 1 0 0 0 0
```

| representa el punto de cruce.

5.2.6 Mutación.

La mutación, que consiste en cambiar los 0's por 1's y viceversa en las cadenas de bits aleatoriamente y con cierta probabilidad, se realizará de la siguiente forma: dado que los parámetros básicos dicen que la probabilidad de mutación a utilizar es de 0.1 y se tienen un total de 300 bits en la población (número de individuos por bits por individuo), tendremos 300×0.1 mutaciones por generación. La elección del bit que cambia es aleatoria. De modo que para:

```
Individuo A' 0 1 0 0 0 1 0 1 1 0 0 1 1 0 1
```

Con mutación en los bits 3 y 5 queda como:

```
Individuo A'' 0 1 1 0 1 1 0 1 1 0 0 1 1 0 1
```

Y para

Individuo B' 0 1 1 0 1 0 1 0 0 1 1 0 0 0 0

Con mutación en los bits 8 y 14 queda como:

Individuo B" 0 1 1 0 1 0 1 1 0 1 1 0 0 1 0

5.2.7 Resultados.

Tabla 5.3 Resultados de la primera generación.

Individuos Generación 1														<i>Fit</i>	<i>%fit</i>	<i>nselec</i>	<i>#act</i>		
1.-	1	0	0	1	0	0	1	1	1	0	1	0	0	1	0	0.0798	0.0252	0.5048	1
2.-	0	1	0	0	0	1	0	0	0	1	1	0	0	0	0	03809	0.1205	2.4095	2
3.-	0	0	0	0	1	1	0	1	1	1	0	0	0	1	0	0.4926	0.1558	3.1161	3
4.-	1	1	1	0	1	0	0	1	1	0	1	1	1	1	1	0.0388	0.0123	0.2454	0
5.-	0	1	0	0	1	0	0	0	0	1	1	0	1	1	1	0.4182	0.1323	2.6455	3
6.-	1	0	1	1	1	0	0	0	0	1	1	0	1	0	0	0.0550	0.0174	0.3479	0
7.-	1	0	1	1	0	1	0	1	1	0	0	1	0	0	1	0.0564	0.0178	0.3568	0
8.-	0	1	1	0	1	0	1	1	1	1	0	0	0	1	1	0.1487	0.0470	0.9407	1
9.-	1	0	0	0	0	1	1	1	0	1	0	0	1	1	1	0.0941	0.0298	0.5953	1
10.-	1	0	0	1	0	0	1	1	0	1	0	1	0	0	0	0.0802	0.0254	0.5073	1
11.-	1	0	0	1	1	1	0	1	1	0	1	0	0	0	0	0.757	0.0239	0.4789	1
12.-	1	0	0	1	1	0	1	0	0	1	0	0	1	0	1	0.711	0.0225	0.4498	0
13.-	1	1	1	0	1	0	1	1	1	0	1	0	0	1	0	0.0385	0.0122	0.2435	0
14.-	0	1	1	0	0	1	0	1	1	0	1	0	1	1	0	0.1642	0.0519	1.0387	1

15.-	1	0	1	0	0	1	0	0	0	1	1	0	1	1	1	0.0662	0.0209	0.4188	0
16.-	1	0	1	0	0	1	0	1	0	0	1	1	0	1	0	0.0657	0.0208	0.4156	0
17.-	0	1	1	0	0	1	0	0	1	1	0	0	1	1	0	0.1668	0.0528	1.055	1
18.-	0	1	1	1	1	0	0	0	1	0	1	1	1	0	0	0.1191	0.0377	0.7534	1
19.-	0	1	1	0	1	0	1	1	1	0	0	1	1	0	1	0.1492	0.0472	0.9438	1
20.-	0	0	0	0	0	0	1	1	1	0	1	0	1	1	0	0.4004	0.1266	2.5329	3

Tabla 5.4 Resultados de la segunda generación.

	Individuos Generación 2															<i>Fit</i>	<i>%fit</i>	<i>nselect</i>	<i>#act</i>
1.-	0	1	1	0	1	1	0	1	1	0	0	1	1	0	1	0.1447	0.0283	0.5666	1
2.-	0	1	1	0	1	0	1	1	0	1	1	0	0	1	0	0.1496	0.0293	0.5857	1
3.-	0	1	0	0	0	1	0	1	1	1	1	0	1	1	0	0.3589	0.0703	1.4052	1
4.-	0	1	1	0	0	1	0	0	1	1	1	0	0	0	0	0.1665	0.0326	0.6519	1
5.-	0	0	0	0	0	1	0	1	1	1	0	0	1	1	1	0.4170	0.0817	1.6327	2
6.-	1	0	1	0	0	1	1	1	0	1	0	0	0	0	0	0.0644	0.0126	0.2522	0
7.-	0	0	0	0	0	1	0	1	1	1	0	0	0	1	0	0.4166	0.0816	1.6312	2
8.-	1	1	1	0	1	0	1	1	1	1	0	0	0	1	0	0.0385	0.0075	0.1507	0
9.-	0	0	1	0	1	1	1	1	1	0	1	0	1	1	1	0.6505	0.1274	2.547	3
10.-	0	0	0	0	0	0	0	0	1	1	0	0	0	1	0	0.380	0.0744	1.4879	1
11.-	0	1	1	1	1	0	0	0	0	0	1	1	1	0	0	0.1202	0.0235	0.4699	1
12.-	0	1	0	0	1	0	1	1	0	1	1	0	1	1	1	0.2977	0.0583	1.1656	1
13.-	0	1	0	0	1	0	0	0	0	1	1	0	0	1	0	0.3286	0.0643	1.286	1
14.-	0	0	0	0	0	1	1	1	1	1	1	0	1	1	1	0.4348	0.0851	1.702	2
15.-	1	1	0	0	1	0	1	1	0	1	0	1	0	1	0	0.0474	0.0093	0.1856	0

16.-	1	1	0	1	0	0	0	0	0	0	1	1	0	1	1	1	0.0457	0.0089	0.1789	0
17.-	1	1	1	0	0	1	1	1	1	0	1	0	1	1	1	0.0393	0.0077	0.1539	0	
18.-	0	0	1	0	0	0	0	0	0	1	0	0	1	1	0	0.8520	0.1667	3.335	3	
19.-	1	0	0	1	1	0	0	1	1	0	1	0	0	0	0	0.0744	0.0146	0.2913	0	
20.-	1	0	0	1	0	0	1	1	0	0	1	0	0	1	0	0.0803	0.0157	0.3144	0	

Tabla 5.3 Resultados de la tercera generación.

Individuos Generación 3															<i>Fit</i>	
1.-	0	0	1	0	1	1	0	0	1	0	0	0	1	1	1	0.7180
2.-	0	0	0	0	0	1	0	1	0	1	0	1	1	0	1	0.4139
3.-	0	1	1	0	1	1	1	1	0	1	0	0	1	1	1	0.1410
4.-	0	1	0	0	0	0	1	1	0	1	1	0	0	1	0	0.3496
5.-	1	1	0	0	0	0	1	1	1	1	1	0	1	1	1	0.0502
6.-	0	0	1	0	0	1	0	1	1	1	1	0	1	1	0	0.9206
7.-	0	1	0	1	1	0	0	1	0	1	1	0	0	1	0	0.2079
8.-	0	1	1	0	0	1	0	0	0	1	1	0	0	1	0	0.1679
9.-	0	0	0	1	0	1	0	1	1	1	0	0	0	1	0	0.602
10.-	0	1	0	0	0	0	0	0	1	1	0	0	1	1	1	0.4294
11.-	0	0	0	1	0	1	0	1	1	1	0	0	1	1	1	0.6029
12.-	0	0	1	0	1	1	1	1	1	0	1	0	1	1	1	0.6505
13.-	0	0	1	0	0	1	0	1	1	1	0	0	1	1	0	0.9255
14.-	0	0	1	0	0	1	0	0	0	1	0	0	0	1	1	0.9901
15.-	0	0	1	0	1	1	1	1	0	1	1	0	1	1	0	0.6556
16.-	0	0	1	0	0	0	0	0	1	1	1	0	1	1	1	0.8737

17.-	0	0	1	0	1	0	0	0	1	1	0	0	1	1	1	0.820
18.-	0	0	1	0	0	1	0	1	1	0	1	0	1	1	1	0.9302
19.-	0	1	0	0	1	1	1	1	0	1	1	0	1	1	1	0.2649
20.-	0	0	1	0	1	0	0	0	0	0	1	1	1	0	1	0.8384

Donde #act es en número de veces que aparece el esquema en la población.

Como se puede ver en las tablas de resultados por generación, en la tercera generación se alcanza una solución óptima por parte del individuo 14 con un fitness de 0.9901 que corresponde a la siguiente solución:

$$\lambda=2.1759$$

$$P_{g1}=25.0$$

$$P_{g2}=45.0607$$

$$P_{g3}=50.0$$

$$\text{Desviación de potencia}=0.0607$$

$$\text{Costo}=584.06$$

5.3 Solución al problema planteado mediante un método matemático tradicional.

A continuación se presenta la solución para el problema resuelto arriba utilizando el método del Lagrangiano.

Como primer paso se plantean las funciones de costo para cada generador con los parámetros mostrados en la Tabla 5.1.

$$F(P_1) = 0.006P_1^2 + 2P_1 + 140$$

$$F(P_2) = 0.0075P_2^2 + 1.5P_2 + 120$$

$$F(P_3) = 0.007P_3^2 + 1.8P_3 + 80$$

Se formula la función de costo para el despacho de las tres unidades:

$$F(P) = 0.006P_1^2 + 2P_1 + 140 + 0.0075P_2^2 + 1.5P_2 + 120 + 0.007P_3^2 + 1.8P_3 + 80 + \lambda(120 - P_1 + P_2 + P_3)$$

Se calcula el Lagrangiano para el sistema de ecuaciones y se iguala a cero.

$$\frac{dF(P)}{dP} = \begin{bmatrix} \frac{dF(P)}{dP_1} \\ \frac{dF(P)}{dP_2} \\ \frac{dF(P)}{dP_3} \\ \frac{dF(P)}{d\lambda} \end{bmatrix}$$

$$\frac{dF(P)}{dP} = \begin{bmatrix} 0.012P_1 + 2 - \lambda \\ 0.015P_2 + 1.5 - \lambda \\ 0.014P_3 + 1.8 - \lambda \\ 120 - P_1 - P_2 - P_3 \end{bmatrix} = 0$$

Y por último se resuelve el sistema de ecuaciones resultante.

$$\begin{bmatrix} 0.012 & 0 & 0 & -1 \\ 0 & 0.015 & 0 & -1 \\ 0 & 0 & 0.014 & -1 \\ -1 & -1 & -1 & 0 \end{bmatrix} \begin{bmatrix} P_1 \\ P_2 \\ P_3 \\ \lambda \end{bmatrix} = \begin{bmatrix} -2.0 \\ -1.5 \\ -1.8 \\ -120 \end{bmatrix}$$

Donde la solución propuesta es la siguiente:

$$\begin{bmatrix} P_1 \\ P_2 \\ P_3 \\ \lambda \end{bmatrix} = \begin{bmatrix} 27.24 \\ 55.125 \\ 37.644 \\ 2.32 \end{bmatrix}$$

Sin embargo, dado que la solución propone una generación de 37.5 Mw para la máquina tres, lo cual, por sus límites de generación no se permite, se propone una solución en que se fija la potencia de salida de dicha máquina en su límite inferior y se despachan las otras dos únicamente.

$$\begin{bmatrix} 0.012 & 0 & -1 \\ 0 & 0.015 & -1 \\ -1 & -1 & 0 \end{bmatrix} \begin{bmatrix} P_1 \\ P_2 \\ \lambda \end{bmatrix} = \begin{bmatrix} -2.0 \\ -1.5 \\ 70.0 \end{bmatrix}$$

$$\begin{bmatrix} P_1 \\ P_2 \\ \lambda \end{bmatrix} = \begin{bmatrix} 20.370 \\ 49.629 \\ 2.244 \end{bmatrix}$$

Donde el costo total de generación es:

$$F(P)=583.645$$

Para este problema como es evidente el método tradicional utilizado requirió un replanteamiento del problema por la violación de límites de un generador en la solución obtenida mientras que con algoritmos genéticos no fue necesario. Y aunque el resultado obtenido con algoritmos genéticos se dio en forma natural, situaciones como la anterior se pueden evitar mediante un sencillo pero efectivo condicionamiento de programación.

CAPITULO 6

FUNDAMENTOS MATEMÁTICOS DE LOS ALGORITMOS GENÉTICOS.

6.1 Introducción

El análisis del funcionamiento de los algoritmos genéticos se ha centrado básicamente en elementos individuales (cromosomas) y sus características como posibles soluciones óptimas de un problema determinado. No obstante, para entender realmente qué hace a un algoritmo genético para mejorar el conjunto de soluciones generación tras generación y qué es lo que nos garantiza que siempre será así, habrá que analizar grupos de cromosomas y sus similitudes importantes en la codificación. Sobre todo aquellos cromosomas con altos niveles de fitness. Estos últimos son quienes nos pueden guiar en la búsqueda del óptimo.

Al analizar el conjunto de cromosomas con mayor fitness en una población y establecer sus similitudes veremos que a raíz de estas, es posible representar un subconjunto de cromosomas por medio de un tercer cromosoma conocido como esquema.

6.2 Esquemas y sus características.

Un esquema [3] es una muestra de similitudes que describe un subconjunto de cadenas con similitudes en ciertas posiciones de bits. Para explicar este concepto introduciremos el símbolo "*" que representa la información irrelevante en nuestra codificación binaria. Con el alfabeto [0,1,*] podremos crear muestras de similitudes o esquemas que se requieran.

Se dice que un esquema coincide con una cadena particular, si en cada posición del esquema un 1 coincide con un 1 en la cadena, y un 0 coincide con un 0 en la cadena y un * coincide con cualquiera de los dos (0 ó 1) [3].

Ejemplo:

Considere el conjunto de cromosomas con mejores características de un problema determinado:

1.-	0	1	0	0	0	1	0	0	0	1	1	0	0	0	0
2.-	0	0	0	0	1	1	0	1	1	1	0	0	0	1	0
3.-	0	1	0	0	1	0	0	0	0	1	1	0	1	1	1
4.-	0	1	1	0	0	1	0	1	1	0	1	0	1	1	0
5.-	0	0	0	0	0	0	1	1	1	0	1	0	1	1	0
6.-	0	1	1	0	0	1	0	0	1	1	0	0	1	1	0

Analizando sus similitudes, vemos que el esquema H_1 puede representar a los 6 individuos.

$$H_1 = 0 * * * * * * * * * * * * * *$$

Al igual que el esquema H_2

$$H_2 = 0 * * 0 * * * * * * * * * * * *$$

Mientras que el esquema H_3 solo representa a los individuos 1 y 3.

$$H_3 = 0 1 0 * * * 0 0 * * * * * * *$$

Para establecer mejor este análisis, introduciremos un poco de notación, además de considerar las operaciones de reproducción, cruce y mutación sobre el esquema.

Como es de esperarse, un esquema no es exclusivo de los cromosomas con mejores características en una población determinada, solo hemos fijado nuestra atención en estos para analizar la propagación o desaparición de un esquema a través del tiempo en un algoritmo genético, por ser estos los que en realidad interesan.

En una población de n cromosomas codificados en código binario de longitud l , es posible encontrar $n \cdot 2^l$ esquemas distintos. Con la finalidad de poder clasificar o diferenciar un esquema de otro en una población, introduciremos los siguientes conceptos: orden del esquema y longitud del esquema.

6.2.1 Orden de un esquema.

El orden de un esquema es el número de 1's y 0's presentes en la muestra, que se denota como $o(H)$ para el esquema H .

Ejemplo:

Para el esquema H_1

$$H_1 = 0 * * * * * * * * * * * * * * *$$

El orden es:

$$o(H_1) = 1$$

Para el esquema H_2

$$H_2 = 0 1 0 * * * 0 0 * * * * * * * *$$

El orden es:

$$o(H_2) = 5$$

6.2.2 Longitud de un esquema.

La longitud de un esquema es la distancia que hay entre el primer y el último bit especificado o definido como 0 ó 1, y se denota como $\delta(H)$ para el esquema H .

Ejemplo:

Para el esquema H_1

$$H_1 = 0 * * * * * * * * * * * * * * *$$

Su longitud es:

$$\delta(H_1) = 0$$

ya que la primera y la última posición definida es la 1

Para el esquema H_2

$$H_2=0 \ 1 \ 0 \ * \ * \ * \ 0 \ 0 \ * \ * \ * \ * \ * \ * \ *$$

La longitud es:

$$\delta(H_2)=8-1=7$$

6.3 Efecto de la reproducción en un esquema.

El número m de cadenas de bits representadas por el esquema H en un población, en la generación t se denota como:

$$m = m(H,t) \tag{0.1}$$

Donde m puede variar de generación a generación.

Durante la reproducción, únicamente los individuos más aptos son seleccionados, de modo que cada individuo en la población es seleccionado con una probabilidad:

$$P_s = \frac{Fit_i}{\sum_{i=1}^{\#ind.} f_j} \tag{0.2}$$

Con esto, después de la reproducción esperamos tener $m(H,t+1)$ muestras del esquema H en la generación $t+1$, denotado por:

$$m(H,t+1) = m(H,t) \times \left(\frac{f(H)}{\sum f_i} \right) \times n \tag{0.3}$$

Donde:

$f(H)$ =es el fitness promedio del esquema.

n =es el número de individuos en la población.

$\sum f_i$ =Fitness total de la población.

Además como:

$$f^- = \frac{\sum_{i=1}^{\#ind} f_i}{n} \quad (0.4)$$

Podemos re escribir la ecuación anterior como:

$$m(H, t+1) = m(H, t) \cdot \frac{f(H)}{f^-} \quad (0.5)$$

Con esto se observa que un esquema cualquiera crece en número de la generación t a la generación $t+1$ si su fitness promedio esta por encima del fitness promedio de la población, y disminuye si su fitness promedio esta por debajo del fitness promedio de la población [3]

6.4 Efecto del cruce en un esquema.

Para ver de qué forma el operador de cruce afecta el crecimiento o desaparición de muestras o representantes de un esquema en una población, analizaremos su efecto sobre dos esquemas de características distintas. En particular de diferente longitud para el caso de cruce de un solo punto.

Considere los esquemas H_1 y H_2 que representan la cadena A.

$$H_1 = 1 \quad * \quad * \quad * \quad * \quad 0$$

$$H_2: * * 1 1 * *$$

$$A = 1 0 1 1 0 0$$

Al ser sometida A al operador de cruce, con el índice $k=2$ como punto de cruce tendremos que el esquema H_1 desaparecerá, ya que uno de los elementos del esquema formará parte de uno de los descendientes y el otro elemento formará parte del otro descendiente. Mientras que el esquema H_2 sobrevivirá ya que ambos elementos del esquema pasarán a formar parte de uno de los descendientes.

6.5 Efecto de la mutación en un esquema.

El operador de mutación actúa sobre los bits de una cadena cambiando los 1's por 0's y viceversa con una probabilidad p_m . Para el caso de un esquema H en particular, este sobrevivirá al operador de mutación si todos los bits definidos $o(H)$ no se ven modificados por la mutación. Como cada bit del esquema sobrevivirá a la mutación con una probabilidad $(1-p_m)$ y son independientes entre si, podemos decir que un esquema H_1 sobrevivirá con una probabilidad de $(1-p_m)$ multiplicado $o(H)$ veces. Es decir, $(1-p_m)^{o(H)}$. Para valores de $p_m \ll 1$ la probabilidad será $p_s(1-o(H)*p_m)$.

En consecuencia, un esquema de bajo orden tiene mayor posibilidad de sobrevivir al operador de mutación que un esquema de alto orden.

El crecimiento o desaparición de muestras de un esquema de una generación a otra combinando el efecto de los operadores de reproducción, cruce y mutación se evalúa a partir de la ecuación (0.6) la cual resulta de:

$$m(H, t + 1) = m(H, t) \cdot \frac{f(H)}{f} \cdot \left(1 - p_c \cdot \frac{\delta(H)}{(l-1)} - p_m \cdot o(H) \right) \quad (0.6)$$

Donde p_c corresponde a la probabilidad de cruce

Se concluye que un esquema de bajo orden, de longitud pequeña, y con fitness por encima del promedio de la población, tendrá un crecimiento de muestras generación tras generación. Esta conclusión es conocida como el teorema de esquema o teorema fundamental de los algoritmos genéticos [3].

6.6 Procesamiento manual de esquemas.

Es este apartado, analizaremos para el problema de despacho económico clásico resuelto en el Capítulo 5, como se lleva a cabo el procesamiento de esquemas y su crecimiento o desaparición generación tras generación. Pondremos especial atención en aquellos esquemas con altos valores de fitness, los cuales, como se comprobará, nos llevarán a la solución óptima.

De la población inicial, vemos que los individuos con más alto fitness son los siguientes:

```

2.- 0 1 0 0 0 1 0 0 0 1 1 0 0 0 0
3.- 0 0 0 0 1 1 0 1 1 1 0 0 0 1 0
5.- 0 1 0 0 1 0 0 0 0 1 1 0 1 1 1
14.-0 1 1 0 0 1 0 1 1 0 1 0 1 1 0
20.-0 0 0 0 0 0 1 1 1 0 1 0 1 1 0

```

Los esquemas que procesaremos serán;

```

H1= 0 * * * * * * * * * * * * * *
H2= 0 * * 0 * * * * * * * * * * * *
H3= 0 1 0 * * * 0 0 * * * * * * * *

```

Que tienen las siguientes características:

$$o(H_1)=1, \delta(H_1)=0$$

$$o(H_2)=2, \delta(H_2)=3$$

$$o(H_3)=5, \delta(H_3)=7$$

En la población inicial cada esquema presenta los siguientes valores:

Tabla 6.1 Valores de los esquemas en la población inicial.

	H ₁	H ₂	H ₃
m(H,t)	9	8	2
f(H)	0.2711	0.2864	0.3996
Muestras	2,3,5,8,14,17,18,19, 20	2,3,5,8,14,17,19,20	2,5

Con una probabilidad de cruce de $p_c=0.8$ y una probabilidad de mutación de $p_m=0.1$, se espera tener el siguiente número de muestras para los esquemas en la generación $t+1$.

$$m(H_1, t+1) = 9 \cdot \left(\frac{0.2711}{0.1581} \right) \cdot (1 - 0.1 \cdot 1) = 13.8$$

$$m(H_2, t+1) = 8 \cdot \left(\frac{0.2864}{0.1581} \right) \cdot \left(1 - 0.8 \cdot \left(\frac{3}{14} \right) - 0.1 \cdot 2 \right) = 9.1$$

$$m(H_3, t+1) = 2 \cdot \left(\frac{0.3996}{0.1581} \right) \cdot \left(1 - 0.8 \cdot \left(\frac{7}{14} \right) - 0.1 \cdot 5 \right) = 0.505$$

Analizando los individuos de la segunda generación, vemos que para los esquemas se tiene el siguiente número de muestras,

$$m(H_1, t+1) = 13$$

$$m(H_2, t+1) = 12$$

$$m(H_3, t+1) = 1$$

Lo cual concuerda con lo esperado, un **aumento** para H_1 y H_2 mientras que para H_3 el número de muestras disminuyó.

En la segunda generación cada esquema **presenta** los siguientes valores:

Tabla 6.2 Valores de los esquemas en la segunda generación.

	H_1	H_2	H_3
$m(H, t+1)$	13	12	1
$f(H)$	0.3629	0.3831	0.3286
Muestras	1,2,3,4,5,7,9,10,11, 12,13,14,18	1,2,3,5,7,9,10,12,13, 14,18	13

Se espera tener el siguiente número de **muestras** para los esquemas en la generación $t+2$.

$$m(H_1, T+2) = 1 \cdot \left(\frac{0.3629}{0.2554} \right) (1 - 0.1 \cdot 1) = 16.6$$

$$m(H_2, t+2) = 12 \cdot \left(\frac{0.3831}{0.2554} \right) \left(1 - 0.8 \cdot \left(\frac{3}{14} \right) - 0.2 \right) = 11.31$$

$$m(H_3, t+2) = 1 \cdot \left(\frac{0.3286}{0.2554} \right) \left(1 - 0.8 \cdot \left(\frac{7}{14} \right) - 0.1 \cdot 5 \right) = 0.1287$$

Analizando los individuos de la tercera **generación**, vemos que se tiene el siguiente número de muestras para los esquemas:

$$m(H_1, t+1) = 13$$

$$m(H_2, t+1) = 12$$

$$m(H_3, t+1) = 1$$

Finalmente, se encuentra una solución muy cerca del óptimo que incluye una de las muestras del esquema H_1 y H_2 .

Individuo 14 0 0 1 0 0 1 0 0 0 1 0 0 0 1 1

Se confirma el teorema fundamental de los algoritmos genéticos que predice una reproducción de muestras de un esquema entre generaciones cuando existe un fitness por encima del promedio, esquemas de corta longitud y es de bajo orden.

La convergencia al óptimo se produce como consecuencia de tomar esquemas de los mejores individuos de la población inicial que mantienen un fitness por encima del promedio, La longitud y orden de los esquemas son los que dan la pauta para su crecimiento o desaparición de una generación a otra.

CAPITULO 7

RESULTADOS

7.1 Introducción.

En el presente capítulo se presentan los resultados obtenidos al resolver diferentes problemas de despacho económico mediante la técnica de algoritmos genéticos. Primeramente se presenta un análisis paramétrico del algoritmo genético aplicado al problema de despacho económico y posteriormente los resultados obtenidos para casos de despacho económico clásico utilizando distintas técnicas de codificación. Se incluyen a casos más complejos como los de punto de válvula, pasando por aquellos en que se considere también el sistema de transmisión y restricción en líneas utilizando distintos sistemas de prueba.

7.2 Análisis paramétrico.

En este apartado se analizará el comportamiento del algoritmo genético aplicado al problema de despacho económico, en respuesta de la variación de sus parámetros básicos, haciendo énfasis en su proceso de convergencia y exactitud de resultados. Los parámetros a analizar serán: tamaño de la población, número de descendientes por cruce, tipo de cruce, probabilidad de mutación, probabilidad de cruce, elitismo, valor de la semilla aleatoria y el número de generaciones. Una vez analizado cada parámetro se fijara su valor de mejor comportamiento. El sistema de prueba utilizado para este caso se muestra a continuación.




Figura 7.1 Sistema de prueba 2.

Tabla 7.1 Red de transmisión del sistema de prueba 2.

Línea	R(pu)	X(pu)
1-2	0.10	0.20
1-4	0.05	0.20
1-5	0.08	0.30

2-3	0.05	0.25
2-4	0.05	0.10
2-5	0.10	0.30
2-6	0.07	0.20
3-5	0.12	0.26
3-6	0.02	0.10
4-5	0.20	0.40
5-6	0.10	0.30

Tabla 7.2 Datos de curvas de costo para generadores del sistema de prueba 2.

	Generador 1	Generador 2	Generador 3
a	0.00533	0.00889	0.00741
b	11.669	10.333	10.833
c	213.1	200.0	240.0

Tabla 7.3 Límites de generación para generadores del sistema de prueba 2.

	Pmin	Pmáx
Generador 1	50.0	200.0
Generador 2	37.5	150.0
Generador 3	45.0	180.0

En la Tabla 7.4 se presenta la solución de despacho económico para el sistema de prueba de la Figura 7.1 obtenida con el módulo de flujos óptimos (PSS/OPF) del Simulador de Sistemas de Potencia para Ingenieros (PSS/E™ por sus siglas en inglés). Se establece como único objetivo la minimización de costo.

Tabla 7.4 Solución de Despacho Económico para el sistema de prueba 2 utilizando PSS/OPF.

	Potencia	Costo	Lambda	Pérdidas	Desv. de Pot.
Generador 1	50.0	809.88	12.0		
Generador 2	90.6	1209.57	11.94		
Generador 3	76.1	1107.23	11.96		
Totales	216.7	3126.6		6.73	0.0

La función de costo que se utilizará en el algoritmo genético para este caso es la siguiente:

$$Fit = sf_1 \left(1 - 0.1 \left(\frac{DP}{factor} \right) \right)^{sp_1} + sf_2 \left(\frac{c_{max} - c_{ind}}{c_{max}} \right)^{sp_2} \quad (0.1)$$

Donde:

$$sf_1, sf_2, sp_1, sp_2 = 1.0, factor = 2.0$$

7.2.1 Efecto del tamaño de la población.

El tamaño de la población determina la cantidad de individuos y en consecuencia, la variedad del espacio de solución del algoritmo genético. El número de individuos en una población puede variar en un amplio margen dependiendo de la complejidad del problema a resolver, solo que entre mayor sea la población mayor será el tiempo de ejecución del algoritmo ya que tiene que decodificar, evaluar y aplicar los operadores de reproducción cruce y mutación a todos los individuos de la población durante cada generación. Sin embargo, mientras más grande sea el tamaño de la población, más rápido se alcanzará convergencia, ya que se explota con mayor eficacia el recurso de búsqueda en paralelo; una de las virtudes de los algoritmos genéticos

A continuación se muestra gráficamente los resultados obtenidos a partir de tres simulaciones de algoritmos genéticos para la solución al problema de despacho

económico. Se consideran las pérdidas en la red de transmisión del sistema anterior con distinto número de individuos en cada caso. Los parámetros básicos para este caso son:

Generaciones=100

Mutación=0.1

Descendientes=2

Sin elitismo

Cruce=0.8

Cruce uniforme

Semilla=1600

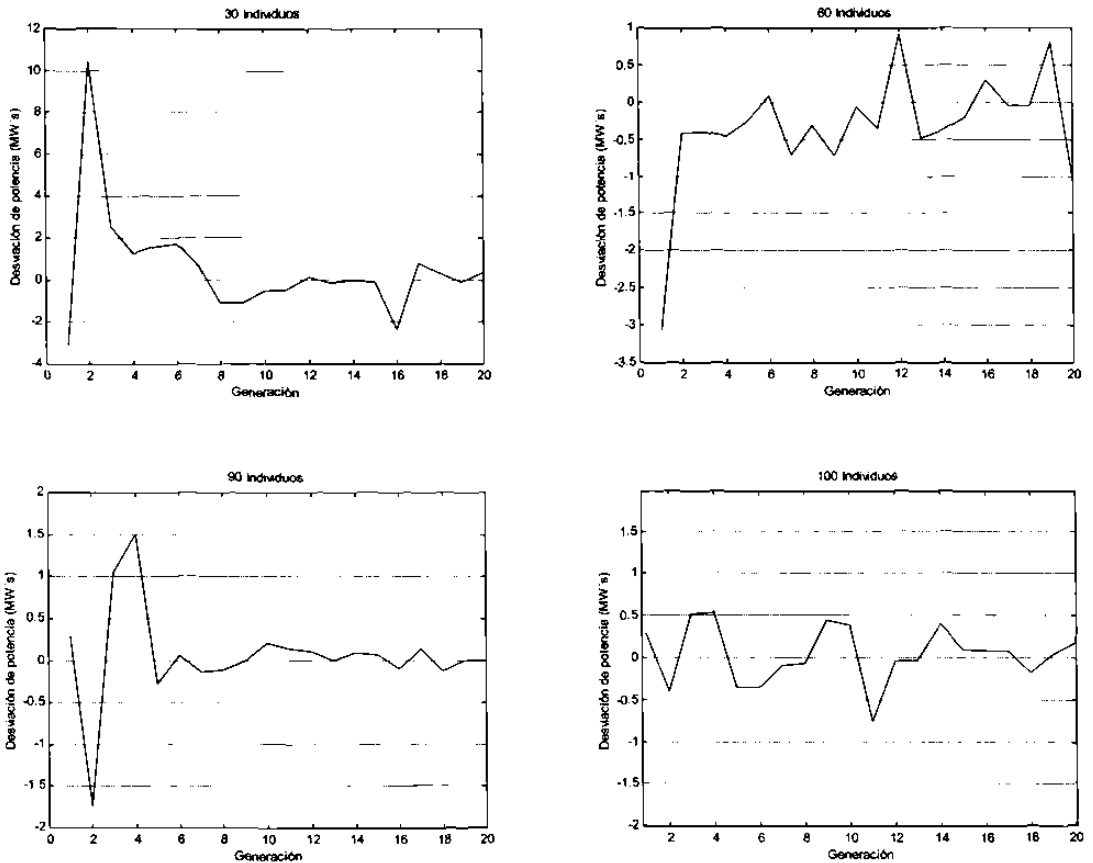


Figura 7.2 Efecto del tamaño de la población.

El resultado de las simulaciones anteriores muestra que se obtiene un mejor comportamiento para una población de 90 ó 100 individuos en adelante dado que en estos casos la restricción de potencia del problema (desviación de potencia) es menor que para los casos donde se tiene una población de 30 y 60 individuos. El comportamiento del algoritmo no parece muy estable y/o confiable en este punto. Habrá que tomar en cuenta que el análisis apenas inicia y faltan algunos parámetros por ajustar

para que el algoritmo quede bien sintonizado. Mientras tanto, de aquí en adelante se utilizará una población de 100 individuos.

7.2.2 Efecto del tipo de cruce empleado.

El tipo de cruce empleado impacta directamente la calidad y el número de generaciones requeridas para alcanzar una solución. Como se recordará, el cruce es un proceso de intercambio de información entre cromosomas; de modo que el utilizar uno u otro tipo de cruce pareciera indistinto, sin embargo, para determinado problema el cruce uniforme pudiera funcionar mejor para los objetivos buscados mientras que para otros el cruce de un solo punto sería el ideal. Siempre se busca encontrar el tipo de cruce que mejor se adapte al problema en cuestión. La Figura 7.3 se muestra gráficamente los resultados obtenidos utilizando cruce de un solo punto y cruce uniforme. Los parámetros básicos para este caso son:

Generaciones=100

Mutación=0.1

Descendientes=2

Sin elitismo

Cruce=0.8

Población=100

Semilla=1600

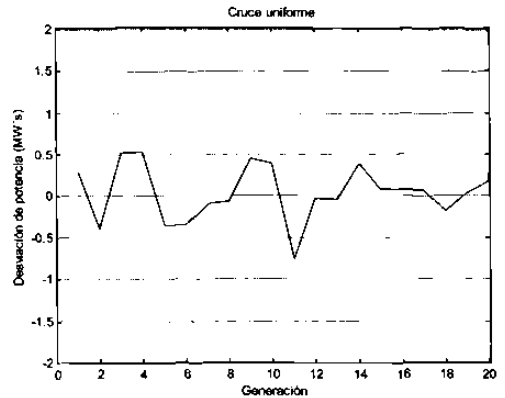



Figura 7.3 Efecto del tipo de cruce empleado.

Como se puede apreciar, el comportamiento del algoritmo utilizando cruce uniforme es ligeramente mejor que utilizando cruce de un solo punto, dado que se alcanza una mayor desviación de potencia con este último. La razón por la cual estamos evaluando

el análisis paramétrico por medio de la desviación de potencia es debido a que dicha desviación no es más que una de las restricciones del problema de despacho económico que si no se satisface, el problema no se ha resuelto aún. Una vez satisfecha esta restricción se debe evaluar si la solución propuesta es la más económica y los generadores están dentro de sus límites de generación. De aquí hasta el término del análisis usaremos cruce uniforme.

7.2.3 Efecto del número de descendientes por cruce.

El número de descendientes por cruce determina la variedad del espacio de solución entre generaciones. Por ejemplo, al tener un descendiente por cruce, existe mayor diversidad de individuos para la siguiente generación por la naturaleza del proceso de reproducción. Si se tiene dos descendientes por cruce, el camino que tome la convergencia estará definido en gran parte por los individuos de las primeras generaciones. Esto se cumple tanto para el cruce de un solo punto como para el cruce uniforme. La Figura 7.4 se muestra el comportamiento del algoritmo con uno y dos descendientes para el cruce uniforme. Los parámetros básicos para este caso son:

Generaciones=100

Mutación=0.1

Cruce uniforme

Sin elitismo

Cruce=0.8

Población=100

Semilla=1600





Figura 7.4 Efecto del número de descendientes por cruce.

Como puede verse, el número de descendientes que brinda mejores resultados, en cuanto a la magnitud de la desviación de potencia se refiere, es dos descendientes por cruce para el problema en estudio. De aquí hasta el término del análisis utilizaremos dos descendientes por cruce.

7.2.4 Efecto de la probabilidad de mutación.

Aunque se dice que el operador de mutación juega un rol secundario en los algoritmos genéticos, a continuación se verá su impacto en los resultados obtenidos para distintos valores de probabilidad de mutación. Es decir, variando la ocurrencia de mutaciones por generación. Los parámetros básicos para este caso son:

Generaciones=100

Descendientes=2

Sin elitismo

Cruce uniforme

Cruce=0.8

Población=100

Semilla=1600

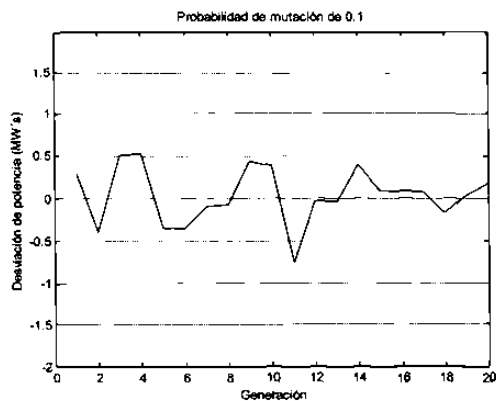
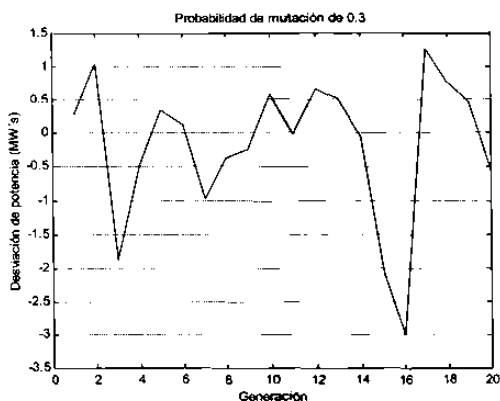


Figura 7.5 Efecto de la probabilidad de mutación.

Como se puede ver en la Figura 7.5, una probabilidad de mutación pequeña brinda mejores resultados. Esto es claro tomando en cuenta que el efecto del operador de mutación es cambiar los bits de los cromosomas de 1 a 0 y viceversa para el caso de codificación binaria, ocasionando que se “anule” el efecto del operador de cruce. En general, se recomienda que se utilice una probabilidad de mutación baja para cualquier

problema que se pretenda resolver utilizando algoritmos genéticos. De aquí en adelante utilizaremos una probabilidad de mutación de 0.1 para el resto del estudio.

7.2.5 Efecto de la probabilidad de cruce.

Como se mencionó antes, el operador de cruce es fundamental en algoritmos genéticos, ya que es a través de este operador que se realiza un intercambio de información o “experiencia” entre soluciones no viables para encontrar soluciones viables. De la magnitud de la probabilidad de cruce depende se dé el intercambio de información en menor o mayor grado. A continuación se muestran dos casos con diferente probabilidad de cruce.

Generaciones=100

Mutación=0.1

Descendientes=2

Sin elitismo

Cruce uniforme

Población=100

Semilla=1600





Figura 7.6 Efecto del valor de la probabilidad de cruce.

El tener un mayor número de cruces en cada generación propicia se alcance convergencia en menor tiempo debido al efecto del operador de cruce. De esta forma vemos que es conveniente se maneje una probabilidad de cruce alta en general para cualquier problema que se pretenda resolver utilizando la técnica de algoritmos genéticos. De aquí en adelante utilizaremos una probabilidad de cruce de 0.8.

7.2.6 Efecto de incluir elitismo.

El incluir elitismo en la aplicación de algoritmos genéticos resulta de gran ayuda, ya que se tiene la posibilidad de explotar información histórica respecto a las soluciones encontradas por el algoritmo en generaciones previas. Es decir, no solo se realiza un intercambio de información entre individuos de una misma generación, sino que también participan los mejores individuos de generaciones previas, de aquí su nombre. A continuación se muestra el resultado con y sin elitismo utilizando los parámetros obtenidos en intentos anteriores.

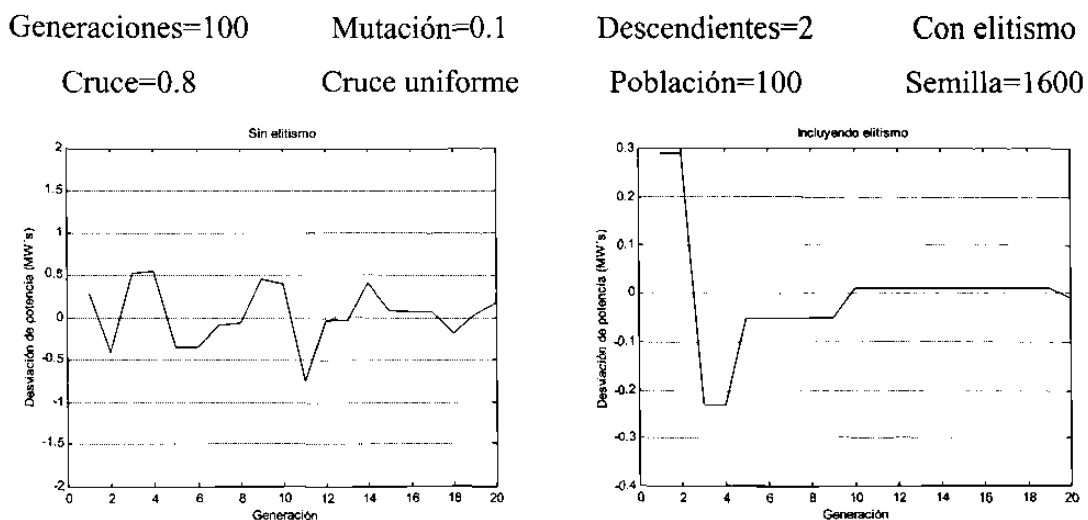


Figura 7.7 Efecto del elitismo.

Como es evidente el incluir elitismo mejora por mucho el comportamiento del algoritmo para la solución del problema planteado. En general para cualquier problema que se pretenda resolver utilizando la técnica de algoritmos genéticos se podría esperar lo mismo, ya que el efecto del elitismo es una de las fortalezas de esta técnica.

Si se observan los resultados obtenidos para el problema planteado desde el inicio del análisis, se verá que el comportamiento del algoritmo es similar en el transcurso de las primeras diez y veinte generaciones, y después de las cuales se comporta de manera

distinta, empeorando en la mayoría de los casos con el transcurso de las generaciones. La razón de este comportamiento se debe a que precisamente el algoritmo no incluye elitismo, es decir, no toma en cuenta los resultados obtenidos en generaciones previas sino que prácticamente se podría decir que se “resetea” en cada nueva generación buscando soluciones en otra “sección” del espacio de solución. A partir de que se incluye elitismo, se observa que prácticamente en las primeras diez generaciones se alcanza convergencia y se mantiene el mismo resultado para las siguientes generaciones, lo cual quiere decir que de todas las soluciones encontradas en el transcurso de las siguientes generaciones, ninguna de estas es mejor a la ya obtenida en la generación veintitrés, de acuerdo a la Figura 7.7 la cual representa la solución más cercana al óptimo. La Tabla 7.5 se muestra el resultado de generación obtenido para esa generación.

Tabla 7.5 Solución encontrada en la generación veintitrés.

Generación 23	Potencia	Costo	Lambda	Pérdidas
Generador 1	52.2	836.745	12.2	
Generador 2	90.4	1206.753	11.9	
Generador 3	74.1	1083.412	11.9	
Totales	216.7	3127.2		6.7

En la Figura 7.7 donde se incluye elitismo, se puede observar que en la generación diez aparentemente se alcanza convergencia, sin embargo el costo para esta solución es mayor que para la encontrada en la generación veintitrés, lo cual se presenta en detalle en la Tabla 7.6.

Tabla 7.6 Solución encontrada en la generación diez.

Generación 10	Potencia	Costo	Lambda	Pérdidas
Generador 1	62.2	959.532	12.3	
Generador 2	40.1	628.648	11.0	
Generador 3	114.6	1578.778	12.5	
Totales	216.9	3168.1		7.0

7.2.7 Efecto de la semilla aleatoria.

En las gráficas de resultados mostradas anteriormente se puede observar que para todos los casos, independientemente del parámetro que se este analizando, el algoritmo inicia de la misma manera o lo que es lo mismo, se inicia explorando el mismo punto del espacio de solución. En otras palabras, el algoritmo crea los mismos individuos para la primera generación en todos los casos. Este comportamiento se debe al valor de la semilla aleatoria que se está utilizando para inicializar el algoritmo, que para todos los casos es la misma. Otro punto a observar para este caso es que con ese valor de semilla aleatoria se inicia muy cerca de la solución óptima buscada. La Figura 7.8 muestra dos casos en los que se utilizó un valor de semilla aleatoria distinto al propuesto anteriormente, cuyos resultados se detallan en las Tablas 7.7 y 7.8.

Generaciones=100

Mutación=0.1

Descendientes=2

Con elitismo

Cruce=0.8

Cruce uniforme

Población=100


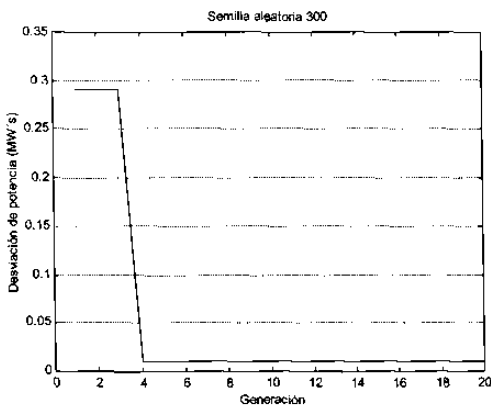


Figura 7.8 Efecto de la semilla aleatoria.

Tabla 7.7 Solución para semilla aleatoria 1000.

Semilla 1000	Potencia	Costo	Lambda	Pérdidas	Desv. de Pot.
Generador 1	56.8	893.095	12.3		
Generador 2	83.4	1123.607	11.8		
Generador 3	76.4	1110.893	12.0		
Totales	216.6	3128.0		6.7	0.1

Tabla 7.8 Solución para semilla aleatoria 300.

Semilla 300	Potencia	Costo	Lambda	Pérdidas	Desv. de Pot.
Generador 1	50.3	813.536	12.2		
Generador 2	66.1	921.853	11.5		
Generador 3	100.3	1401.095	12.3		
Totales	216.7	3136.8		6.8	0.1

Debe notarse en la Figura 7.8 la diferencia en el patrón de convergencia para ambos casos.

7.2.8 Efecto del número de generaciones.

El número de generaciones, establece el tiempo de búsqueda en el espacio de solución para el problema propuesto, es decir, el número de iteraciones que completa el algoritmo en la búsqueda de la solución. Para el problema estudiado en este análisis, se observa que no es necesario realizar cien generaciones para encontrar la solución, en otros casos, sin embargo, podrá requerir un número mayor. Para minimizar el número de generaciones se recomienda utilizar criterios de convergencia adecuados al problema en cuestión.

7.3 Solución al problema de despacho económico codificando potencia de generación.

En el análisis de la sección anterior se utilizó codificación de costos incrementales individuales obteniendo. En esta sección se presentarán resultados obtenidos para el mismo problema, solo que para este caso se utilizará codificación de potencia de generación por máquina, es decir, esquemas de generación. Cabe mencionar que los mejores parámetros básicos que se utilizaron para este caso son los obtenidos del análisis paramétrico. Los resultados obtenidos se muestran en la Figura 7.9 y Tabla 7.9:




Figura 7.9 Proceso de convergencia codificando potencia.

Tabla 7.9 Solución codificando potencia.

	Potencia	Costo	Lambda	Pérdidas	Desv. de Pot.
Generador 1	56.4	888.186	12.3		
Generador 2	91.3	1217.507	11.9		
Generador 3	69.1	1023.941	11.7		
Totales	216.8	3129.2		6.7	0.02

En la Tabla 7.9 se observa una solución distinta a la de la Tabla 7.8 del punto anterior, donde se utilizó codificación de costos incrementales individuales, sin embargo muy parecida en cuanto a costo total de generación; lo cual nos indica que el problema

de despacho económico es un problema con espacio de solución multimodal. La versatilidad del algoritmo genético para encontrar la solución de un problema en todo el espacio de soluciones es una característica de mucha utilizada en situaciones donde los algoritmos de optimización tradicionales presentan problemas de convergencia.

7.4 Resultados para otras funciones de evaluación.

La Tabla 7.10 y la Figura 7.10 muestran los resultados de Despacho Económico obtenidos para el sistema de la Figura 7.1 con los parámetros básicos mencionados y utilizando la función de evaluación (7.2) codificando potencia de generación.

$$Fit = sf_1(1 - \%lerr_\lambda)^{sp_1} + sf_2(1 - \%lerr_p)^{sp_2} \quad (0.2)$$

Donde:

$$sp_1 = sp_2 = 3$$

$$sf_1 = sf_2 = 1$$

Tabla 7.10 Solución utilizando la función de evaluación 7.2.

	Potencia	Costo	Lambda	Pérdidas	Desv. de Pot.
Generador 1	50.9	820.6	12.2		
Generador 2	87.8	1175.7	11.8		
Generador 3	78.0	1130.1	11.9		
Totales	216.7	3126.4		6.7	0




Figura 7.10 Proceso de convergencia utilizando la función de evaluación 7.2.

Para el caso de esta función, la minimización de costo se realiza a través de su primer término, que engloba la condición de optimalidad para el problema de Despacho Económico, que dice que cuando se tienen costos incrementales iguales en todas las máquinas, se está operando el sistema al mínimo costo.

La Tabla y la Figura 7.11 se presentan resultados cuando se codifica el costo incremental del sistema de prueba y utilizando la función de evaluación (7.3).

$$Fit = \frac{1}{\left(1 - \left(\frac{DP}{P_d}\right)\right)} \quad (0.3)$$

Tabla 7.11 Solución utilizando la función de evaluación 7.3.

	Potencia	Costo	Lambda	Pérdidas	Desv. de Pot.
Generador 1	50	809.875	12.2		
Generador 2	91.1	1215.1	12.0		
Generador 3	75.6	1101.3	12.0		
Totales	216.6	3126.1		6.7	0.03




Figura 7.11 Proceso de convergencia utilizando la función de evaluación 7.3.

Para este caso, se mejora la convergencia con respecto al caso anterior y al igual que en este último, la minimización de costo se realiza automáticamente al buscar un solo valor de costo incremental en el que se satisfagan las restricciones del problema.

Cabe mencionar que la función de evaluación utilizada en este punto únicamente funciona cuando se codifica costo incremental, ya sea el del sistema o el de cada generador.

Los resultados obtenidos hasta este momento demuestran que es indistinto el utilizar codificación de potencia de generación o costo incremental individual o del sistema, sin embargo, en el caso general, el tipo de problema a resolver determina el tipo de codificación a utilizar. En lo que respecta a las funciones de evaluación, todas satisfacen los requerimientos del problema resuelto. Los métodos de codificación requieren ciertas modificaciones, sobre todo en lo que se refiere a factores de prioridad y de penalización para alcanzar el objetivo buscado cuando se resuelven problemas complejos, para el caso del Despacho Económico un gran número de generadores y un sistema de transmisión complicado. La sección 7.7 de este capítulo presenta resultados para problemas de este tipo.

7.5 Solución al problema de Despacho Económico con restricción en líneas de transmisión.

En este apartado se presentan resultados para el problema de Despacho Económico del sistema de la Figura 7.1 considerando pérdidas y restricciones en líneas de transmisión, codificando costo incremental de cada máquina y utilizando la siguiente función de evaluación:

$$Fit = sf_1 \left(\frac{1}{1 - 0.1 \left(\frac{DP}{factor} \right)} \right)^{sp_1} + sf_2 \left(\frac{c_{max} - c_{ind}}{c_{max}} \right)^{sp_2} + sf_3 (1 - Diflu)^{sp_3} \quad (0.4)$$

Por cada línea de transmisión que se restrinja en el problema se deberá incluir en la función de evaluación un término adicional similar al mostrado en la parte final de la función (0.4).

Las restricciones de flujo de potencia activa que se imponen al sistema de transmisión se muestran en la Tabla 7.12.

Tabla 7.12 Líneas restringidas, flujo de potencia del Caso Base y Máximo Permitido en megawatts.

Línea	Flujo Caso Base (MW)	Flujo Máximo (MW)
L35	25.3	20.0
L37	49.3	40.0

Los valores que se presentan en la Tabla 7.12 como flujo normal por las líneas indicadas, se obtuvieron de la solución al problema de despacho económico para el caso base que considera pérdidas en la red de transmisión, utilizando la función de evaluación (0.1) y codificando costos incrementales individuales. La Tabla 7.3 muestra los resultados obtenidos en este caso.

Tabla 7.13 Solución con restricción en líneas.

	Potencia	Costo	Lambda	Pérdidas	Desv. de Pot.
Generador 1	58.5	913.977	12.3		
Generador 2	107.0	1407.400	12.1		
Generador 3	51.4	817.393	11.3		
Totales	217.9	3137.4		7.9	0.1





Figura 7.12 Proceso de convergencia para el caso con restricción en líneas.

Tabla 7.14 Solución obtenida utilizando PSS/OPF.

	Potencia	Costo	Lambda	Pérdidas	Desv. de Pot.
Generador 1	57.17	897.54	12.27		
Generador 2	108.92	1430.97	12.27		
Generador 3	50.83	809.84	11.58		
Totales	217.9	3138.33		7.9	0.0

Los resultados para este caso muestran un incremento en el costo total de generación a causa de la restricción impuesta, y aunque no se presentan resultados de flujos para ambas soluciones (AG's y PSS/OPF) la restricción de flujo en líneas se satisface al cien por ciento. Se obtiene una muy buena aproximación de la solución con algoritmos genéticos respecto a la de PSS/OPF.

7.6 Solución al problema de Despacho Económico considerando punto de válvula en las curvas de costo.

Para este caso en particular se utilizó un sistema de prueba distinto [2], que al igual que el de la Figura 7.1, consta de tres generadores, sin embargo no se considera la red de transmisión. Los valores de las constantes de la curva de costo de cada generador así como sus límites de generación se presentan en las Tablas 7.15 y 7.16.

Tabla 7.15 Datos de curva de costo para generadores.

	Generador 1	Generador 2	Generador 3
a	0.00157	0.00194	0.00482
b	7.92	7.85	7.97
c	571.0	310.0	78.0
e	300.0	200.0	150.0
f	0.0315	0.042	0.073

Tabla 7.16 Límites de generación.

	P _{min}	P _{máx}
Generador 1	100.0	700.0
Generador 2	100.0	400.0
Generador 3	50.0	200.0

La solución de este problema de Despacho Económico Clásico al considerar el efecto del punto de válvula es muy difícil de encontrar utilizando las funciones de evaluación presentadas en el Capítulo 4. Por tal motivo se recurrió a una nueva función de evaluación (7.5) Dicha función evalúa todos los individuos en la población y los compara entre si asignando un valor de fitness alto a aquellos que representan un menor costo ($Costo_{rel}$) y satisfacen mejor la restricción de potencia (DP_{rel}) en relación a los valores máximos y mínimos de la variable correspondiente existentes en la población.

$$Fit = (2 - Costo_{rel}^{|a|}) e^{-|c| \frac{DP_{rel}}{|b|}} \quad \text{para: } 0 \leq DP_{rel} \leq 1.0 \quad (0.5)$$

$$Fit = (2 - Costo_{rel}^{|a|}) e^{|c| \frac{DP_{rel}}{|b|}} \quad \text{para: } -1.0 \leq DP_{rel} \leq 0$$

$$Costo_{rel} = \frac{Costo_i - Costo_{min}}{Costo_{max} - Costo_{min}} \quad (0.6)$$

$$DP_{rel} = \frac{DP_i - DP_{min}}{DP_{max} - DP_{min}} \quad \text{para: } DP_i \geq 0 \quad (0.7)$$

$$DP_{rel} = -\frac{DP_i - DP_{min}}{DP_{max} - DP_{min}} \quad \text{para: } DP_i \leq 0$$

$$a = b = 0.5, c = 5.0$$

$Costo_i$ = costo del individuo evaluado.

DP_i = desviación de potencia del individuo evaluado.

Cabe mencionar que el término exponencial funciona de manera similar a los factores sp utilizados en funciones previas, atenuando la pendiente entre puntos del espacio de solución, lo cual mejora el proceso de convergencia para problemas complicados. La condición de la función a utilizar, dependiendo del valor de DP_{rel} se hace con la intención de que el valor del exponente siempre sea negativo. Los resultados para este caso se presentan en la Figura 7.13 y Tabla 7.17.




Figura 7.13 Proceso de convergencia considerando puntos de válvula en las curvas de costo de los generadores.

Tabla 7.17 Solución considerando puntos de válvula en las curvas de costo de los generadores.

	Potencia	Costo	Lambda	Pérdidas	Desv. de Pot.
Generador 1	301.4	3108.4	18.3		
Generador 2	399.0	3752.7	17.8		
Generador 3	149.7	1379.4	18.9		
Totales	850.0	8240.4		0.0	0.0

El problema de despacho económico considerando puntos de válvula en la curva de costo de los generadores es sin duda un problema difícil en el que se presenta claramente la característica multimodal del espacio de solución del problema. Encontrar la solución a este problema mediante Algoritmos Genéticos requiere un cambio en los parámetros básicos del algoritmo respecto a los usados para los casos presentados anteriormente. A continuación se muestran los parámetros utilizados para este caso particular.

Generaciones=1000

Cruce=0.7

Mutación=0.05

Cruce uniforme

Descendientes=2

Población=900

Con elitismo

Semilla=88

En la Figura 7.13 donde se muestra el proceso de convergencia, se observa como a pesar del tamaño de la población, se mantienen la misma solución durante un número de generaciones considerable. Esto indica lo difícil que resulta para el algoritmo encontrar soluciones con buenas características en el espacio de solución propuesto [1].

7.7 Sistemas de gran escala.

En este apartado se presenta la solución al problema de Despacho Económico con pérdidas y restricción en líneas para el sistema Noroeste de Comisión Federal de Electricidad (CFE). Para este caso se consideran 17 máquinas térmicas y una red de transmisión de 209 nodos y 298 líneas de esta porción del Sistema Eléctrico Mexicano. La complejidad de encontrar la solución para sistemas de este tipo, mediante la técnica de algoritmos genéticos, radica principalmente en el número de máquinas a despachar ya que entran en juego un mayor número de variables a “cuadrar”, es decir, respecto a las restricciones propias del problema.

Los resultados obtenidos se muestran en las figuras 7.14 y 7.15, y las Tablas 7.19 y Tabla 7.22. La Tabla 7.18 presenta los datos de las curvas de costo para el sistema de la CFE. Por comparación las Tablas 7.20 y 7.23 presentan los resultados del problema mediante un algoritmo de optimización convencional utilizado por el programa PSS/OPF [12]. Debe notarse la similitud de resultados.




Figura 7.14 Proceso de convergencia para el sistema eléctrico de la CFE.

Tabla 7.18. Datos de curvas de costo para generadores del sistema noroeste de CFE.

	a	b	c
Generador 1	0.24136	100.518	5798.5
Generador 2	0.06578	143.571	2845.9
Generador 3	0.14405	126.074	3094.8
Generador 4	0.06678	144.571	2845.9
Generador 5	0.14505	127.074	3094.8
Generador 6	0.16585	231.394	265.36
Generador 7	0.27071	166.627	1955.1
Generador 8	0.00937	178.139	225.26
Generador 9	0.06993	142.356	1903.9
Generador 10	0.05283	148.399	1432.7
Generador 11	0.02971	171.456	741.67
Generador 12	0.15963	136.113	1596.29
Generador 13	0.27071	166.627	1955.1
Generador 14	0.15963	136.113	1596.29
Generador 15	0.05283	148.399	1432.7
Generador 16	0.02971	171.456	741.67
Generador 17	0.00937	178.139	225.26

Tabla 7.19 Solución de Despacho Económico para el Sistema Noroeste de CFE mediante Algoritmos Genéticos.

	Potencia	Costo	Pérdidas	Desv. de Pot.
Generador 1	140	24602		
Generador 2	145	25047		
Generador 3	145	24404		
Generador 4	145	25213		
Generador 5	145	24570		
Generador 6	11	2831		
Generador 7	51.26	11208		

Generador 8	300	54510		
Generador 9	145	24016		
Generador 10	145	24061		
Generador 11	150	27129		
Generador 12	219.14	39090		
Generador 13	56.82	12297		
Generador 14	189.56	33134		
Generador 15	22	4723		
Generador 16	150	27129		
Generador 17	80	14536		
Totales	2239.78	398499.2	47.0	0

Tabla 7.20 Solución de despacho económico para el Sistema Noroeste de CFE con PSS/OPF.

	Potencia	Costo	Pérdidas	Desv. de Pot.
Generador 1	140	24602		
Generador 2	145	25047		
Generador 3	145	24404		
Generador 4	145	25213		
Generador 5	145	24570		
Generador 6	11	2831		
Generador 7	51.33	11221		
Generador 8	300	54510		
Generador 9	145	24016		
Generador 10	145	24061		
Generador 11	150	27129		
Generador 12	219.14	39090		
Generador 13	56.82	12297		
Generador 14	189.56	33134		

Generador 15	22	4723		
Generador 16	150	27129		
Generador 17	80	14536		
Totales	2239.86	398513.56	47	0

Para el caso de restricción en líneas de transmisión se restringió el enlace norte-sur del sistema Noroeste que corresponde a las líneas PNO-230 a LMD-230 de doble circuito. En la Tabla 7.21 se muestra la magnitud del flujo por el enlace para el caso de despacho económico con pérdidas visto arriba y el flujo al que se limita el enlace para el caso que se presenta a continuación.

Tabla 7.21 Flujo normal y límite para el enlace norte-sur del sistema Noroeste.

Línea/Flujo	PNO-203 a LMD-230 1	PNO-203 a LMD-230 2
Flujo normal (MW's)	16.2	15.6
Flujo límite (MW's)	10	10

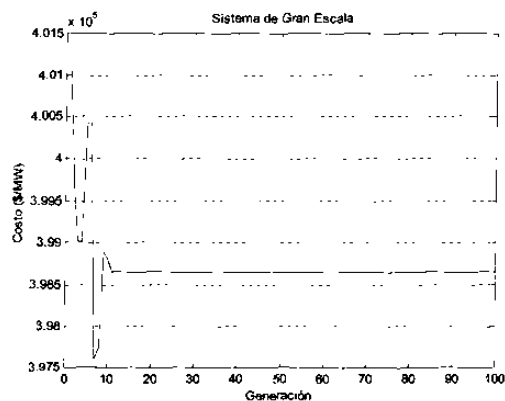
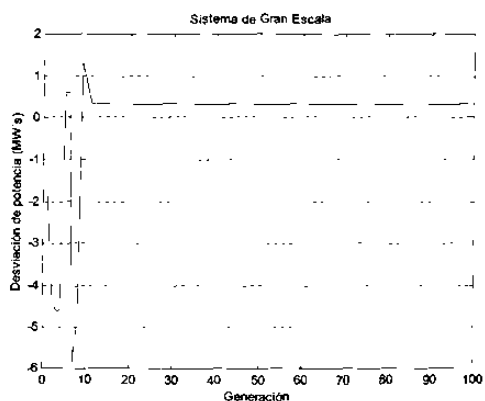


Figura 7.15 Proceso de convergencia para el sistema eléctrico de la CFE con restricción en líneas.

Como es evidente Algoritmos Genéticos brinda una muy buena aproximación de la solución del problema con respecto a PSS/OPF.

Tabla 7.22 Solución de Despacho Económico con restricción en líneas para el sistema Noroeste de CFE mediante Algoritmos Genéticos.

	Potencia	Costo	Pérdidas	Desv. de Pot.
Generador 1	140	24602		
Generador 2	145	25047		
Generador 3	145	24404		
Generador 4	145	25213		
Generador 5	145	24570		
Generador 6	11	2831		
Generador 7	52.53	11455		
Generador 8	300	54510		
Generador 9	145	24016		
Generador 10	145	24061		
Generador 11	150	27129		
Generador 12	231.45	41651		
Generador 13	43.03	9626		
Generador 14	189.61	33144		
Generador 15	22	4723		
Generador 16	150	27129		
Generador 17	80	14536		
Totales	2239.62	398646	46.6	0

Tabla 7.23 Solución de Despacho Económico con restricción en líneas para el sistema Noroeste de CFE mediante PSS/OPF.

	Potencia	Costo	Pérdidas	Desv. de Pot.
Generador 1	140	24602		
Generador 2	145	25047		
Generador 3	145	24404		
Generador 4	145	25213		
Generador 5	145	24570		

Generador 6	11	2831		
Generador 7	47.62	10504		
Generador 8	300	54510		
Generador 9	145	24016		
Generador 10	145	24061		
Generador 11	150	27129		
Generador 12	231.45	41651		
Generador 13	53.42	11629		
Generador 14	183.82	32010		
Generador 15	22	4723		
Generador 16	150	27129		
Generador 17	80	14536		
Totales	2239.31	398564	46.5	0

Cabe mencionar que la restricción de líneas se satisface al cien por ciento utilizando Algoritmos Genéticos al igual que con PSS/OPF.

CAPITULO 8

CONCLUSIONES

De la aplicación de los Algoritmos Genéticos al problema de Despacho Económico se derivan las siguientes conclusiones:

- Los Algoritmos genéticos representan una buena opción para la solución de problemas de optimización, sobre todo aquellos con espacios de solución multimodal donde los métodos tradicionales de solución, que utilizan reglas de transición determinísticas, corren riesgo de quedarse atorados en mínimos locales.
- La implementación y aplicación digital de los algoritmos genéticos es mucho más sencilla con respecto a métodos tradicionales al estar condicionada únicamente por la función de evaluación.

- El problema de despacho económico presenta un espacio de solución multimodal con un grado de complejidad mayor cuanto mayor sea el número de máquinas a despachar y las restricciones que se consideren.
- La linealización de las curvas de costo de los generadores permite obtener una solución aproximada al problema de Despacho Económico. El considerar puntos de válvula en las curvas de costo de los generadores conduce a soluciones más reales. La consideración de este tipo de efecto es posible en algoritmos genéticos por su capacidad de manejar no linealidades comúnmente encontradas en sistemas reales.
- En la solución de un problema de optimización utilizando algoritmos genéticos es fundamental la representación o codificación de las posibles soluciones. Si se falla en este punto, se estaría perdiendo de vista por completo el problema a resolver. Es conveniente además considerar la optimización del recurso computacional al momento de elegir el método de codificación a utilizar. Otro aspecto clave es la función de evaluación, la cual guía la búsqueda de la solución basada en los parámetros o variables del problema a resolver.
- Las funciones de evaluación estructuradas como sumatorias, donde se define un sumando para cada variable del problema y asignando distintos pesos a cada uno de ellos, muestran buenos resultados y facilitan el proceso de sintonización del algoritmo para el problema en cuestión. Además, si cada variable del problema se mide con respecto así misma tomando en cuenta el mejor y el peor resultado obtenido en cada generación de forma tal que el índice de la variable sea realmente un ponderado, mejora la calidad de la solución y el proceso de convergencia. Cabe mencionar que para este caso el comportamiento de fitness de los mejores individuos generación a generación, no tendrá un patrón definido a causa del cambio de referencia en cada generación, sin embargo esto no afecta el funcionamiento del algoritmo.

- A diferencia de los métodos tradicionales de solución en los que existe la posibilidad o incertidumbre de que se queden atorados en mínimos locales del espacio de solución, el algoritmo genético asegura siempre encontrar una solución si no es que la óptima si una muy aproximada, en el entendido de que esto dependerá del buen condicionamiento de sus parámetros básicos y demás variables que intervienen en el.
- Del análisis de los fundamentos matemáticos de los algoritmos genéticos se concluye que es la simplicidad de dichos fundamentos y su sencilla implementación computacional lo que hace a la técnica de algoritmos genéticos ser considerada como una buena opción para la solución de problemas de optimización.
- Respecto al análisis paramétrico se concluye que el éxito en la aplicación de los algoritmos genéticos requiere un conocimiento sólido del efecto de sus parámetros básicos.
- En algoritmos genéticos la experiencia a probado que una alta probabilidad de cruce y una baja probabilidad de mutación por lo general ofrecen buenos resultados. El tamaño de la población impacta la calidad de las soluciones y el tiempo de procesamiento involucrado. El valor de la semilla en el proceso aleatorio determina la diversidad de puntos de búsqueda en el espacio de solución.
- Los algoritmos genéticos representan una opción viable al problema de despacho económico en la búsqueda de mínimos globales.

APORTACIONES.

1. Se evaluó con éxito la aplicación de la técnica de Algoritmos Genéticos en problemas asociados a Sistemas Eléctricos de Potencia.
2. Se desarrollo una herramienta flexible y eficiente como solución alterna al problema de Despacho Económico utilizando Algoritmos Genéticos.
3. La herramienta desarrollada muestra características superiores en el modelado de las características de entrada salida de los generadores y en el proceso de búsqueda de la solución. En consecuencia, las soluciones encontradas representan valores más cercanos a la realidad, generalmente de menor costo en el caso del problema de Despacho Económico.
4. Se demostró la aplicación del Algoritmo Genético al problema de Despacho Económico en varios sistemas de prueba y en un sistema de gran escala real representando una parte de la red Eléctrica Nacional.
5. Se analiza a detalle el comportamiento de los Algoritmos Genéticos y se identifican los efectos más relevantes de los parámetros básicos, métodos de codificación y de la función de evaluación.

REFERENCIAS.

1. D. C. Walter and G. B. Sheble, "Genetic algorithm solution of economic dispatch with valve point loading". IEEE Transactions on Power Systems, 8(3): 1325-1332, August 1993.
2. J. Wood and B. F. Wollenberg. Power Generation, Operation and Control, John Wiley and Sons, New York, 1983.
3. E. Goldberg, Genetic Algorithm in Search Optimization and Machine Learning, Reading, M.A.: Addison-Wesley Publishing Company Inc., 1989
4. David L. Carrol, Genetic Algorithm (GA) driver V.1.7, University of Illinois.
5. P. J. Fleming and C. M. Fonseca, "Genetic algorithm in control system engineering", Research Report No. 470, Dept. of Automatic Control and Systems Engineering, University of Sheffield, Sheffield, U. K. March 1993.
6. J. J. Grefenstette, "Optimization of control parameters of genetic algorithm", IEEE Transactions on System, Man and Cybernetics, Vol. SCM-16 No. 1 January/February 1986, p. p. 122-128.
7. L. Davis, Hamkbook of Genetic Algorithms, New York, Van Nostrand Reimhold, 1991.
8. Bakirtzis, V. Petridis, and S. Kazarlis, "A Genetic algorithm solution to the economic dispatch problem". IEEE Proceedings Generation, Transmission and Distribution, 414(4): 377-382, July 1994.

- 9. Gerald B. Sheble and Kristin Britting, “Refined genetic algorithm-economic dispatch example”. IEEE Transactions on Power Systems, Vol. 10, No. 1, February 1995.**

- 10. Po-Hung Chen and Hogn Chan Chang, “Large-scale economic dispatch by genetic algorithm”. IEEE Transactions on Power Systems, Vol. 10, No. 4, November 1995.**

- 11. J. Toyoda, M. S. Chen, “A new approach to unit commitment study and the conception of an equivalent generator”, Power System Research Center at the University of Texas at Arlington, 1970.**

- 12. PSS/E Versión 29.0 Copyright (c) 1976-2003. Power Technologies, Inc.**

