

**Universidad de Cienfuegos**  
**“Carlos Rafael Rodríguez”**

**Facultad de Ingeniería Informática**

**Trabajo de Diploma**

**Diseño de algoritmo genético para la estimación de  
parámetros operacionales utilizados en la medición de la  
eficiencia energética de motores asíncronos**

Autor: Dayron Arano Fernández

Tutores: Dr. C. Julio Gómez Sarduy

Ing. Lissette Montero Herrera

Consultante: Ing. Yunior A. Hernández Andrade

Cienfuegos, 2010

“Año del Aniversario 51 de la Revolución”

## Declaración de Autoría

Yo, Dayron Arano Fernández declaro que soy el único autor del trabajo de diploma titulado “**Diseño de algoritmo genético para la estimación de parámetros operacionales utilizados en la medición de la eficiencia energética de motores asincrónicos**”, y autorizo al departamento de Informática de la facultad de Informática de la Universidad de Cienfuegos “Carlos Rafael Rodríguez”, para que haga el uso que estime pertinente con el mismo.

Para que así conste firmo la presente a los 24 días del mes de Junio del 2009.

---

**Firma del autor**

Dayron Arano Fernández

Los abajo firmantes certificamos que el presente trabajo ha sido revisado según acuerdo de la dirección de nuestro centro y el mismo cumple los requisitos que debe tener un trabajo de esta envergadura.

---

**Firma del tutor**

Dr. C. Julio Gómez Sarduy

---

**Firma del tutor**

Ing. Lissette Montero Herrera

# *Dedicatoria*

*A mis seres queridos que hoy no están a mi lado*

*A mis padres y a mi hermana.*

# Agradecimientos

*A mis abuelos por todo el cariño y apoyo recibido desde pequeño, que desde donde estén siempre sabrán guiarme.*

*A mis padres por traerme al mundo, porque por ellos soy quien soy hoy, porque con sus consejos he sabido llegar hasta aquí.*

*A mi hermana, que con su carácter muy de ella y esté lejos hoy, se que me quiere mucho y yo a ella más.*

*A Tita y a Miguel por cada cariño dado, que siempre será correspondido.*

*A mi enorme familia, que si me pongo a mencionarlos no acabaría ni después del Mundial.*

*A Sahyli por cada paso que ha dado a mi lado, por cada momento, por cada lágrima, por cada sonrisa y por ser tan especial y tolerante la quiero y ella me quiere.*

*A mis amigos que han sabido resistirme y me han acompañado en cada momento, en especial a Edua, Carli, Whillo, Yoana y a todos lo que se me quedan discúlpenme, los llevo en el pensamiento.*

*A Yunion por todas las horas de ayuda que me dedicó.*

*A mis compañeros del aula, a esa gran familia que hemos formado durante 5 años, por los momentos compartidos.*

*A mis tutores Julio y Lissette, por aclararme cada duda y saber compartir sus conocimientos conmigo.*

*A mis profes por enseñarme lo que me serviría y lo que no para un futuro.*

*A Roy que sin su ayuda el AG no hubiera caminado.*

*A mi suegra por todo el apoyo y confianza que ha depositado en mi y su Luisito por todos los sabios consejos que me ha dado.*

*A mis cuñados por los buenos momentos compartidos juntos y por los malos.*

*Al piquete de los sábados por compartir conmigo cada minuto del DOTA.*

*A 22 y KK, por todo el cariño desprendido hacia mí, las siento como abuelas.*

*A todo aquel a quién considero imprescindible en mi vida cotidiana y de una forma u otra ayudó, criticó y se preocupó por este trabajo.*

*A Dios, por ponerme en el camino que me ha puesto, y ha hecho posible casi todos mis sueños.*

*“Gracias”*

## Resumen

Los métodos estocásticos realizan una búsqueda aleatoria del espacio. Muchos de estos métodos han dado como resultado una serie de procedimientos computacionales heurísticos capaces de resolver problemas con alto grado combinatorio y de encontrar buenas soluciones, muy próximas al óptimo global. Los Algoritmos Genéticos, pertenecientes al grupo de los métodos estocásticos, están caracterizados por el paralelismo intrínseco de su arquitectura, ellos realizan la búsqueda de forma simultánea con varias soluciones o individuos, en vez de trabajar de forma secuencial como las técnicas tradicionales. Además, no necesitan conocimientos específicos sobre el problema que intentan resolver. En las últimas dos décadas estos algoritmos han sido muy empleados en la estimación de los parámetros operacionales de los motores eléctricos de la industria, para la estimación de su eficiencia en condiciones de campo. El Centro de Estudio de Energía y Medio Ambiente (CEEMA), de la Universidad de Cienfuegos, propuso un método para la estimación de los motores eléctricos; el núcleo de este método es un AG que estima los parámetros operacionales, para lo cual utiliza el software MATLAB. El objetivo del presente trabajo fue mejorar los estimados obtenidos por el método del CEEMA. Para ello, se definieron cinco nuevos diseños de AGs, a partir de variaciones de los operadores genéticos y sus probabilidades. El resultado final, basado en una comparación estadística, fue la selección del AG que realizó estimaciones más cercanas a valores medidos experimentalmente en laboratorio, y la implementación del mismo en lenguaje de programación C#.

## [ÍNDICE GENERAL] I

---

<i>Introducción.</i>	1
<i>Capítulo 1: Estudio de los Algoritmos Genéticos.</i>	6
1.1 Introducción.	6
1.2 Los Algoritmos Genéticos en la resolución de problemas de búsqueda.	6
1.3 Esquema de funcionamiento del Algoritmo Genético Simple.	9
1.4 Codificación de la solución.	12
1.5 Población.	13
1.5.1 Población inicial.	13
1.5.2 Tamaño de la población.	14
1.6 Función de adaptabilidad.	14
1.7 Funcionamiento de los operadores genéticos.	16
1.8 Parámetros probabilísticos, reemplazo de la población y condición de parada.	21
1.9 Convergencia de los Algoritmos Genéticos.	22
1.10 ¿Cómo saber si es posible usar el Algoritmo Genético?	24
1.11 Diferencia entre los Algoritmos Genéticos y otros métodos tradicionales de búsqueda.	24
1.12 Aplicaciones de los Algoritmos Genéticos.	25
1.13 Conclusiones.	27
<i>Capítulo 2: Los Algoritmos Genéticos en la estimación de la eficiencia energética de los motores eléctricos.</i>	28
2.1 Introducción.	28
2.2 Aplicación de Algoritmos Genéticos a problemas de optimización de la eficiencia de los motores eléctricos.	28
2.3 Determinación de la eficiencia de los motores asíncronos en condiciones de campo, según método del CEEMA.	30
2.4 Elementos considerados para otros diseños de Algoritmos Genéticos a compararse con el propuesto por el CEEMA.	34
2.4.1 Diseño del cromosoma.	34
2.4.2 Población.	35
2.4.3 Función de aptitud empleada.	39
2.4.4 Operadores genéticos.	42
2.5 Herramientas utilizadas.	43
2.6 Conclusiones.	43

## [ÍNDICE GENERAL] II

---

<i>Capítulo 3: Análisis de los resultados.</i>	45
3.1 Introducción.	45
3.2 Propuestas de diseños.	45
3.3 Comparación de los resultados arrojados por los diseños propuestos.	46
3.4 Comparación entre los resultados arrojados por el Diseño 2 y el Diseño 0.	51
3.4.1 Comparación entre las diferencias de las potencias de salida.	52
3.4.2 Comparación entre las diferencias de la eficiencia.	53
3.4.3 Comparación entre los errores.	54
3.4.4 Comparación de los estadísticos descriptivos de las muestras.	56
3.4.5 Comparación de los tiempos.	57
3.4.6 Comparación del número de Generaciones.	58
3.5 Fundamentación del diseño seleccionado e implementación.	59
3.6 Conclusiones	61
<i>Conclusiones.</i>	62
<i>Recomendaciones.</i>	63
<i>Referencias Bibliográficas.</i>	64
<i>Bibliografía</i>	67
<i>Anexos:</i>	68

## [ÍNDICE DE TABLAS] III

---

<i>Tabla 1: Operadores y parámetros probabilísticos de los diseños propuestos.</i>	46
<i>Tabla 2: Medias de la eficiencia y de la potencia de salida estimadas y del error del Diseño 1.</i>	47
<i>Tabla 3: Medias de la eficiencia y de la potencia de salida estimadas y del error del Diseño 2.</i>	47
<i>Tabla 4: Medias de la eficiencia y de la potencia de salida estimadas y del error del Diseño 3.</i>	48
<i>Tabla 5: Medias de la eficiencia y de la potencia de salida estimadas y del error del Diseño 4.</i>	48
<i>Tabla 6: Medias de la eficiencia y de la potencia de salida estimadas y del error del Diseño 5.</i>	49
<i>Tabla 7: Diferencias entre las estimaciones del Diseño 0 y los datos experimentales.</i>	51
<i>Tabla 8: Diferencias entre las estimaciones del Diseño 2 y los datos experimentales.</i>	52
<i>Tabla 9: Estadísticos descriptivos de muestras, con tamaño 8, analizadas.</i>	56

## [ÍNDICE DE FIGURAS] IV

---

<i>Figura 1: Representación de la estimación de los parámetros del motor a partir de un modelo.</i>	31
<i>Figura 2: Resultados del Diseño 0 con población de 16 individuos.</i>	37
<i>Figura 3: Resultados del Diseño 0 con población de 30 individuos.</i>	37
<i>Figura 4: Resultados del Diseño 0 con población de 50 individuos.</i>	38
<i>Figura 5: Resultados del Diseño 0 con población de 80 individuos.</i>	38
<i>Figura 6: Resultados del Diseño 0 con población de 100 individuos.</i>	39
<i>Figura 7: Gráfica comparativa entre las diferencias de eficiencias, estimada y experimental, de los diseños.</i>	49
<i>Figura 8: Gráfica comparativa entre las diferencias de potencias de salida, estimada y experimental, de los diseños.</i>	50
<i>Figura 9: Gráfica comparativa entre los errores de los diseños (aproximados a dos lugares después de la coma).</i>	50
<i>Figura 10: Comparación gráfica de las medias de cada muestra.</i>	56
<i>Figura 11: Comparación gráfica de las desviaciones estándar de las muestras.</i>	57
<i>Figura 12: Comparación grafica del tiempo para diferentes estados del motor en ambos diseños.</i>	58
<i>Figura 13: Comparación grafica del número de generaciones para diferentes estados del motor en ambos diseños.</i>	58

## Introducción.

El hombre, desde épocas remotas, ha tratado de reproducir en las máquinas y dispositivos que construye, las características, propiedades y atributos que poseen los organismos vivos que lo rodean en la naturaleza. Algunas de estas características complejas que fascinan al ser humano son el aprendizaje, la capacidad de tolerancia, la adaptabilidad extrema, el reflejo incondicionado y la capacidad de evolucionar, todas ellas difícilmente reproducibles mediante métodos tradicionales de ingeniería, por lo que con el auxilio de la informática, los científicos han podido desarrollar herramientas matemáticas fundadas sobre principios biológicos, que constituyen técnicas no convencionales para el tratamiento de diferentes sistemas, y que han sido utilizadas con éxito en áreas tan disímiles como la salud, la defensa, el deporte, el transporte, la meteorología, la economía, la industria y la energía.

Ejemplo de estas técnicas es la computación evolutiva, dentro de la cual encontramos los Algoritmos Genéticos (AGs) y cuya aplicación práctica comenzó a proliferar en los años 90 abarcando todas las esferas del conocimiento con innumerables aplicaciones de los AGs como herramienta de optimización inteligente. Dentro de estas aplicaciones se encuentran las relacionadas con la rama energética, rama a la cual se asocian los problemas más acuciantes y complejos que enfrenta hoy la humanidad.

Actualmente, como nunca antes, se hace necesario optimizar y explotar eficientemente los recursos energéticos. La crisis global, que comprende también una crisis energética y medioambiental, ha alcanzado cada rincón del planeta y se llevan a cabo significativos esfuerzos a escala mundial en programas de conservación y ahorro de energía, logrando además disminuir el impacto ambiental asociado a las tecnologías energéticas, fundamentalmente a la generación y uso final de la energía eléctrica.

Nuestro país no se puede dar el lujo de malgastar los pocos recursos de que dispone, por lo que todas las medidas tomadas tanto en el sector residencial,

como en la industria y los servicios, en relación al ahorro energético son siempre bienvenidas.

Específicamente en la industria, los especialistas velan porque el uso de cada máquina sea el adecuado y que su trabajo se realice con una alta eficiencia energética. Tal es el caso de los motores asincrónicos trifásicos, que constituyen los convertidores electromecánicos que más proliferan y los principales productores de fuerza motriz en la industria, y cuya eficiencia debe evaluarse en las condiciones reales de explotación para tomar decisiones fundamentadas sobre la conveniencia de sustituir el motor en operación por otro más eficiente.

El hecho de determinar la eficiencia de un motor puede resultar un proceso complicado para un ambiente industrial y los especialistas deben calcularla con una precisión adecuada según sea el propósito que se persiga. Esto permite comprobar si el motor ha sido seleccionado y opera acorde a los estándares del fabricante, si deben tomarse medidas que mejoren las condiciones de explotación y contribuir a elevar la eficiencia del motor y por tanto del sistema de suministro donde está ubicado, así como disminuir los costos energéticos y medioambientales relacionados con una operación menos eficiente. Para realizar tales mediciones la paralización del motor introduce demoras por el desmontaje del motor y pérdidas de utilidades por la paralización de algún proceso en la industria.

Por tanto, la realización de un sistema que pueda comprobar la eficiencia con que trabaja un motor asincrónico en condiciones de campo aportaría una herramienta potente brindando información detallada del motor en uso. Con este propósito son muchos los métodos que se han desarrollado y aún se continúa investigando en este sentido.

En el Centro de Estudios de Energía y Medio Ambiente (CEEMA), de la Universidad de Cienfuegos “Carlos Rafael Rodríguez” se desarrolló un método que emplea un AG simple para la estimación paramétrica del modelo del motor asincrónico trifásico y con ello calcular la eficiencia. Aunque esta aplicación marca un adelanto en cuanto al desarrollo de métodos de estimación de eficiencia de los

motores asincrónicos, no garantiza que constituya un diseño eficaz de AG, con combinación de operadores genéticos dirigidos no sólo a conseguir el funcionamiento del mismo, sino a lograr una disminución del esfuerzo de cómputo. Por otra parte, la aplicación emplea el toolbox de AG de MATLAB y por lo tanto no llega a ser un producto completamente adecuado para el campo, usualmente en ninguna computadora personal de la industria está instalado este sistema y los especialistas tienen poca familiarización con su uso. Las dificultades que se han mencionado conducen a identificar la siguiente situación problemática.

### **Situación problemática.**

Aunque con el diseño de un AG simple, que sirve de base al método de estimación de la eficiencia operacional de los motores asincrónicos trifásicos desarrollado en el CEEMA, se obtienen resultados técnicos aceptables, con errores del orden del 2% en la estimación de la eficiencia, no está garantizado que con ese diseño se obtengan las mejores estimaciones. Además, su empleo está condicionado a la disponibilidad de MATLAB en las máquinas donde se utilice.

### **Problema a resolver.**

¿Es posible construir otro diseño de AG para la estimación de la eficiencia de motores asincrónicos que arroje mejores resultados que los obtenidos por el método implementado en el CEEMA?

### **Idea a defender.**

Con el rediseño del AG se obtendrá un modelo que estime mejor los parámetros de los motores asincrónicos, necesitando menos recursos computacionales.

### **Objeto de estudio y campo de acción.**

Para la realización de este trabajo se enmarca como *objeto de estudio*, la información general de los motores eléctricos asincrónicos y el *campo de acción*

son los métodos de estimación de los parámetros operacionales de dichos motores.

Para dar solución al problema descrito anteriormente se plantean los siguientes objetivos:

### **Objetivo general.**

Construir un AG más adecuado para utilizarlo como optimizador en la búsqueda de los parámetros operacionales de los motores eléctricos asincrónicos, según metodología desarrollada en el CEEMA.

### **Tareas de la investigación.**

1. Actualización bibliográfica sobre la aplicación de los AGs a los problemas de estimación de parámetros operacionales de los motores eléctricos.
2. Determinación de diferentes diseños de AGs con la asistencia del toolbox de MATLAB.
3. Comparación de los diseños de AGs.
4. Selección del diseño más adecuado para la estimación de los parámetros.
5. Implementación del diseño seleccionado en el lenguaje de programación C#.
6. Documentación de la investigación realizada.

### **Estructura del documento.**

La tesis se concibe organizada en tres capítulos, en el siguiente orden:

Capítulo 1: “Estudio de los Algoritmos Genéticos”. Se describe el estado del arte de los Algoritmos Genéticos, definiendo los elementos que lo componen: cromosomas, población, función de adaptabilidad y operadores genéticos. Además, se analizan aspectos de la convergencia de estos algoritmos y las principales diferencias con respecto a otros métodos de búsqueda y optimización.

Capítulo 2: “Los Algoritmos Genéticos en la estimación de la eficiencia energética de los motores eléctricos”. Se referencia la amplia aplicación de los AGs a la

estimación de la eficiencia energética y específicamente, se estudia la metodología desarrollada por el Centro de Estudios de Energía y Medio Ambiente (CEEMA). Además en este capítulo, se proponen los operadores a variar en el AG propuesto por el CEEMA, con el fin de obtener nuevos diseños.

Capítulo 3: “Análisis de los resultados e implementación”. En este capítulo se muestran los resultados comparativos de los diferentes diseños obtenidos a partir de la variación de los operadores genéticos y los parámetros probabilísticos. Se selecciona el mejor diseño para su implementación en el lenguaje C#.

## **Capítulo 1: Estudio de los Algoritmos Genéticos.**

### ***1.1 Introducción.***

En el presente capítulo se exponen los resultados del estudio del estado del arte de los AGs. Se define el esquema general de funcionamiento de los AGs simples y otros conceptos como son: codificación de cromosomas, población, función de adaptabilidad. Además, se describen los diferentes operadores genéticos y se analizan aspectos fundamentales a considerarse para la convergencia de estos algoritmos. Las principales diferencias con respecto a otros métodos de búsqueda y optimización, son enunciadas también en el capítulo.

### ***1.2 Los Algoritmos Genéticos en la resolución de problemas de búsqueda.***

En los últimos años, el hombre ha logrado un desarrollo científico y tecnológico vertiginoso. Tal desarrollo, resuelve muchos problemas, pero puede ocasionar otros que deben resolverse. No se hace referencia a las leyes de la naturaleza, sino a como la naturaleza las interpreta. En ese sentido, si se transforma la energía como lo hacen las células, si se recicla los materiales como lo hace la naturaleza, quizás no habría problemas ecológicos, energéticos o de otra índole. La conclusión es, entonces, voltear a la naturaleza cuando se tenga un problema entre manos y seguramente ahí se encuentre la solución. En el caso de la inteligencia artificial, la genética ha aportado elementos importantes para su desarrollo.

De la misma forma, se puede encontrar en la biología la solución o elementos de una solución, a los problemas más sofisticados a los que se enfrenta la ingeniería. Como ingenieros, se debe mirar de vez en cuando a la naturaleza y considerarla como una alternativa importante. En 1866, un monje austríaco llamado Gregor

Mendel<sup>1</sup>, dio a conocer los resultados de ocho años de estudio y pensamiento, pero su trabajo fue ignorado durante 34 años. Cuando fue rescatado, se le consideró como una nueva y notable dificultad a vencer. Este resultó ser el origen del estudio de la genética, la ciencia de la herencia, como una rama definida de la Biología.

De acuerdo a los principios de la naturaleza, en los cuales están inspirados, los Algoritmos Genéticos (AGs) son muy simples. De acuerdo con la teoría de Charles Darwin [1], el principio de selección privilegia a los individuos más aptos y, por lo tanto, con mayor probabilidad de reproducción. Los individuos con más descendientes tienen más oportunidades de transmitir sus códigos genéticos en las próximas generaciones. Tales códigos genéticos constituyen la identidad de cada individuo.

Los principios básicos de los algoritmos genéticos fueron establecidos por Holland [2], y se encuentran bien descritos en varios textos como por ejemplo: Davis [3], Michalewicz [4], Reeves [5].

Los algoritmos genéticos (AGs) son algoritmos de búsqueda basados en los mecanismos de selección natural que combinan la supervivencia de las secuencias mejores adaptadas con cambios aleatorios de información. [6]

Algoritmos de búsqueda basados en los mecanismos de selección natural y genética natural. Combinan la supervivencia de los más compatibles entre las estructuras de cadenas, con una estructura de información ya aleatorizada, intercambiada para construir un algoritmo de búsqueda con algunas de las capacidades de innovación de la búsqueda humana. [7]

---

<sup>1</sup> Gregor Mendel-Angustuos (20 de julio de 1822 – 6 de enero de 1884) fue un monje agustino católico y naturalista, nacido en Heinzendorf, Austria (actual Hynčice, República Checa), que describió las llamadas Leyes de Mendel que rigen la herencia genética, por medio de los trabajos que llevó a cabo con diferentes variedades de la planta del guisante. Los primeros trabajos en genética fueron realizados por Mendel. Inicialmente realizó cruces de semillas, las cuales se particularizaron por salir de diferentes estilos y algunas de su misma forma.

Los AGs pertenecen al grupo de los *Métodos Estocásticos* que son aquellos que realizan una búsqueda aleatoria del espacio. Muchos de estos métodos se han venido desarrollando desde la década del sesenta del siglo pasado, dando como resultado una serie de procedimientos computacionales heurísticos capaces de resolver problemas con alto grado combinatorio y encontrar buenas soluciones, muy próximas al óptimo. Lo descrito anteriormente se puede encontrar en [36].

Al principio, los algoritmos genéticos fueron aplicados principalmente en problemas de parámetros numéricos. Hoy en día, encuentran más y más aplicaciones generales gracias a un mejor entendimiento de los requerimientos de cada problema, y formas nuevas de procesar las restricciones de los problemas.

Una definición bastante completa de un algoritmo genético es la propuesta por John Koza<sup>2</sup>:

*“Es un algoritmo matemático altamente paralelo que transforma un conjunto de objetos matemáticos individuales con respecto al tiempo usando operaciones modeladas de acuerdo al principio Darwiniano de reproducción y supervivencia del más apto, y tras haberse presentado de forma natural una serie de operaciones genéticas de entre las que destaca la recombinación sexual. Cada uno de estos objetos matemáticos suele ser una cadena de caracteres (letras o números) de longitud fija que se ajusta al modelo de las cadenas de cromosomas, y se les asocia con una cierta función matemática que refleja su aptitud.” [8]*

Los algoritmos genéticos son algoritmos de investigación basados en la mecánica de la selección natural y la genética. Combinan la supervivencia del más apto entre estructuras formadas por cadenas de bits.

---

<sup>2</sup> Jonh R Koza es un científico de la computación y un profesor de consulta en la Universidad de Stanford, el más notable por su trabajo en la innovación del uso de la programación genética para la optimización de problemas complejos. John Koza también es acreditado con ser el creador de la "scratch card". Obtuvo su doctorado en de Ciencias de la Computación en la Universidad de Michigan en 1972 y posee su propia compañía de Programación Genética.

El tema central en las investigaciones sobre algoritmos genéticos, ha sido la *robustez*, el equilibrio necesario entre la eficiencia y la eficacia suficiente para la supervivencia en entornos diferentes. Las implicaciones que tiene la robustez en los sistemas artificiales son variadas. Si se puede conseguir que un sistema artificial sea más robusto, se podrán reducir, e incluso eliminar, los costes por rediseños. Y si se es capaz de lograr niveles altos de adaptación, los sistemas podrán desarrollar sus funciones mejor y durante más tiempo. Sin embargo, ante la robustez, eficiencia y flexibilidad de los sistemas biológicos, sólo es posible sentarse a contemplar, y maravillarse; se mentiría si se dijera que los humanos son capaces de igualarlos.

### **1.3 Esquema de funcionamiento del Algoritmo Genético Simple.**

Como se ve en el epígrafe anterior, los algoritmos genéticos son métodos sistemáticos para la resolución de problemas de búsqueda y optimización que aplican a estos los mismos métodos de la evolución biológica: selección basada en la población, reproducción sexual y mutación.

Los algoritmos genéticos son métodos de optimización, que tratan de resolver un conjunto de problemas tras ser parametrizables en una serie de variables,  $(x_i, \dots, x_n)$  codificando así el *cromosoma*. Todos los operadores utilizados por un algoritmo genético se aplicarán sobre estos cromosomas, o sobre poblaciones de ellos. En el algoritmo genético va implícito el método para resolver el problema; son sólo parámetros de tal método los que están codificados, a diferencia de otros algoritmos evolutivos como la programación genética. Hay que tener en cuenta que un algoritmo genético es independiente del problema, lo cual lo hace un algoritmo robusto, por ser útil para cualquier problema, pero a la vez débil, pues no está especializado en ninguno.

Las soluciones codificadas en un cromosoma compiten para ver cuál constituye la mejor solución (aunque no necesariamente la mejor de todas las soluciones posibles). El *ambiente*, constituido por las otras camaradas soluciones, ejerce una

presión selectiva sobre la población, de forma que sólo los mejor adaptados (aquellos que resuelvan mejor el problema) sobrevivan o leguen su material genético a las siguientes generaciones, igual que en la evolución de las especies. La diversidad genética se introduce mediante mutaciones y recombinación.

En la naturaleza lo único que hay que optimizar es la supervivencia, y eso significa a su vez maximizar diversos factores y minimizar otros. Un algoritmo genético, sin embargo, se usa habitualmente para optimizar sólo una función, no diversas funciones relacionadas entre sí simultáneamente. La optimización que busca diferentes objetivos simultáneamente, denominada multimodal o multiobjetivo, también se suele abordar con un algoritmo genético especializado.

Por lo tanto, un algoritmo genético simple consiste en lo siguiente: hallar de qué parámetros depende el problema, codificarlos en un cromosoma, y se aplican los métodos de la evolución: selección y reproducción sexual con intercambio de información y alteraciones que generan diversidad.

En la naturaleza los individuos de una población compiten entre sí en la búsqueda de recursos tales como comida, agua y refugio. Incluso los miembros de una misma especie compiten a menudo en la búsqueda de un compañero. Aquellos individuos que tienen más éxito en sobrevivir y en atraer compañeros tienen mayor probabilidad de generar un gran número de descendientes. Por el contrario individuos poco dotados producen un menor número de descendientes. Esto significa que los genes de los individuos mejor adaptados se propagan en sucesivas generaciones hacia un número de individuos creciente. La combinación de buenas características provenientes de diferentes ancestros, puede a veces producir descendientes "súper individuos", cuya adaptación es mucho mayor que la de cualquiera de sus ancestros. De esta manera, las especies evolucionan logrando unas características cada vez mejor adaptadas al entorno en el que viven.

Se supone que los individuos son posibles soluciones del problema, pueden representarse como un conjunto de parámetros que se denomina genes, los

cuales agrupados forman una ristra de valores a menudo referida como cromosoma.

Los algoritmos genéticos usan una analogía directa con el comportamiento natural. Trabajan con una población de individuos, cada uno de los cuales representa una solución factible a un problema dado.

La función de adaptación debe ser diseñada para cada problema de manera específica. Dado un cromosoma particular, la función de adaptación le asigna un número real, que se supone refleja el nivel de adaptación al problema del individuo representado por el cromosoma.

A cada individuo se le asigna un valor o puntuación, relacionado con la bondad de dicha solución. En la naturaleza esto equivaldría al grado de efectividad de un organismo para competir por unos determinados recursos. Cuanto mayor es la adaptación de un individuo al problema, mayor es la probabilidad de que el mismo sea seleccionado para reproducirse, cruzando su material genético con otro individuo seleccionado de igual forma. Este cruce produce nuevos individuos, descendientes de los anteriores los cuales comparten algunas de las características de sus padres.

Cuanto menor es la adaptación de un individuo, menor es la probabilidad de que dicho individuo sea seleccionado para la reproducción, y por tanto de que su material genético se propague en sucesivas generaciones.

De esta manera se produce una nueva población de posibles soluciones, la cual reemplaza a la anterior y verifica la interesante propiedad de que contiene una mayor proporción de buenas características en comparación con la población anterior. Así a lo largo de las generaciones las buenas características se propagan a través de la población. Favoreciendo el cruce de los individuos mejor adaptados, van siendo exploradas las áreas más prometedoras del espacio de búsqueda. Si el algoritmo genético ha sido bien diseñado, la población convergerá hacia una solución óptima del problema.

En próximos epígrafes se definen los elementos mencionados, necesarios para la comprensión del funcionamiento del algoritmo genético simple del cual se propone a continuación un pseudocódigo:

```
BEGIN
  Generar una población inicial.
  Evaluar la función de evaluación de cada individuo.
  WHILE NOT Terminado DO
    BEGIN
      /* Producir nueva generación */
      FOR Tamaño población/2 DO
        BEGIN
          /*Ciclo Reproductivo */
          Seleccionar dos individuos de la anterior generación, para el cruce.
          Cruzar con cierta probabilidad dos individuos obteniendo descendientes.
          Mutar los descendientes con cierta probabilidad.
          Evaluar la función de evaluación de los descendientes mutados.
          Insertar los descendientes mutados en la nueva generación.
        END
      IF la población ha convergido THEN
        Terminado:= TRUE
      END
    END
  END
```

#### **1.4 Codificación de la solución.**

Durante los primeros años el tipo de representación utilizado era siempre binario, sin embargo esta representación no siempre es efectiva. Por tal motivo comenzaron a utilizarse otros tipos de representaciones. En general, una representación ha de ser capaz de identificar las características constituyentes de un conjunto de soluciones, de forma que distintas representaciones dan lugar a

distintas perspectivas y por tanto distintas soluciones. Se puede considerar tres tipos básicos de representaciones:

- *Representación binaria*: Cada gen es un valor 1 ó 0.

{1; 0; 1; 1; 0; 1}

- *Representación entera*: Cada gen es un valor entero.

{1; 0; 3; -1; 0; 4}

- *Representación real*: Cada gen es un valor real.

{1,78; 2,6; 7; 0; -1,2; 6,5}

En términos biológicos, el conjunto de parámetros representando un cromosoma particular se denomina fenotipo. El fenotipo contiene la información requerida para construir un organismo, el cual se refiere como genotipo. Los mismos términos se utilizan en el campo de los AGs. La adaptación al problema de un individuo depende de la evaluación del genotipo, es decir puede ser computada a partir del cromosoma, usando la función de evaluación.

### **1.5 Población.**

La población no es más que el conjunto de posibles soluciones con las cuales el AG trabaja. Está compuesta por todos los individuos candidatos que son analizados y posteriormente evaluados. A continuación se analiza cómo se genera la población inicial y cuál debe ser el tamaño de una población.

#### **1.5.1 Población inicial.**

Habitualmente la población inicial se escoge generando ristas al azar. Entonces puede surgir la pregunta de qué es lo que sucedería si los individuos de la población inicial se obtuviesen como resultado de alguna técnica heurística o de optimización local. En los pocos trabajos que existen sobre este aspecto, se

constata que esta inicialización no aleatoria de la población inicial, puede acelerar la convergencia del algoritmo genético. Sin embargo en algunos casos la desventaja resulta ser la prematura convergencia del algoritmo, queriendo indicar con esto la convergencia hacia óptimos locales.

### **1.5.2 Tamaño de la población.**

Una cuestión a plantearse es la relacionada con el tamaño idóneo de la población. Parece intuitivo que las poblaciones pequeñas corren el riesgo de no cubrir adecuadamente el espacio de búsqueda, mientras que el trabajar con poblaciones de gran tamaño puede acarrear problemas relacionados con el excesivo costo computacional.

Goldberg en 1989 efectuó un estudio teórico, obteniendo como conclusión que el tamaño óptimo de la población para ristas de longitud  $L$ , con codificación binaria, crece exponencialmente con el tamaño de la ristra. [10]

Este resultado traería como consecuencia que la aplicabilidad de los algoritmos genéticos en problemas reales sería muy limitada, ya que resultarían no competitivos con otros métodos de optimización combinatoria. También Alander en 1992, basándose en evidencia empírica sugiere que un tamaño de población comprendida entre  $L$  y  $2L$  es suficiente para atacar con éxito los problemas. [11]

### **1.6 Función de adaptabilidad.**

Dos aspectos que resultan cruciales en el comportamiento de los algoritmos genéticos son la determinación de una adecuada función de adaptación o función objetivo, así como la codificación utilizada. Idealmente sería de interés construir funciones objetivo con ciertas regularidades, es decir funciones objetivo que verifiquen que para dos individuos que se encuentren cercanos en el espacio de búsqueda, sus respectivos valores en las funciones objetivo sean similares. Por otra parte una dificultad en el comportamiento del algoritmo genético puede ser la

existencia de gran cantidad de óptimos locales, así como el hecho de que el óptimo global se encuentre muy aislado.

La regla general para construir una buena función objetivo es que esta debe reflejar el valor del individuo de una manera real, pero en muchos problemas de optimización combinatoria, donde existen gran cantidad de restricciones, buena parte de los puntos del espacio de búsqueda representan individuos no válidos. Para este planteamiento en el que los individuos están sometidos a restricciones, se han propuesto varias soluciones. La primera sería la que podríamos denominar absolutista, en la que aquellos individuos que no verifican las restricciones, no son considerados como tales, y se siguen efectuando cruces y mutaciones hasta obtener individuos válidos, o bien a dichos individuos se les asigna una función objetivo igual a cero.

Otra posibilidad consiste en reconstruir aquellos individuos que no verifican las restricciones. Dicha reconstrucción suele llevarse a cabo por medio de un nuevo operador que se acostumbra a denominar reparador.

Otro enfoque está basado en la penalización de la función objetivo. La idea general consiste en dividir la función objetivo del individuo por una cantidad (la penalización) que guarda relación con las restricciones que dicho individuo viola. Dicha cantidad puede simplemente tener en cuenta el número de restricciones violadas o bien el denominado costo esperado de reconstrucción, es decir el coste asociado a la conversión de dicho individuo en otro que no viole ninguna restricción.

Otra técnica que se ha venido utilizando en el caso en que la computación de la función objetivo sea muy compleja es la denominada evaluación aproximada de la función objetivo. En algunos casos la obtención de  $n$  funciones objetivo aproximadas puede resultar mejor que la evaluación exacta de una única función objetivo (supuesto el caso de que la evaluación aproximada resulta como mínimo  $n$  veces más rápida que la evaluación exacta).

Un problema habitual en las ejecuciones de los algoritmos genéticos surge debido a la velocidad con la que el algoritmo converge. En algunos casos la convergencia es muy rápida, lo que suele denominarse convergencia prematura, en la cual el algoritmo converge hacia óptimos locales, mientras que en otros casos el problema es justo el contrario, es decir se produce una convergencia lenta del algoritmo. Una posible solución a estos problemas pasa por efectuar transformaciones en la función objetivo. El problema de la convergencia prematura, surge a menudo cuando la selección de individuos se realiza de manera proporcional a su función objetivo. En tal caso, pueden existir individuos con una adaptación al problema muy superior al resto, que a medida que avanza el algoritmo dominan a la población. Por medio de una transformación de la función objetivo, en este caso una comprensión del rango de variación de la función objetivo, se pretende que dichos "súper individuos" no lleguen a dominar a la población. El problema de la lenta convergencia del algoritmo, se resolvería de manera análoga, pero en este caso efectuando una expansión del rango de la función objetivo. La idea de especies de organismos, ha sido imitada en el diseño de los algoritmos genéticos en un método propuesto por Goldberg y Richardson [12], utilizando una modificación de la función objetivo de cada individuo, de tal manera que individuos que estén muy cercanos entre sí devalúen su función objetivo, con objeto de que la población gane en diversidad.

### ***1.7 Funcionamiento de los operadores genéticos.***

Los mecanismos de un algoritmo genético son sorprendentemente sencillos. Un algoritmo genético que produce un buen resultado en muchos problemas prácticos está compuesto por tres operaciones:

#### *1. Selección.*

El operador de *Selección* es el encargado de transmitir y conservar aquellas características de las soluciones que se consideran valiosas a lo largo de las generaciones. El principal medio para que la información útil se transmita es que

aquellos individuos mejor adaptados (mejor valor de función de adaptabilidad) tengan más probabilidades de reproducirse. Sin embargo, es necesario también incluir un factor aleatorio que permita reproducirse a individuos que aunque no estén muy bien adaptados, puedan contener alguna información útil para posteriores generaciones, con el objeto de mantener así también una cierta diversidad en cada población. A continuación se mencionan algunos tipos de *Selección*:

- *Ruleta o Selección Proporcional*: Con este método la probabilidad que tiene un individuo de reproducirse es proporcional a su valor de función de evaluación, es decir, a su adaptación. Una vez calculadas estas probabilidades, la selección de los individuos para reproducirse es aleatoria según estos valores. Se puede encontrar una descripción detallada de esta estrategia en [13].
- *Selección por Ranking*: Desarrollado por Whitley en 1989 consiste en calcular las probabilidades de reproducción atendiendo a la ordenación de la población por el valor de adaptación en vez de atendiendo simplemente a su valor de adecuación. [14]
- *Selección por Torneo*: Reporta un coste computacional muy bajo debido a su sencillez. Se selecciona un grupo de  $t$  individuos (normalmente  $t = 2$ , torneo binario) y se genera un número aleatorio entre 0 y 1. Si este número es menor que un cierto umbral  $K$  (usualmente 0,75), se selecciona para reproducirse al individuo con mejor adaptación, y si este número es menor que  $K$ , se selecciona, por el contrario, al individuo con peor adaptación.
- *Selección Elitista*: De acuerdo al valor de la función de adaptabilidad, se selecciona una pequeña cantidad de individuos para que pasen de forma directa a formar parte de la generación siguiente; sin ser afectados por los otros operadores.
- *Selección escalada*: al incrementarse la aptitud media de la población, la fuerza de la presión selectiva también aumenta y la función de aptitud se

hace más discriminadora. Este método puede ser útil para seleccionar más tarde, cuando todos los individuos tengan una aptitud relativamente alta y sólo les distinguen pequeñas diferencias en la aptitud.

- *Selección generacional*: la descendencia de los individuos seleccionados en cada generación se convierte en toda la siguiente generación. No se conservan individuos entre las generaciones.
- *Selección por estado estacionario*: la descendencia de los individuos seleccionados en cada generación vuelven al acervo genético preexistente, reemplazando a algunos de los miembros menos aptos de la siguiente generación. Se conservan algunos individuos entre generaciones.
- *Selección jerárquica*: los individuos atraviesan múltiples rondas de selección en cada generación. Las evaluaciones de los primeros niveles son más rápidas y menos discriminatorias, mientras que los que sobreviven hasta niveles más altos son evaluados más rigurosamente. La ventaja de este método es que reduce el tiempo total de cálculo al utilizar una evaluación más rápida y menos selectiva para eliminar a la mayoría de los individuos que se muestran pocos o nada prometedores, y sometiendo a una evaluación de aptitud más rigurosa y computacionalmente más costosa sólo a los que sobreviven a esta prueba inicial.

## 2. *Cruzamiento*.

El operador de *Cruzamiento* permite realizar una exploración de toda la información almacenada hasta el momento en la población y combinarla para crear mejores individuos. La literatura es bien densa en este tipo de operadores, un ejemplo de ello se puede encontrar en [15], [16], [17], [18], [19] y [20]. Dentro de los métodos habituales se destacan los siguientes:

- *Cruce de un punto*: Es el método de cruce más sencillo. Se selecciona una posición en las cadenas de los progenitores, y se intercambian los genes a la izquierda de esta posición.

- *Cruce de  $n$  puntos*: Es una generalización del método anterior. Se seleccionan varias posiciones ( $n$ ) en las cadenas de los progenitores y se intercambian los genes a ambos lados de estas posiciones.
- *Cruce Uniforme*: Se realiza un test aleatorio para decidir de cual de los progenitores se toma cada posición de la cadena.

### 3. *Mutación.*

El objetivo del operador de *Mutación* es producir nuevas soluciones a partir de la modificación de un cierto número de genes de una solución existente, con la intención de fomentar la variabilidad dentro de la población. Existen muy diversas formas de realizar la mutación, desde la más sencilla (Puntual), donde cada gen muta aleatoriamente con independencia del resto de genes, hasta configuraciones más complejas donde se tienen en cuenta la estructura del problema y la relación entre los distintos genes.

La reproducción es el proceso en que cadenas individuales de bits son copiadas de acuerdo con el valor del objetivo de su función de aptitud. Ello significa que las cadenas de bits con mejor valor, tienen una alta probabilidad de contribuir con uno o más descendientes en la siguiente generación. Este operador, por supuesto, es una versión artificial de la selección natural, una supervivencia Darwiniana del más apto entre cadenas.

Después de la reproducción, debe seguir un entrecruzamiento. Los mecanismos de reproducción y entrecruzamiento son sorprendentemente simples, involucran un número aleatorio de generaciones, copias de cadenas, y algunos intercambios de los elementos de las cadenas. De Jong investigó el comportamiento del operador de cruce basado en múltiples puntos, concluyendo que el cruce basado en dos puntos representaba una mejora, para una mayor investigación referirse a [21].

La combinación de reproducción y entrecruzamiento dan a los algoritmos genéticos mucho de su poder. Al principio, parece sorprendente como es que dos

procesos tan simples resulten ser algo útil, mucho menos un método de investigación rápido y robusto. Más aún, parece un poco extraño que la suerte juegue un papel fundamental en un proceso de investigación.

Una respuesta a estas cuestiones, la proporciona un matemático llamado Hardamard<sup>3</sup>. Él sugiere que ningún descubrimiento no es resultado (ni debe serlo) de la suerte, aunque tenga algo que ver. Hardamard indica que un rol de la suerte en muchos de los descubrimientos humanos es causar la yuxtaposición de nociones diferentes que conducen al descubrimiento.

La mutación se considera un operador básico, que proporciona un pequeño elemento de aleatoriedad en la vecindad (entorno) de los individuos de la población. Si bien se admite que el operador de cruce es el responsable de efectuar la búsqueda a lo largo del espacio de posibles soluciones, también parece desprenderse de los experimentos efectuados por varios investigadores que el operador de mutación va ganando en importancia a medida que la población de individuos va convergiendo [22].

Schaffer encuentra que el efecto del cruce en la búsqueda es inferior al que previamente se esperaba. Utilizan la denominada evolución primitiva, en la cual, el proceso evolutivo consta tan sólo de selección y mutación. Encuentran que dicha evolución primitiva supera con creces a una evolución basada exclusivamente en la selección y el cruce. Otra conclusión de su trabajo es que la determinación del valor óptimo de la probabilidad de mutación es mucho más crucial que el relativo a la probabilidad de cruce. [23]

---

<sup>3</sup>Jacques Salomon Hadamard (Versalles, Francia, 8 de diciembre de 1865 - París, 17 de octubre de 1963, fue un matemático francés, que trabajó en las universidades de Burdeos y en la Sorbona de París. Su logro más conocido es la demostración que lleva a cabo en 1896 (obtenida de modo independiente ese mismo año por el matemático belga Charles-Jean de la Vallée Poussin) del teorema de los números primos. Estableció asimismo la noción de problema bien planteado en el terreno de las ecuaciones diferenciales. Es también uno de los matemáticos que más han contribuido en el desarrollo del análisis infinitesimal y desarrolló el teorema sobre el valor absoluto de un determinante.

### **1.8 Parámetros probabilísticos, reemplazo de la población y condición de parada.**

Los algoritmos genéticos tienen dos parámetros probabilísticos importantes: Probabilidad de Cruzamiento ( $P_c$ ) y Probabilidad de Mutación ( $P_m$ ). Para ambos operadores genéticos se generan números aleatorios que se comparan con su parámetro probabilístico, si son menores que este último se realiza la operación de recombinación o mutación según corresponda.

La  $P_c$  oscila, generalmente, entre valores de 0.7 y 0.8, mientras la  $P_m$ , toma valores muy pequeños, aproximadamente entre 0.01 y 0.1. La búsqueda del valor óptimo para la probabilidad de mutación, es una cuestión que ha sido motivo de varios trabajos. Así, De Jong en 1975 [24] recomienda la utilización de una probabilidad de mutación del bit de  $1/l$ , siendo  $l$  la longitud del string. En [25] utilizan resultados experimentales para estimar la tasa óptima proporcional a  $1/\lambda 0.931810.4535$ , donde  $\lambda$  denota el número de individuos en la población.

Si bien en la mayoría de las implementaciones de algoritmos genéticos se asume que tanto la probabilidad de cruce como la de mutación permanecen constantes, algunos autores han obtenido mejores resultados experimentales modificando la probabilidad de mutación a medida que aumenta el número de iteraciones. Pueden consultarse los trabajos de Ackley [26], Bramlette [27], Fogarty [28] y Michalewicz y Janikow [29].

Una vez determinados los individuos descendientes de una población de la generación  $t$ , el proceso de reemplazamiento consiste en conformar la siguiente generación ( $t+1$ ), para ello se conforma una nueva población. Esto se puede lograr de tres formas distintas:

- Cuando el número de individuos llega a un cierto número, se elimina un subconjunto de la población conteniendo a los individuos peor adaptados.
- Cada vez que se crea un nuevo individuo, en la población se elimina el peor adaptado para dejar su lugar a este nuevo individuo.

- Cada vez que se crea un nuevo individuo, en la población se elimina aleatoriamente una solución, independientemente de su adaptación.

En cuanto el criterio de parada, generalmente viene determinado por criterios a priori sencillos, como un número máximo de generaciones o un tiempo máximo de resolución, o más eficientemente por estrategias relacionadas con indicadores del estado de evolución de la población, como por la pérdida de diversidad dentro de la población o por no haber mejora en un cierto número de iteraciones, siendo por lo general una condición mixta lo más utilizado, es decir, limitar el tiempo de ejecución a un número de iteraciones y tener en cuenta algún indicador del estado de la población para considerar la convergencia antes de alcanzar tal limitación.

### ***1.9 Convergencia de los Algoritmos Genéticos.***

El concepto de convergencia está relacionado con la progresión hacia la uniformidad: un gen ha convergido cuando al menos el 95 % de los individuos de la población comparten el mismo valor para dicho gen. Se dice que la población converge cuando todos los genes han convergido. Se puede generalizar dicha definición al caso en que al menos un 3% de los individuos de la población hayan convergido [21].

A continuación una serie de criterios acerca de la convergencia:

Rudolph [29] demuestra la no convergencia hacia el óptimo global del algoritmo genético simple o canónico, así como la garantía, de convergencia expresada en términos probabilísticos, del algoritmo genético que mantiene a la mejor solución en la población.

Davis y Principe [30] extrapolan los fundamentos teóricos del algoritmo simulated annealing a un modelo de algoritmo genético basado en cadenas de Markov<sup>4</sup>. Se

---

<sup>4</sup> Cadenas de Markov: Una cadena de Markov, que recibe su nombre del matemático ruso Andrei Andreevitch Markov (1856-1922), es una serie de eventos, en la cual la probabilidad de que ocurra

efectúa un estudio de las matrices de transición de estados teniendo en cuenta en primer lugar tan sólo la reproducción, a continuación la reproducción y la mutación y finalmente la reproducción, la mutación y el cruce.

Suzuki [31] efectúa un estudio de la convergencia de los algoritmos genéticos por medio de cadenas de Markov. Los algoritmos genéticos estudiados presentan un criterio de reducción elitista modificado, según el cual se genera una población de  $\lambda$  individuos, incluyendo en ella al mejor individuo de la población en la generación anterior, obteniéndose los  $\lambda - 1$  individuos restantes por medio de las operaciones genéticas normales.

Liepins [32] demuestra la convergencia del algoritmo genético hacia poblaciones que contienen al óptimo, en el caso de algoritmos genéticos sin operador de mutación, pero en los cuales el reemplazamiento de individuos es elitista -*el mejor individuo no se pierde nunca*- y además se efectúa de tal manera que en cada paso cualquier punto del espacio sea potencialmente alcanzable por medio de la operación de cruce.

Chakraborty y Dastidar [33], presentan un modelo de fiabilidad estocástica de un esquema para el algoritmo genético binario con longitud de representación fija, y obtienen una estimación para el número de generaciones necesarias hasta obtener la convergencia.

Eiben [34] modelan la evolución del algoritmo genético por medio de una cadena de Markov, obteniendo condiciones suficientes para la convergencia en probabilidad del proceso evolutivo hacia el óptimo global.

---

Un evento depende del evento inmediato anterior. En efecto, las cadenas de este tipo tienen memoria. "Recuerdan" el último evento y esto condiciona las posibilidades de los eventos futuros. Esta dependencia del evento anterior distingue a las cadenas de Markov de las series de eventos independientes, como tirar una moneda al aire o un dado.

### ***1.10 ¿Cómo saber si es posible usar el Algoritmo Genético?***

La aplicación más común de los algoritmos genéticos ha sido la solución de problemas de optimización, en donde han mostrado ser muy eficientes y confiables. Sin embargo, no todos los problemas pudieran ser apropiados para la técnica, y se recomienda en general tomar en cuenta las siguientes características del mismo antes de intentar usarla:

- Su espacio de búsqueda (i.e., sus posibles soluciones) debe estar delimitado dentro de un cierto rango.
- Debe poderse definir una función de aptitud que indique qué tan buena o mala es una cierta respuesta.
- Las soluciones deben codificarse de una forma que resulte relativamente fácil de implementar en la computadora.

Una característica que debe tener la función de aptitud es que debe ser capaz de "castigar" a las malas soluciones, y de "premiar" a las buenas, de forma que sean estas últimas las que se propaguen con mayor rapidez.

### ***1.11 Diferencia entre los Algoritmos Genéticos y otros métodos tradicionales de búsqueda.***

- Trabajan con la codificación del conjunto de parámetros, no con los parámetros.
- Buscan a partir de una población de puntos, no un punto único.
- No necesitan conocimientos específicos sobre el problema que intentan resolver.
- Operan de forma simultánea con varias soluciones, en vez de trabajar de forma secuencial como las técnicas tradicionales.

- Cuando se usan para problemas de optimización - maximizar una función objetivo- resultan menos afectados por los máximos locales (falsas soluciones) que las técnicas tradicionales.
- Resulta sumamente fácil ejecutarlos en las modernas arquitecturas masivas en paralelo.
- Usan operadores probabilísticos, en vez de los típicos operadores determinísticos de las otras técnicas.
- Pueden tardar mucho en converger, o no converger en absoluto, dependiendo en cierta medida de los parámetros que se utilicen - tamaño de la población, número de generaciones, etc.-.
- Pueden converger prematuramente debido a una serie de problemas de diversa índole.
- Usan reglas de transición probabilísticas, no reglas determinísticas.

### ***1.12 Aplicaciones de los Algoritmos Genéticos.***

Aunque es difícil hacer una lista con todas las aplicaciones y aportes que se han logrado gracias a los AGs, ya que se hayan aplicados a diversos problemas y modelos en ingeniería, y en la ciencia en general sí, se puede transmitir la idea de la variedad de aplicaciones que tienen los algoritmos genéticos. Gracias al éxito en estas y otras áreas, los algoritmos genéticos han llegado a ser un campo puntero en la investigación actual. Un ejemplo de ello se puede consultar en [35].

**Programación automática:** Los algoritmos genéticos se han empleado para desarrollar programas para tareas específicas, y para diseñar otras estructuras computacionales tales como el autómata celular, y las redes de clasificación.

**Aprendizaje máquina:** Los algoritmos genéticos se han utilizado también en muchas de estas aplicaciones, tales como la predicción del tiempo o la estructura de una proteína. Han servido así mismo para desarrollar determinados aspectos

de sistemas particulares de aprendizaje, como pueda ser el de los pesos en una red neuronal, las reglas para sistemas de clasificación de aprendizaje o sistemas de producción simbólica, y los sensores para robots.

**Economía:** En este caso, se ha hecho uso de estos algoritmos para modelar procesos de innovación, el desarrollo estrategias de puja, y la aparición de mercados económicos.

**Sistemas inmunes:** A la hora de modelar varios aspectos de los sistemas inmunes naturales, incluyendo la mutación somática durante la vida de un individuo y el descubrimiento de familias de genes múltiples en tiempo evolutivo, ha resultado útil el empleo de esta técnica.

**Ecología:** En la modelización de fenómenos ecológicos tales como las carreras de armamento biológico, la co-evolución de parásito-huésped, la simbiosis, y el flujo de recursos.

**Genética de poblaciones:** En el estudio de preguntas del tipo “*¿Bajo qué condiciones será viable evolutivamente un gene para la recombinación?*”

**Evolución y aprendizaje:** Los algoritmos genéticos se han utilizado en el estudio de las relaciones entre el aprendizaje individual y la evolución de la especie.

**Sistemas sociales:** En el estudio de aspectos evolutivos de los sistemas sociales, tales como la evolución del comportamiento social en colonias de insectos, y la evolución de la cooperación y la comunicación en sistemas multi-agentes.

**Optimización:** Se trata de un campo especialmente abonado para el uso de los Algoritmos Genéticos, por las características intrínsecas de estos problemas. No en vano fueron la fuente de inspiración para los creadores estos algoritmos. Los Algoritmos Genéticos se han utilizado en numerosas tareas de optimización, incluyendo la optimización numérica, y los problemas de optimización combinatoria.

### **1.13 Conclusiones.**

Los AGs son algoritmos de búsqueda basados en la selección natural, la recombinación de información genética y la mutación. Dos características que distinguen a los AGs de otras técnicas de búsqueda, operar de forma simultánea con varias soluciones (población) y usar reglas probabilísticas de transición, le permiten desarrollar una amplia exploración en el espacio de búsqueda.

Si el AG ha sido bien diseñado atendiendo a: codificación, función de adaptabilidad, población y operadores genéticos; el algoritmo convergerá hacia una solución óptima del problema. Todo lo anterior permite asegurar que los AGs son una técnica potente para problemas con amplios espacios de búsqueda y computacionalmente abordables por el paralelismo en su arquitectura y la sencillez de sus cálculos.

## **Capítulo 2: Los Algoritmos Genéticos en la estimación de la eficiencia energética de los motores eléctricos.**

### ***2.1 Introducción.***

En el presente capítulo se estudia la aplicación de los AGs a los problemas de optimización de la eficiencia energética, así como la metodología desarrollada por el Centro de Estudios de Energía y Medio Ambiente (CEEMA) para calcular la eficiencia de los motores asincrónicos en condiciones de campo utilizando esta técnica. Además, se proponen los operadores a variar en el AG propuesto por el CEEMA, con el fin de obtenerse nuevos diseños que serán posteriormente comparados con el diseño inicial.

### ***2.2 Aplicación de Algoritmos Genéticos a problemas de optimización de la eficiencia de los motores eléctricos.***

Durante la transformación electromecánica de la energía, una parte de esta se disipa en forma de pérdidas. Estas pérdidas definen índices energéticos importantes como la eficiencia, que es necesario tener en cuenta para diversos análisis, sobre todo en el contexto actual donde la energía es un recurso de primerísimo orden.

Los motores eléctricos son de suma importancia en la actualidad, debido a las diferentes aplicaciones industriales a los que son sometidos, es por ello, que se deben tomar en cuenta todas las fallas que se presentan para el correcto funcionamiento de los mismos.

La industria es uno de los sectores de la sociedad más necesitados del ahorro de energía, su logro supone una mayor competitividad. Son grandes consumidoras de electricidad, por ejemplo las cementeras, metalúrgicas, cerámicas, etc. y aplican en sus procesos de producción diversas estrategias de producción y tecnologías para reducir al máximo el consumo de electricidad.

Como los motores se usan de forma general en cualquier industria, si de antemano se puede conocer la eficiencia a la que trabajan, se ahorraría energía y dinero.

El uso racional y eficiente de la energía ha sido un tema intensamente investigado. Existe gran diversidad de métodos propuestos para la medición de la eficiencia de los motores eléctricos asincrónicos. Algunos de estos métodos utilizan AGs para la estimación de los parámetros operacionales de los motores. Dicha estimación permite, utilizando los modelos matemáticos de los circuitos equivalentes, calcular la potencia de salida del motor y con ello la eficiencia en condiciones de campo, sin necesidad de interrumpir el funcionamiento del motor en la industria.

Investigaciones posteriores a 1994 se han dirigido al método del circuito equivalente para determinar las características operacionales del motor asincrónico a partir de la información suministrada por el fabricante, combinada con algoritmos de optimización estocástica. De esta manera, Haque [36] y Nolan [37] utilizaron AGs simples para determinar la resistencia del estator ( $r_s$ ), la resistencia del rotor ( $r_r$ ), y una combinación de las reactancias del estator y del rotor ( $x_s$  y  $x_r$ ) utilizando las especificaciones del motor provistas por el fabricante. Entre las especificaciones se necesitan los valores de momento a plena carga, momento de arranque y momento máximo, y se calcula además, la reactancia de magnetización ( $x_m$ ) a partir del factor de potencia nominal. De manera similar, en un trabajo posterior Nangsue [38] utilizan un AG para calcular los parámetros de tres motores a partir de las ecuaciones de momento a plena carga, momento de arranque y momento máximo. Pillay y col. usan AG en la determinación de parámetros de motores para el cálculo de momentos transitorios [39] y utilizan para ello también los datos de catálogo.

Continuando esta línea de investigación, en 1998 Pillay y col. [40], proponen tres métodos para determinar la eficiencia de los motores asincrónicos, incorporando las ideas básicas del método de segregación de pérdidas, el método del circuito equivalente y AG como técnica para resolver ecuaciones algebraicas no lineales.

La utilización de AG en combinación con mediciones de campo tales como corriente y tensión de línea, potencia eléctrica de entrada al motor y velocidad a varios estados de carga para optimizar cierta función de error, permite prescindir de los datos de catálogo pero requiere mayor esfuerzo para implementarlo, además de mediciones de la resistencia del estator. En este trabajo se utiliza un circuito equivalente exacto convencional, que incluye una resistencia para simular las pérdidas adicionales y se concluye que las mediciones propuestas constituyen información suficiente para la determinación precisa de los parámetros del circuito equivalente.

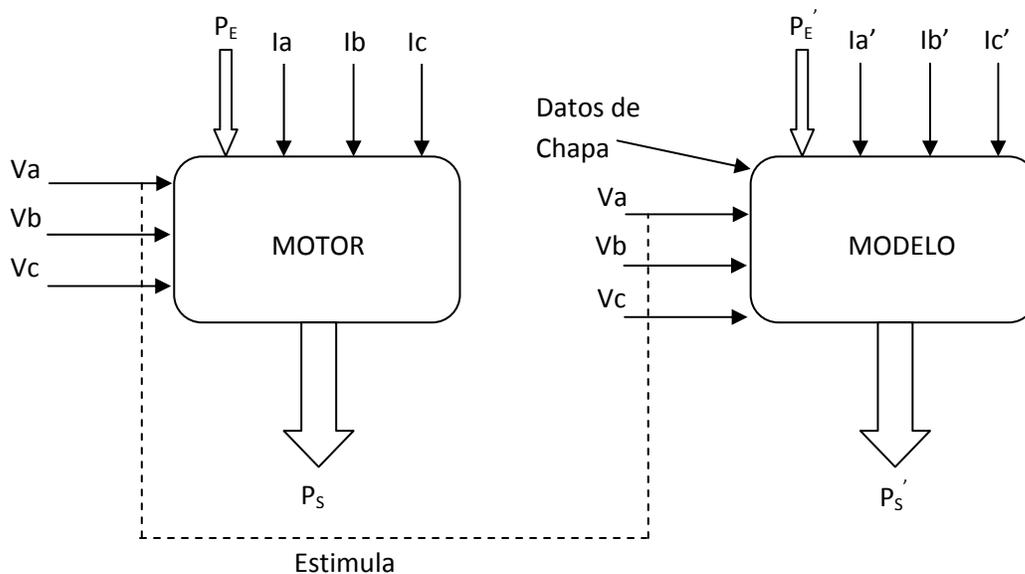
Las investigaciones más recientes en este tema están encausadas a mejorar el comportamiento de los algoritmos desarrollados. En este sentido, Phumiphak y Chatuthai en [41], publicado en el 2002, repiten básicamente los trabajos anteriores; pero comparan los resultados de AG cuya población es representada por cadenas binarias con otro que utiliza directamente números reales. Y concluyen que aunque los resultados son similares, se logra economía de cómputo cuando se utilizan números reales.

### ***2.3 Determinación de la eficiencia de los motores asincrónicos en condiciones de campo, según método del CEEMA.***

El trabajo desarrollado en el CEEMA, presenta el desarrollo teórico y la validación experimental de un procedimiento para determinar la eficiencia y otros parámetros operacionales de las máquinas asincrónicas, en condiciones de campo, mediante la aplicación de AG en presencia de desbalances de tensión. Se incluye el caso particular de régimen balanceado con desviaciones de tensión y/o frecuencia. El procedimiento se fundamenta en la metodología del circuito equivalente, lo cual requiere un bajo nivel de invasividad. Otras ventajas son las limitadas mediciones necesarias y la consideración de parámetros variables, aportando mayor precisión en los resultados obtenidos.

El AG constituye el núcleo de la aplicación, es la técnica que resuelve el circuito equivalente del motor, estima los parámetros operacionales con los cuales se determinan las pérdidas y la eficiencia.

El objetivo del AG es minimizar los errores entre los valores medidos y calculados por el modelo del circuito equivalente, de potencia eléctrica de entrada y corrientes de línea para el estado de carga considerado, lo que implica que los parámetros identificados sólo sean representativos de la operación del motor en este estado. Entonces se compara la respuesta del modelo parametrizado y el sistema físico real, ver Fig. 1, a través de una función de comportamiento que nos da una medida de cuánto se acerca la respuesta del modelo a la respuesta del sistema.



**Figura 1:** Representación de la estimación de los parámetros del motor a partir de un modelo.

En todos los casos la eficiencia se calcula como la relación entre la potencia de salida a la potencia eléctrica de entrada. La potencia de salida es la potencia de entrada menos las pérdidas; las pérdidas dependen de la exactitud del método aplicado.

Con relación a la determinación de la eficiencia operacional de motores eléctricos, otros métodos presuponen un elevado grado de invasividad si se necesita detener la producción en la búsqueda de los datos necesarios para calcular la eficiencia, las pérdidas y las potencias, valores que, en muchos casos, son difíciles de determinar.

Con el propósito de lograr la rápida convergencia del proceso evolutivo y definir un escenario físico en las fronteras de búsqueda, se introduce un vector de impedancias aproximadas en la población inicial del AG. Con el objetivo de determinar estos parámetros, se pueden utilizar los métodos tradicionales cuando son posibles aplicarlos en la industria, pero AG constituye una aproximación en condiciones de campo.

El método desarrollado permite evaluar la eficiencia de las máquinas en condiciones generalizadas, incluyendo aquellas que han sido reparadas, utilizando las componentes simétricas y, a la vez, efectuar otros cálculos de interés (potencia compleja, pérdidas desagregadas, deslizamiento, factor de potencia, etc.). Por esta razón, constituye una herramienta fundamental para el análisis técnico y económico de proyectos de mejoramiento de la eficiencia energética y de desarrollo de programas de máquinas de alta eficiencia en la industria y los servicios, así como para reducir el impacto ambiental de las tecnologías energéticas.

El diseño del AG utilizado por el CEEMA se especifica a continuación: operadores de selección *Estocástico Uniforme* y *Elitista*, operador de cruzamiento *Heurístico* y operador de mutación *Uniforme*; las probabilidades de cruzamiento y mutación son 0,8 y 0,01 respectivamente. Este diseño, referido como Diseño 0 en lo adelante, arroja resultados confiables pero no garantiza ser el más eficiente computacionalmente. Por tal motivo, se hace necesario variar estos operadores así como las probabilidades de cruzamiento y mutación con el fin de probar si es posible encontrar otro diseño de AG mejor, que arroje resultados confiables.

***Términos empleados en este capítulo***

**Impedancia:** Operador complejo formado por la resistencia y la reactancia de un circuito de corriente alterna y se obtiene dividiendo el voltaje por la corriente. La impedancia inhibe el flujo de corriente por el circuito y hay que considerarla al calcularla.

**Reactancia:** En los circuitos de corriente alterna existen elementos en los cuales el voltaje a través de ellos es directamente proporcional a la razón de cambio de la corriente que está circulando y la constante de proporcionalidad se denomina inductancia  $L$  del elemento. La inductancia multiplicada por la frecuencia angular es igual a la reactancia inductiva  $X$  del circuito y constituye la parte imaginaria de la impedancia.

**Resistencia:** La resistencia es un parámetro que relaciona la tensión y la corriente de un circuito. Esta relación es universalmente conocida como la Ley de Ohm e indica que la caída de tensión en una resistencia es directamente proporcional a la corriente que circula por ésta. La resistencia constituye la parte real de la impedancia.

**Modelo Balanceado:** Modelo de un motor asincrónico para simular su comportamiento cuando está alimentado por voltajes de fase de igual magnitud y con una diferencia de fases entre ellos de 120 grados eléctricos.

**Modelo Desbalanceado:** Modelo de un motor asincrónico para simular su comportamiento cuando está alimentado por voltajes de fase de magnitudes diferentes o diferencia de fases entre ellos distinta de 120 grados eléctricos o ambas.

**Motor asincrónico:** Convertidor de energía electromecánica que más prolifera en la industria por su sencillez y robustez. Existen motores asincrónicos monofásicos y trifásicos siendo estos últimos los que más se utilizan en la industria para el accionamiento de bombas, ventiladores, conductores y compresores. Estos

motores giran a velocidad inferior a la del campo magnético giratorio del estator, llamada velocidad asincrónica, por girar a velocidad diferente de la sincrónica se denominan asincrónicos. [42]

## **2.4 Elementos considerados para otros diseños de Algoritmos Genéticos a compararse con el propuesto por el CEEMA.**

### **2.4.1 Diseño del cromosoma.**

Los parámetros operacionales a estimar son 8, cuando el estado de carga es desbalanceado. El cromosoma definido en el Diseño 0 tiene la estructura:

- *Cromosoma para el Estado Desbalanceado:*  
[ $r_s$ ,  $X_1$ ,  $R_m$ ,  $X_m$ ,  $R_2$ ,  $X_2$ ,  $R_{22}$ ,  $X_{22}$ ]

donde:

$r_s$ : Resistencia de fase del estator.

$X_1$ : Reactancia de dispersión del estator.

$R_m$ : Resistencia de la rama de magnetización.

$X_m$ : Reactancia de magnetización.

$R_2$ : Resistencia del rotor.

$X_2$ : Reactancia de dispersión del rotor.

$R_{22}$ : Resistencia del rotor de secuencia negativa.

$X_{22}$ : Reactancia de dispersión del rotor de secuencia negativa

Para el estado balanceado, sólo se estiman 6 parámetros. El cromosoma está definido por:

- *Cromosoma para el Estado Desbalanceado:*

*[rs, X1, Rm, Xm, R2, X2]*

La codificación utilizada es la real, los parámetros operacionales son variables continuas. En la población inicial generada aleatoriamente, los valores se inician en el rango entre 0 y 1.

Se utilizará la estructura y codificación de los cromosomas utilizados en el Diseño 0 para las futuras experimentaciones.

#### **2.4.2 Población.**

Debido a que teóricamente los AGs son capaces de encontrar óptimos globales, en problemas de optimización es importante que la población inicial contenga individuos con material genético de buena calidad. En la mayoría de las aplicaciones de AGs, la población inicial se genera aleatoriamente. En el Diseño 0, la población inicial se construye heurísticamente implantando repetidamente en la misma, un individuo que constituye una solución aproximada del problema. Aunque esto no es determinante, ya que el elitismo empleado garantiza que sólo se conserven en la próxima generación los dos mejores individuos encontrados.

El tamaño de la población (número de individuos) afecta la solución del AG y la eficiencia de la simulación. Una gran población casi siempre está asociada con un tiempo de la simulación más largo, que influye en la razón de convergencia. Con una población pequeña, se corre el riesgo de converger a un óptimo local.

Ya una vez terminada la primera iteración, se construye la nueva población con los individuos que pasaron directamente mediante el elitismo de la generación anterior, sumados a los individuos que salieron de los operadores de cruzamiento y mutación.

Para construir la población inicial, de tamaño 100, se introduce un vector de impedancias (cromosoma) aproximadas, ubicando dicho vector cada 10 individuos y se completa la población de forma aleatoria.

Para determinar si el tamaño de población definido en el Diseño 0 debe considerarse, se desarrollaron experimentos variando el tamaño de población. Se analizó el tiempo, el error y la eficiencia estimada; esta última determinada de antemano por experimentos en laboratorios con un valor de 87.52.

La población se varió como sigue:

- Población de 16 individuos.
- Población de 30 individuos.
- Población de 50 individuos.
- Población de 80 individuos.
- Población de 100 individuos.

Se utilizó la herramienta MATLAB para el análisis del rendimiento del Diseño 0 con los 5 tamaños de poblaciones. Para cada uno se realizaron 4 corridas. A continuación, se muestra la mejor de cada una de ella.

**Población de 16 individuos.**

Tiempo de corrida 16.094158 segundos.

Eficiencia estimada = 88.59

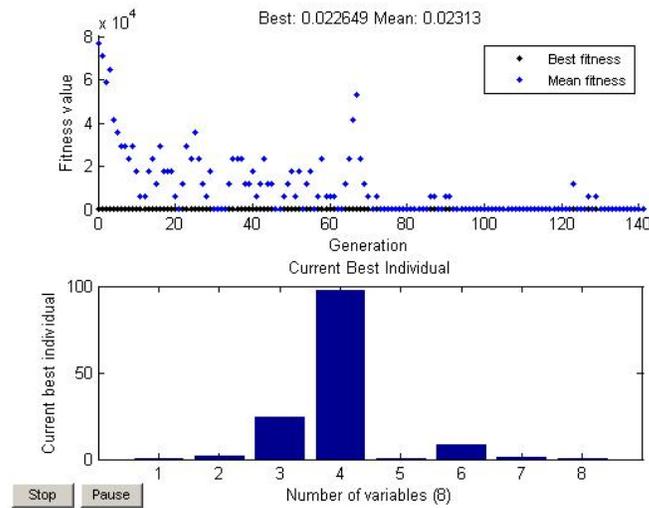


Figura 2: Resultados del Diseño 0 con población de 16 individuos.

### Población de 30 individuos.

Tiempo de corrida 20.490741 segundos.

Eficiencia estimada = 88.33

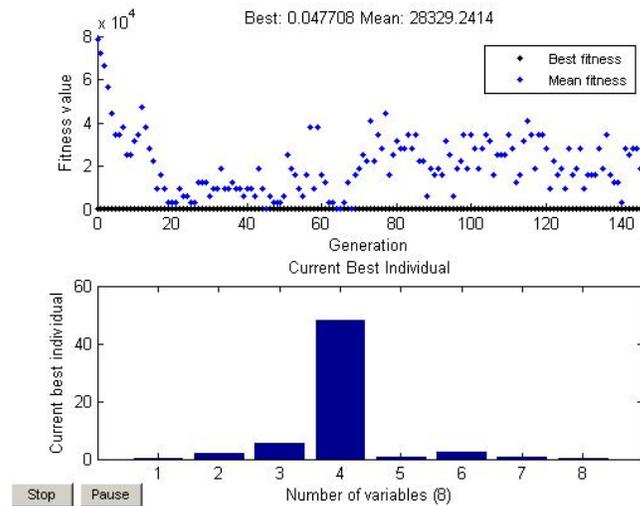


Figura 3: Resultados del Diseño 0 con población de 30 individuos.

### Población de 50 individuos.

Tiempo de corrida 31.294798 segundos.

Eficiencia estimada = 88.13

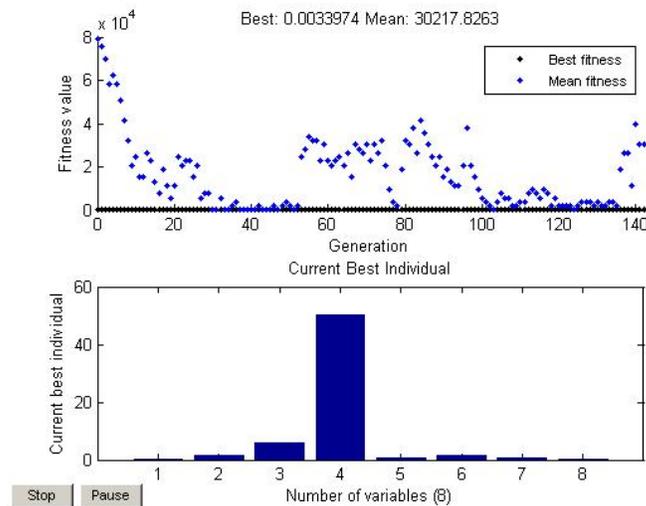


Figura 4: Resultados del Diseño 0 con población de 50 individuos.

**Población de 80 individuos.**

Tiempo de corrida 31.617887 segundos.

Eficiencia estimada = 88.48

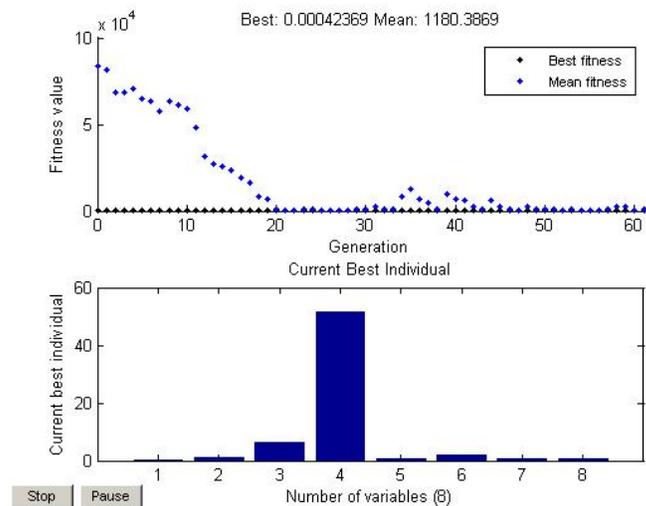


Figura 5: Resultados del Diseño 0 con población de 80 individuos.

### Población de 100 individuos.

Tiempo de corrida 25.693084 segundos.

Eficiencia estimada = 87.92

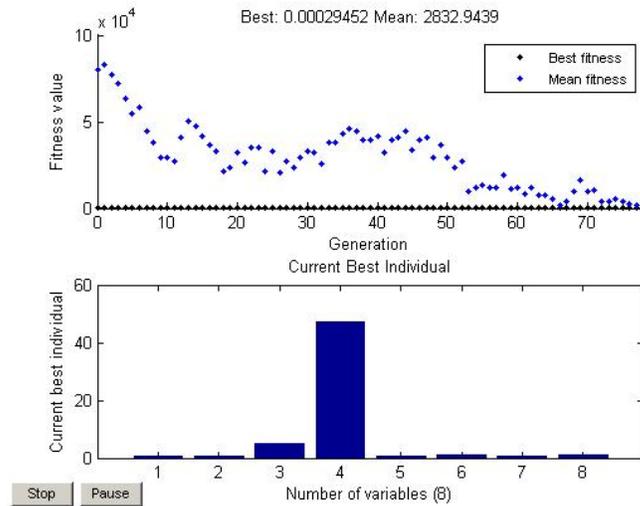


Figura 6: Resultados del Diseño 0 con población de 100 individuos.

Con 100 individuos en la población, se tiene el menor error y la eficiencia estimada es la más cercana a la real. Además, el tiempo no difiere mucho de las poblaciones con menores tiempos que ella, de 16 y 30 individuos. Se utilizará este tamaño de población para los futuros diseños.

#### 2.4.3 Función de aptitud empleada.

La función de aptitud juega un papel fundamental en la clasificación potencial de las soluciones en términos de sus características; es el criterio de optimización y evaluación de la calidad de los individuos. Se desarrolla a partir de los valores del fenotipo y da como resultado la calidad o aptitud del individuo.

El objetivo del AG es minimizar los errores entre los valores medidos y calculados de potencia eléctrica de entrada y corrientes de línea para el estado de carga

considerado, lo que implica que los parámetros identificados solo sean representativos de la operación del motor en este estado.

Se utiliza como restricción adicional las pérdidas rotacionales. Esto básicamente constituye un problema de optimización. Por lo tanto, las funciones de error que se emplean en el AG, cada una de las cuales constituye una función objetivo, son las siguientes:

$$f_1 = (I_{aCalc} - I_{aMed})/I_{aMed}$$

$$f_2 = (I_{bCalc} - I_{bMed})/I_{bMed}$$

$$f_3 = (I_{cCalc} - I_{cMed})/I_{cMed}$$

$$f_4 = (P_{inCalc} - P_{inMed})/P_{inMed}$$

$$f_5 = (P_{fbcCalc} - P_{fbcEst})/P_{fbcEst}$$

Donde:

$I_{aCalc}$ ,  $I_{bCalc}$ ,  $I_{cCalc}$  : Son las tres corrientes de línea calculadas para cada individuo de la población, en A.

$I_{aMed}$ ,  $I_{bMed}$ ,  $I_{cMed}$  : Son las corrientes medidas para el estado de carga analizado, en A.

$P_{inCalc}$  : Es la potencia eléctrica de entrada calculada, en W.

$P_{inMed}$  : Es la potencia eléctrica de entrada medida, en W.

$P_{fbcCalc}$  : Pérdidas de fricción, batimiento y núcleo calculadas, en W.

$P_{fbcEst}$  : Pérdidas de fricción, batimiento y núcleo estimadas o medidas en el caso de que esto sea posible, en W.

Y la función de aptitud a minimizar es:

$$error = \sum_{i=1}^5 |f_i|$$

El cálculo del error se repite para cada nuevo individuo (nuevo conjunto de parámetros del circuito equivalente del motor) hasta que se cumplen los requisitos de parada del AG.

Como se conoce, el algoritmo va obteniendo progresivamente mejores soluciones y detiene la búsqueda cuando cumple los requerimientos de parada. Como criterio de parada un *error* con un valor de  $1 \times 10^{-3}$ , o sea, cada corrida cesa cuando el valor de la función de aptitud del mejor individuo está por debajo de este valor. Esto significa convergencia y obtención de parámetros del modelo que garantizan un error prácticamente igual a cero de los valores de corrientes y potencias calculados con relación a los valores de referencia.

También el algoritmo se detiene cuando llega a un total de 500 generaciones y no ha encontrado un error que cumpla el criterio anterior.

La penalización se aplica de manera estricta para manejar la situación cuando algún gen no cumpla alguna condición específica. Esta técnica convierte el problema original en un problema sencillo, castigando las violaciones de las condiciones especificadas como restricciones.

El método de penalización es simple en su concepto y aplicación. En el caso de este trabajo, es posible que aparezcan conjuntos de combinaciones en las cuales existan valores de impedancias negativos. Estos constituyen individuos no factibles o ilegales que deben ser desechados, pues no tienen sentido físico. Para manejar estos individuos se penaliza la función de aptitud cuando encuentre valores de reactancia o resistencia negativas en el modelo.

La penalización consiste en asignar valores extremadamente altos a las corrientes de línea y a la potencia calculada si algún elemento  $i$  del cromosoma  $k$  es  $< 0$  ( $y(i, k) \leq 0$ ), lo cual hace que la función de error se aleje del mínimo. Además, el conocimiento previo del modelo dicta que se especifique también el cumplimiento de que:

*Modelo Balanceado*

- $rs \leq y(1, k) \leq rsh$
- $y(4, k) \leq (3,5 \times Zb)$
- $y(7, k) > y(5, k)$
- $y(8, k) < y(6, k)$
- $y(2, k) \geq y(6, k)$

#### *Modelo Desbalanceado*

- $rs \leq y(1, k) \leq rsh$
- $y(4, k) \leq (3,5 \times Zb)$
- $y(2, k) \geq y(6, k)$

donde:

$rs$  y  $rsh$  son las resistencias de fase del estator sin y con corrección por temperatura, respectivamente, de acuerdo a la clase de aislamiento del motor.

$Zb$  es la impedancia base, definida como la relación entre la tensión y corriente nominal de fase del motor.

Las anteriores consideraciones se mantendrán para la experimentación con otros diseños.

#### **2.4.4 Operadores genéticos.**

En los diseños propuestos se trabajará con los siguientes operadores genéticos:

*Operador elitista:* Este operador conserva las mejores soluciones encontradas, manteniendo un grupo de ellas en la próxima generación. Esta permanencia asegura que la mejor solución no se pierda cuando se pasa de una generación a otra.

*Operador de selección:* Este operador aporta a la técnica de búsqueda mayor potencia y robustez.

*Fracción de cruzamiento:* Especifica qué fracción de la próxima generación, que no sean los individuos élites, son obtenidos por cruzamiento.

*Operador de cruzamiento:* Las opciones de cruzamiento especifican cómo el algoritmo genético combina a dos individuos, o padres, para crear un nuevo individuo para la próxima generación.

*Fracción de mutación:* Especifica qué fracción del cromosoma va a mutar, variando los individuos obtenidos del cruzamiento.

*Operador de mutación:* El propósito de la mutación es introducir una perturbación ligera para aumentar la diversidad de individuos después del cruzamiento, previniendo a los individuos de aglomerarse y causar convergencia prematura de solución.

## **2.5 Herramientas utilizadas.**

Debido a la robustez y confianza que brinda el MATLAB, se seleccionó dicha aplicación para comprobar y comparar cada diseño propuesto, además, la decisión estuvo determinada por el paquete de herramientas dedicadas a AGs con que cuenta. Se seleccionó STATGRAPHICS, para estudiar estadísticamente los resultados obtenidos de los nuevos diseños y compararlos de acuerdo a la potencia de salida, el error y la eficiencia estimada y el tiempo, con el diseño propuesto por el CEEMA.

## **2.6 Conclusiones.**

Los AGs han sido ampliamente utilizados en la estimación de parámetros operacionales para el cálculo de la eficiencia energética de motores. El método propuesto por el CEEMA utiliza un AG (Diseño 0) para dicho propósito. Con este último se comprobó que el diseño y codificación de los cromosomas, el tamaño de población y la función de adaptabilidad definidos son correctos. Para la

determinación de nuevos diseños de AGs a compararse con el Diseño 0, se determinó variar sólo los tipos de selección, cruzamiento, mutación y los parámetros probabilísticos.

## Capítulo 3: Análisis de los resultados.

### 3.1 Introducción.

En el presente capítulo se proponen cinco diseños de AGs, variando los operadores genéticos y los parámetros probabilísticos. Se realiza una comparación del mejor diseño propuesto con el implementado por el CEEMA, utilizando para ello pruebas de hipótesis de las medias de cada muestra. Además, se describe la implementación del AG finalmente seleccionado.

### 3.2 Propuestas de diseños.

El algoritmo genético propuesto por el CEEMA (Diseño 0) está diseñado como sigue: el operador de selección es Estocástica con selección de los dos mejores individuos utilizando Elitismo; el operador de cruzamiento es Heurístico y la mutación Uniforme; la probabilidad de cruzamiento es igual a 0,8 y la de mutación, 0,01. La población la componen 100 individuos.

Para lograr mejores rendimientos, se emplearon 5 diseños diferentes de AGs (ver Tabla 1), variando los operadores de selección, cruzamiento y mutación y las probabilidades de cruzamiento y de mutación. Se escogieron los más utilizados tanto en MATLAB, como los que gozaban de mejor resultados en la práctica:

	Diseño 1	Diseño 2	Diseño 3	Diseño 4	Diseño 5
<b>Selección</b>	Ruleta	Remainder	Torneo	Ruleta	Torneo
<b>Cruzamiento</b>	Un Punto	Heurística	Heurística	Heurística	Dos Puntos
<b>Probabilidad</b>	0.7, 0.75 y				
<b>Cruzamiento</b>	0.8	0.8	0.8	0.8	0.8
<b>Mutación</b>	Uniforme	Uniforme	Uniforme	Gaussiana	Uniforme

<b>Probabilidad</b>	0.01, 0.05	0.01, 0.05	0.01, 0.05	0.01, 0.05	0.01, 0.05
<b>Mutación</b>	y 0.1				

Tabla 1: Operadores y parámetros probabilísticos de los diseños propuestos.

### ***3.3 Comparación de los resultados arrojados por los diseños propuestos.***

Para cada diseño y juegos de parámetros, se realizaron diez corridas los resultados arrojados se muestran en los Anexos. En las tablas siguientes (Tabla 2, 3, 4, 5, 6) se muestran los diseños propuestos, y el análisis se realiza para dos tipos de estados del motor: si el modelo es balanceado o si es desbalanceado, la probabilidad de cruzamiento y mutación empleadas, los valores de eficiencia y potencia de salida estimados y los obtenidos experimentalmente, así como la diferencias entre los mismos.

Debe analizarse la eficiencia de la estimación de parámetros operacionales que arrojan los diseños, atendiendo a las diferencias entre la eficiencia y la potencia de salida estimadas y la eficiencia y la potencia de salida obtenidas experimentalmente en laboratorio. La función de aptitud se construye a partir del error entre las magnitudes de entrada medidas y las estimadas por el modelo. Lo anterior puede conducir a una solución matemática muy buena, pero la estimación de la salida del motor alejarse de los valores experimentales utilizados en la validación del procedimiento; por ende, la estimación de la salida tiene mayor importancia que el mismo valor del error obtenido.

A continuación se muestran las tablas con los diseños propuestos, la variación de los parámetros probabilísticos, los valores experimentales obtenidos en laboratorio y las medias obtenidas de la estimación de la potencia de salida y de la eficiencia, así como sus diferencias con las experimentales. En los Anexos se muestra el resultado de las 10 corridas realizadas.

	Eficiencia Experimental	Potencia Experimental	Potencia Salida Estimada	Eficiencia Estimada	Error	Diferencia Eficiencia	Diferencia Potencia
<b>Diseño 1</b>	<b>Estado del Motor Balanceado</b>				<b>Pc= 0,7 y Pm= 0,01</b>		
<b>Media</b>	87,68	19 097,04	21 636,73	92,46	0,84	4,78	2 539,69
	<b>Estado del Motor Balanceado</b>				<b>Pc= 0,75 y Pm= 0,05</b>		
<b>Media</b>	87,68	19 097,04	21 683,21	92,34	0,77	4,66	2 586,17
	<b>Estado del Motor Balanceado</b>				<b>Pc= 0,8 y Pm= 0,1</b>		
<b>Media</b>	87,68	19 097,04	21 996,59	92,48	0,70	4,80	2 899,55
	<b>Estado del Motor Desbalanceado</b>				<b>Pc= 0,7 y Pm= 0,01</b>		
<b>Media</b>	87,52	18 939,04	21790,25	91,81	0,86	4,29	2 851,21
	<b>Estado del Motor Desbalanceado</b>				<b>Pc= 0,75 y Pm= 0,05</b>		
<b>Media</b>	87,52	18 939,04	20 942,35	91,84	0,77	4,32	2 003,31
	<b>Estado del Motor Desbalanceado</b>				<b>Pc= 0,8 y Pm= 0,1</b>		
<b>Media</b>	87,52	18 939,04	21 418,07	91,83	0,76	4,31	2 479,03

Tabla 2: Medias de la eficiencia y de la potencia de salida estimadas y del error del Diseño 1.

	Eficiencia Experimental	Potencia Experimental	Potencia Salida Estimada	Eficiencia Estimada	Error	Diferencia Eficiencia	Diferencia Potencia
<b>Diseño 2</b>	<b>Estado del Motor Balanceado</b>				<b>Pc= 0,7 y Pm= 0,01</b>		
<b>Media</b>	87,68	19 097,04	19 347,63	88,35	0,00	0,67	250,59
	<b>Estado del Motor Balanceado</b>				<b>Pc= 0,75 y Pm= 0,05</b>		
<b>Media</b>	87,68	19 097,04	19 164,53	88,26	0,00	0,58	67,48
	<b>Estado del Motor Balanceado</b>				<b>Pc= 0,8 y Pm= 0,1</b>		
<b>Media</b>	87,68	19 097,04	19 194,00	88,11	0,00	0,43	96,96
	<b>Estado del Motor Desbalanceado</b>				<b>Pc= 0,7 y Pm= 0,01</b>		
<b>Media</b>	87,52	18 939,04	18 989,89	88,21	0,00	0,69	50,85
	<b>Estado del Motor Desbalanceado</b>				<b>Pc= 0,75 y Pm= 0,05</b>		
<b>Media</b>	87,52	18 939,04	19 208,29	88,07	0,00	0,55	269,25
	<b>Estado del Motor Desbalanceado</b>				<b>Pc= 0,8 y Pm= 0,1</b>		
<b>Media</b>	87,52	18 939,04	19208,29	88,07	0,00	0,73	318,63

Tabla 3: Medias de la eficiencia y de la potencia de salida estimadas y del error del Diseño 2.

	Eficiencia Experimental	Potencia Experimental	Potencia Salida Estimada	Eficiencia Estimada	Error	Diferencia Eficiencia	Diferencia Potencia
<b>Diseño 3</b>	<b>Estado del Motor Balanceado</b>				<b>Pc= 0,7 y Pm= 0,01</b>		
<b>Media</b>	87,68	19 097,04	18 095,33	88,54	0,25	0,86	1 001,71
	<b>Estado del Motor Balanceado</b>				<b>Pc= 0,75 y Pm= 0,05</b>		
<b>Media</b>	87,68	19 097,04	18 242,06	88,28	0,10	0,59	854,98
	<b>Estado del Motor Balanceado</b>				<b>Pc= 0,8 y Pm= 0,1</b>		
<b>Media</b>	87,68	19 097,04	18 655,31	88,40	0,24	0,72	441,73
	<b>Estado del Motor Desbalanceado</b>				<b>Pc= 0,7 y Pm= 0,01</b>		
<b>Media</b>	87,52	18 939,04	18 519,87	88,79	0,35	1,27	419,17
	<b>Estado del Motor Desbalanceado</b>				<b>Pc= 0,75 y Pm= 0,05</b>		
<b>Media</b>	87,52	18 939,04	18 524,20	88,87	0,45	1,35	414,84
	<b>Estado del Motor Desbalanceado</b>				<b>Pc= 0,8 y Pm= 0,1</b>		
<b>Media</b>	87,52	18 939,04	17 923,69	88,06	0,26	0,54	1 015,35

Tabla 4: Medias de la eficiencia y de la potencia de salida estimadas y del error del Diseño 3.

	Eficiencia Experimental	Potencia Experimental	Potencia Salida Estimada	Eficiencia Estimada	Error	Diferencia Eficiencia	Diferencia Potencia
<b>Diseño 4</b>	<b>Estado del Motor Balanceado</b>				<b>Pc= 0,7 y Pm= 0,01</b>		
<b>Media</b>	87,68	19 097,04	21 724,32	92,20	0,85	4,68	2 785,28
	<b>Estado del Motor Balanceado</b>				<b>Pc= 0,75 y Pm= 0,05</b>		
<b>Media</b>	87,68	19 097,04	21 755,08	92,29	0,65	4,61	2 658,04
	<b>Estado del Motor Balanceado</b>				<b>Pc= 0,8 y Pm= 0,1</b>		
<b>Media</b>	87,68	19 097,04	22 170,03	92,27	0,70	4,59	3 072,99
	<b>Estado del Motor Desbalanceado</b>				<b>Pc= 0,7 y Pm= 0,01</b>		
<b>Media</b>	87,52	18 939,04	21 724,32	92,20	0,85	4,68	2 785,28
	<b>Estado del Motor Desbalanceado</b>				<b>Pc= 0,75 y Pm= 0,05</b>		
<b>Media</b>	87,52	18 939,04	21 310,94	92,11	0,79	4,59	2 371,90
	<b>Estado del Motor Desbalanceado</b>				<b>Pc= 0,8 y Pm= 0,1</b>		
<b>Media</b>	87,52	18 939,04	21 112,17	92,21	0,76	4,69	2 173,13

Tabla 5: Medias de la eficiencia y de la potencia de salida estimadas y del error del Diseño 4.

	Eficiencia Experimental	Potencia Experimental	Potencia Salida Estimada	Eficiencia Estimada	Error	Diferencia Eficiencia	Diferencia Potencia
<b>Diseño 5</b>	<b>Estado del Motor Balanceado</b>				<b>Pc= 0,7 y Pm= 0,01</b>		
<b>Media</b>	87,68	19 097,04	21 186,12	92,26	0,83	4,58	2 089,08
	<b>Estado del Motor Balanceado</b>				<b>Pc= 0,75 y Pm= 0,05</b>		
<b>Media</b>	87,68	19 097,04	21 946,50	92,31	0,69	4,63	2 849,46
	<b>Estado del Motor Balanceado</b>				<b>Pc= 0,8 y Pm= 0,1</b>		
<b>Media</b>	87,68	19 097,04	21 936,21	92,32	0,70	4,63	2 839,17
	<b>Estado del Motor Desbalanceado</b>				<b>Pc= 0,7 y Pm= 0,01</b>		
<b>Media</b>	87,52	18 939,04	21 050,69	92,18	0,81	4,66	2 111,65
	<b>Estado del Motor Desbalanceado</b>				<b>Pc= 0,75 y Pm= 0,05</b>		
<b>Media</b>	87,52	18 939,04	21 169,27	92,08	0,78	4,56	2 230,23
	<b>Estado del Motor Desbalanceado</b>				<b>Pc= 0,8 y Pm= 0,1</b>		
<b>Media</b>	87,52	18 939,04	21 438,70	92,08	0,78	4,56	2 499,66

Tabla 6: Medias de la eficiencia y de la potencia de salida estimadas y del error del Diseño 5.

Para el análisis comparativo entre los diferentes diseños, se utilizaron auxiliariamente los gráficos siguientes:

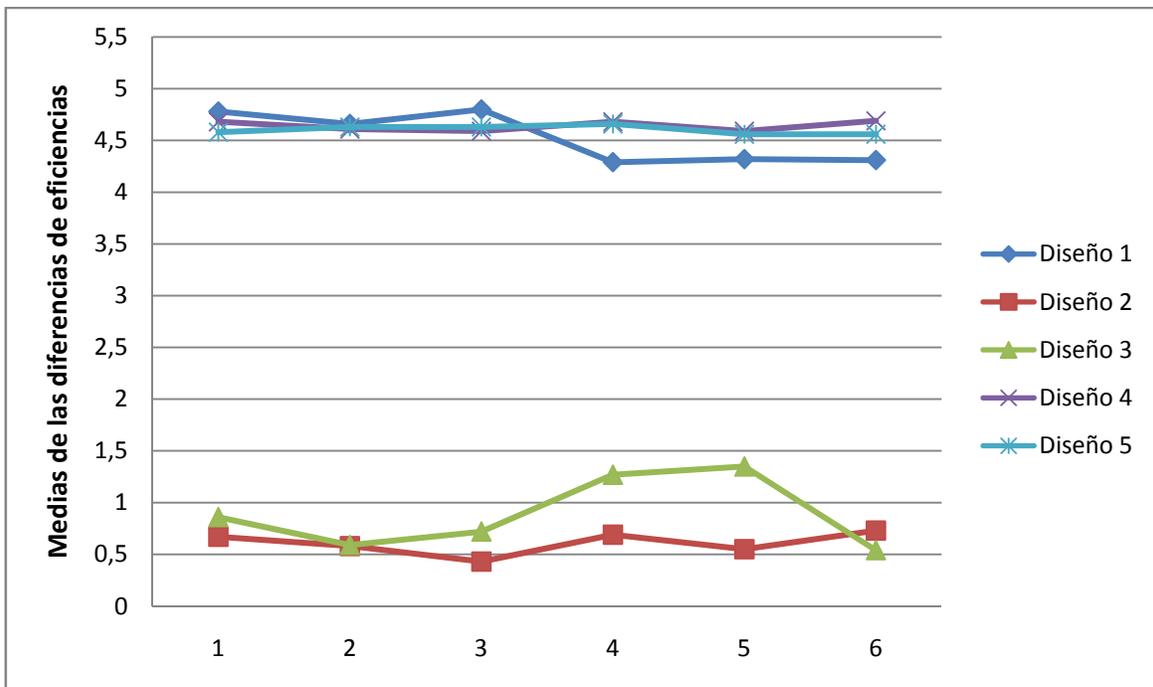
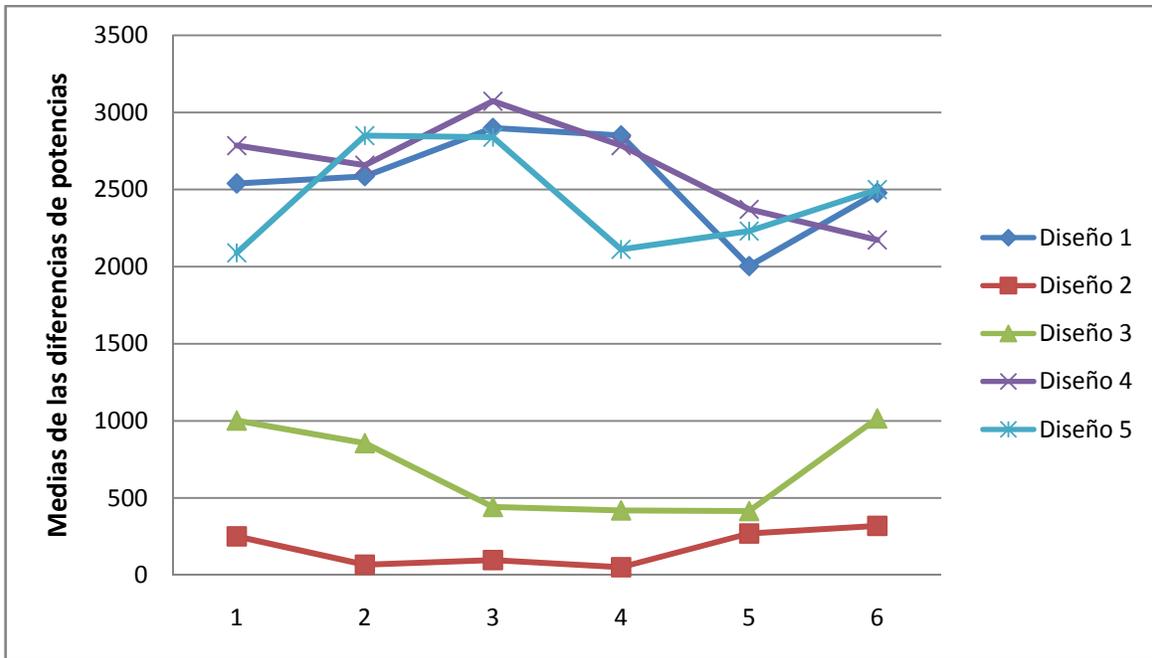
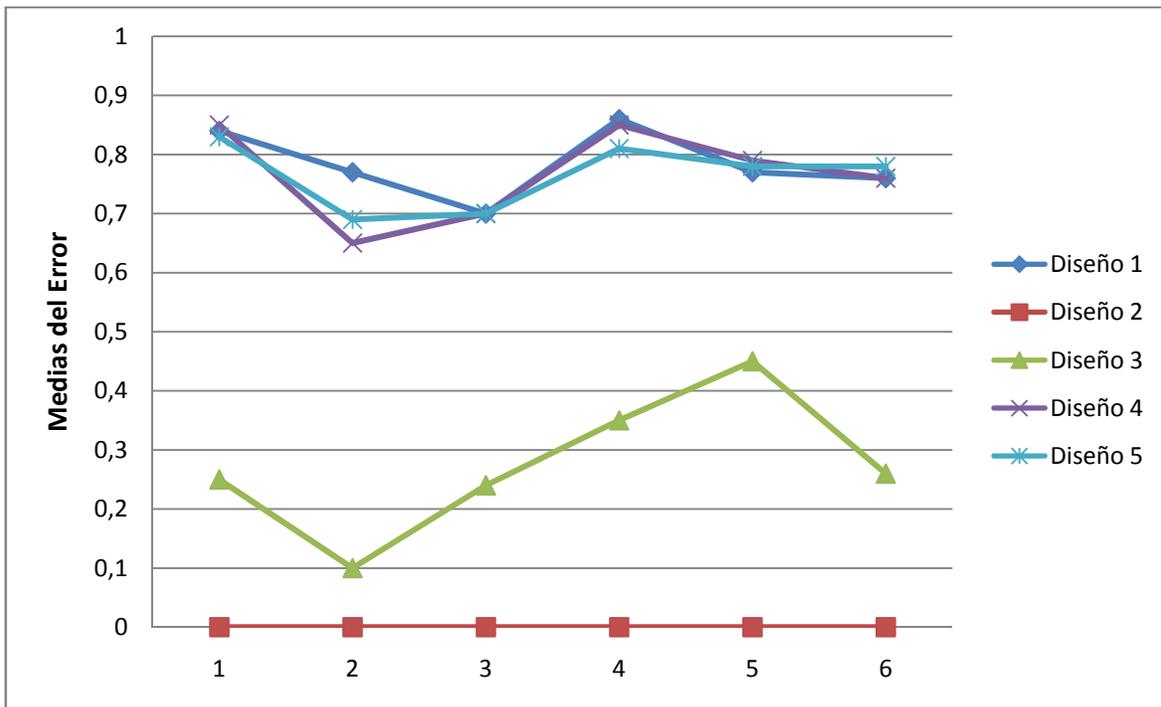


Figura 7: Gráfica comparativa entre las diferencias de eficiencias, estimada y experimental, de los diseños.



**Figura 8:** Gráfica comparativa entre las diferencias de potencias de salida, estimada y experimental, de los diseños.



**Figura 9:** Gráfica comparativa entre los errores de los diseños (aproximados a dos lugares después de la coma).

Es fácil comprobar, a partir de los resultados expuestos anteriormente, que el mejor diseño es el número 2. Se decidió fijar los parámetros probabilísticos  $P_c = 0,75$  y  $P_m = 0,05$ .

### **3.4 Comparación entre los resultados arrojados por el Diseño 2 y el Diseño 0.**

El diseño seleccionado, Diseño 2 y el propuesto por el CEEMA, Diseño 0, se compararon con 8 mediciones experimentales obtenidas en laboratorios. Para cada diseño, se comparan las estimaciones de la potencia de salida (P. Salida') y de la eficiencia (Eficiencia') resultadas del AG, con las obtenidas en el laboratorio (P. Salida y Eficiencia), calculándose la diferencia entre ellas (DPS y DE); además se tuvo en cuenta el valor del error (Error).

Diseño 0							
Estado	Error	P. Salida'	Eficiencia'	P. Salida	Eficiencia	DPS	DE
1	0,00023712	19337,42	88,38	19097,04	87,68	240,38	0,70
2	0,0001564	19397,39	88,25	18939,04	87,52	458,35	0,73
3	0,00491692	11473,16	85,44	11188,31	84,59	284,85	0,85
4	0,00029896	14820,26	87,48	14614,51	86,26	205,75	1,22
5	0,0419786	23189,29	89,07	22765,91	87,44	423,38	1,63
6	0,00090701	8715,84	82,96	8788,57	83,36	72,73	0,40
7	0,0049608	17336,99	87,91	17051,4	86,45	285,59	1,46
8	0,06644	21640,39	88,87	21251,99	87,29	388,40	1,58

**Tabla 7:** Diferencias entre las estimaciones del Diseño 0 y los datos experimentales.

Diseño 2							
Estado	Error	P. Salida'	Eficiencia'	P. Salida	Eficiencia	DPS	DE
1	0,000206	19181,19	88,07	19097,04	87,68	84,15	0,39
2	0,00013654	19120,15	87,81	18939,04	87,52	181,11	0,29
3	0,00025585	11327,97	85,35	11188,31	84,59	139,66	0,76
4	0,0002622	14822,14	87,25	14614,51	86,26	207,63	0,99
5	0,0442919	23099,42	88,69	22765,91	87,44	333,51	1,25
6	0,00013772	8763,42	83,13	8788,57	83,36	25,15	0,23
7	0,00018472	17246,93	87,75	17051,4	86,45	195,53	1,30
8	0,0752998	21478,17	88,62	21251,99	87,29	226,18	1,33

**Tabla 8:** Diferencias entre las estimaciones del Diseño 2 y los datos experimentales.

Se decidió comparar las medias de cada muestra de las diferencias de potencias de salida (DPS), de las diferencias de eficiencia (DE) y de los errores, de los Diseños 0 y 2. Para seleccionar la prueba de hipótesis, fue necesario comprobar el supuesto que las muestras siguen distribución Normal, utilizando para ello la prueba de Kolmogorov-Smirnov. Todo el análisis se realizó con la ayuda del STATGRAPHICS.

### 3.4.1 Comparación entre las diferencias de las potencias de salida.

#### Prueba de Kolmogorov-Smirnov.

- P-value = 0,0878776

Como el P-value es mayor que el nivel de significación (0.05), se acepta la hipótesis nula, las muestras DPS\_0 y DPS\_2 siguen una distribución Normal.

#### Prueba para la comparación de las Desviaciones Estándar.

- Planteamiento de las hipótesis:
  1. Hipótesis Nula: Desv. Est. DPS\_0 = Desv. Est. DPS\_2
  2. Hipótesis Alternativa: Desv. Est. DPS\_0  $\neq$  Desv. Est. DPS\_2

- Nivel de significación = 5%
- Análisis de los resultados de STATGRAPHICS:

Estadígrafo F = 1,83654

P-value = 0,441061

El P-value no es menor que el nivel de significación, por tanto no se puede rechazar la hipótesis nula. Se acepta que las desviaciones estándar de ambas muestras son iguales, con un 95% de nivel de confianza. Asumiendo varianzas iguales, se plantean las hipótesis para comparar las medias.

### **Prueba para la comparación de las Medias.**

- Planteamiento de las hipótesis:
  1. Hipótesis Nula: Media DPS\_0 = Media. DPS\_2
  2. Hipótesis Alternativa: Media DPS\_0 > Media DPS\_2
- Nivel de significación = 5%
- Análisis de los resultados de STATGRAPHICS:

Estadígrafo t = 2,16955

P-value = 0,023872

El P-value es menor que el nivel de significación, por tanto se rechaza la hipótesis nula y acepta la alternativa. Se acepta que la media DPS\_0 es mayor que la media DPS\_2, con un 95% de nivel de confianza.

### **3.4.2 Comparación entre las diferencias de la eficiencia.**

#### **Prueba de Kolmogorov-Smirnov.**

- P-value = 0,627167

Como el P-value es mayor que el nivel de significación (0.05), se acepta la hipótesis nula, las muestras DPS\_0 y DPS\_2 siguen una distribución Normal.

### Prueba para la comparación de las Desviaciones Estándar.

- Planteamiento de las hipótesis:
  1. Hipótesis Nula: Desv. Est. DE\_0 = Desv. Est. DE\_2
  2. Hipótesis Alternativa: Desv. Est. DE\_0  $\neq$  Desv. Est. DE\_2
- Nivel de significación = 5%
- Análisis de los resultados de STATGRAPHICS:

Estadígrafo F = 0,98445

P-value = 0,984038

El P-value no es menor que el nivel de significación, por tanto no se puede rechazar la hipótesis nula. Se acepta que las desviaciones estándar de ambas muestras son iguales, con un 95% de nivel de confianza. Asumiendo varianzas iguales, se plantean las hipótesis para comparar las medias.

### Prueba para la comparación de las Medias.

- Planteamiento de las hipótesis:
  1. Hipótesis Nula: Media DE\_0 = Media DE\_2
  2. Hipótesis Alternativa: Media DE\_0  $\neq$  Media DE\_2
- Nivel de significación = 5%
- Análisis de los resultados de STATGRAPHICS:

Estadígrafo t = 1,09272

P-value = 0,292964

El P-value no es menor que el nivel de significación, por tanto no se rechaza la hipótesis nula. Se acepta que las medias de ambas muestras son iguales, con un 95% de nivel de confianza.

### 3.4.3 Comparación entre los errores.

#### Prueba de Kolmogorov-Smirnov.

- P-value = 0,271006

Como el P-value es mayor que el nivel de significación (0.05), se acepta la hipótesis nula, las muestras Error\_0 y Error\_1 siguen una distribución Normal.

### **Prueba para la comparación de las Desviaciones Estándar.**

- Planteamiento de las hipótesis:
  1. Hipótesis Nula: Desv. Est. Error\_0 = Desv. Est. Error\_2
  2. Hipótesis Alternativa: Desv. Est. Error\_0  $\neq$  Desv. Est. Error\_2
- Nivel de significación = 5%
- Análisis de los resultados de STATGRAPHICS:

Estadígrafo F = 0,762534

P-value = 0,729649

El P-value no es menor que el nivel de significación, por tanto no se puede rechazar la hipótesis nula. Se acepta que las desviaciones estándar de ambas muestras son iguales, con un 95% de nivel de confianza. Asumiendo varianzas iguales, se plantean las hipótesis para comparar las medias.

### **Prueba para la comparación de las Medias.**

- Planteamiento de las hipótesis:
  1. Hipótesis Nula: Media DE\_0 = Media DE\_2
  2. Hipótesis Alternativa: Media DE\_0  $\neq$  Media DE\_2
- Nivel de significación = 5%
- Análisis de los resultados de STATGRAPHICS:

Estadígrafo t = -0,00812543

P-value = 0,993632

El P-value no es menor que el nivel de significación, por tanto no se rechaza la hipótesis nula. Se acepta que las medias de ambas muestras son iguales, con un 95% de nivel de confianza.

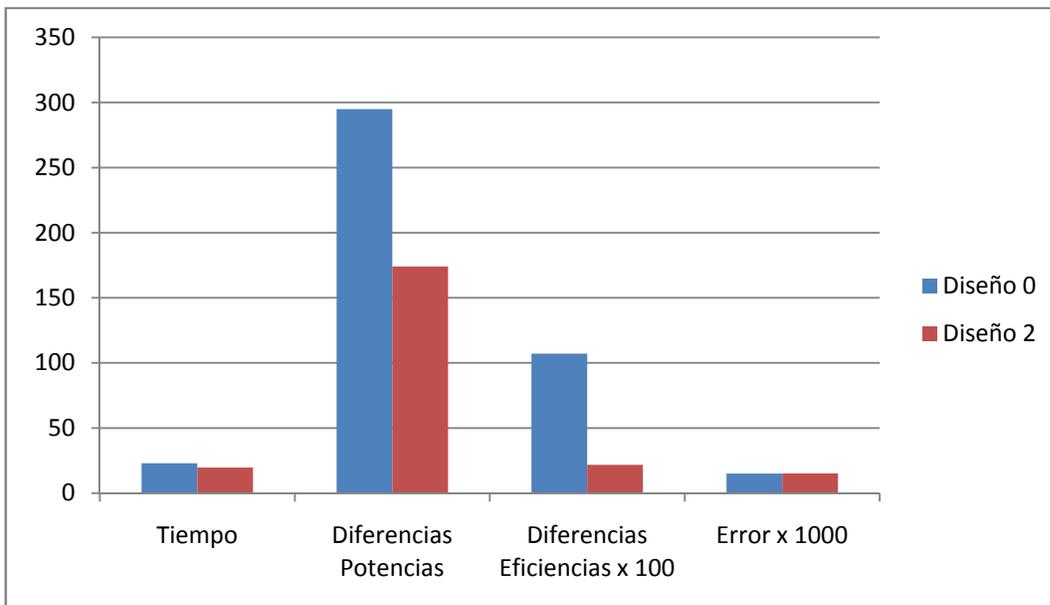
### 3.4.4 Comparación de los estadísticos descriptivos de las muestras.

En la siguiente tabla se muestran los valores de los estadísticos descriptivos de las muestras: tiempos en segundos ( $t_0$  y  $t_2$ ), diferencias entre las potencias estimadas y experimentales ( $DPS_0$  y  $DPS_2$ ), diferencias entre las eficiencias estimadas y experimentales ( $DE_0$  y  $DE_2$ ) y los errores ( $Error_0$  y  $Error_2$ ); tomadas de los Diseños 0 y 2. Estos valores fueron calculados con el programa estadístico STATGRAPHICS.

Muestras	$t_0$	$t_2$	$DPS_0$	$DPS_2$	$DE_0$	$DE_2$	$Error_0$	$Error_2$
Cantidad	8	8	8	8	8	8	8	8
Media	22,96	19,6788	294,929	174,115	1,0712	0,2173	0,01498	0,015097
Varianza	41,3029	2,94061	16061,8	8745,68	0,21401	0,21739	0,000633	0,000829
Desv. Est.	6,42673	1,71482	126,735	93,5183	0,46261	0,46625	0,025155	0,0288

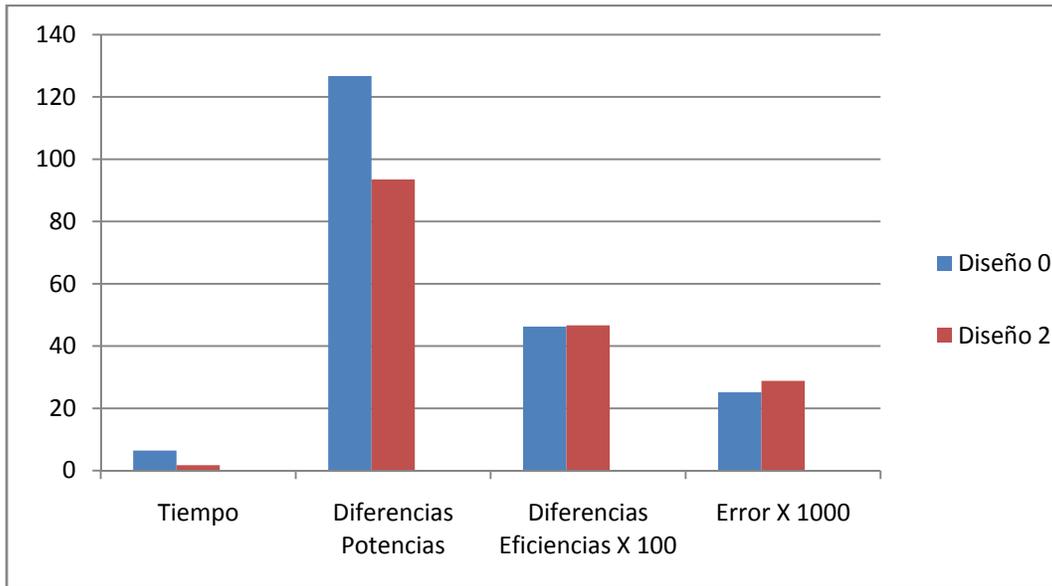
**Tabla 9:** Estadísticos descriptivos de muestras, con tamaño 8, analizadas.

La siguiente gráfica permite hacer un análisis de las medias de cada muestra.



**Figura 10:** Comparación gráfica de las medias de cada muestra.

Como se observa en la gráfica las muestras tomadas del Diseño 0, generalmente, tienen mayor media que las tomadas del Diseño 2. Sólo el error del Diseño 0 es menor que el error del Diseño 2 por milésimas.



**Figura 11:** Comparación gráfica de las desviaciones estándar de las muestras.

Tal como se observa en la gráfica de comparación de las desviaciones estándar de cada muestra, las desviaciones estándar de las muestras tiempo y diferencias entre potencias (experimental y estimada) del Diseño 2 son menores que las del Diseño 0. Para las otras muestras, diferencias entre potencias (experimental y estimada) y error, las desviaciones estándar de las muestras del Diseño 0 son ligeramente menor que las del 2.

### 3.4.5 Comparación de los tiempos.

A continuación, se muestra el valor del tiempo para los 8 estados de carga diferentes del motor en que se experimenta, el gráfico indica que los tiempos medidos para el Diseño 0 alcanza los valores mas elevados, solamente en dos puntos, el tiempo del Diseño 2 es ligeramente mayor al del Diseño 0. El Diseño 2,

tiene tiempos ligeramente menores el Diseño 0 y por tanto, el uso del procesador es menor.

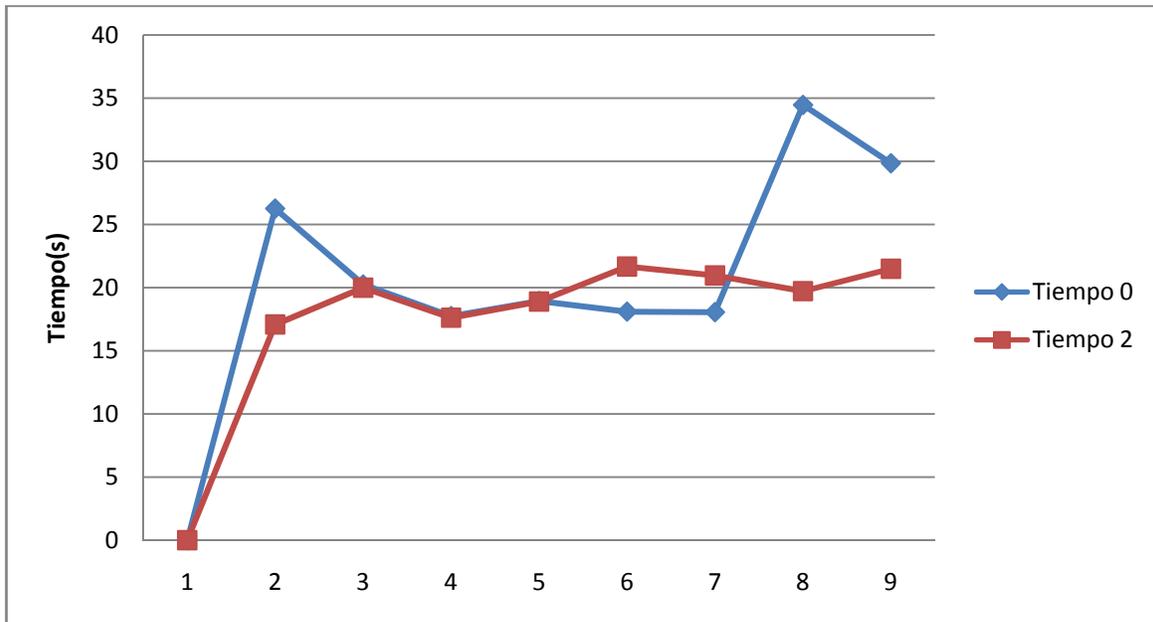


Figura 12: Comparación grafica del tiempo para diferentes estados del motor en ambos diseños.

### 3.4.6 Comparación del número de Generaciones.

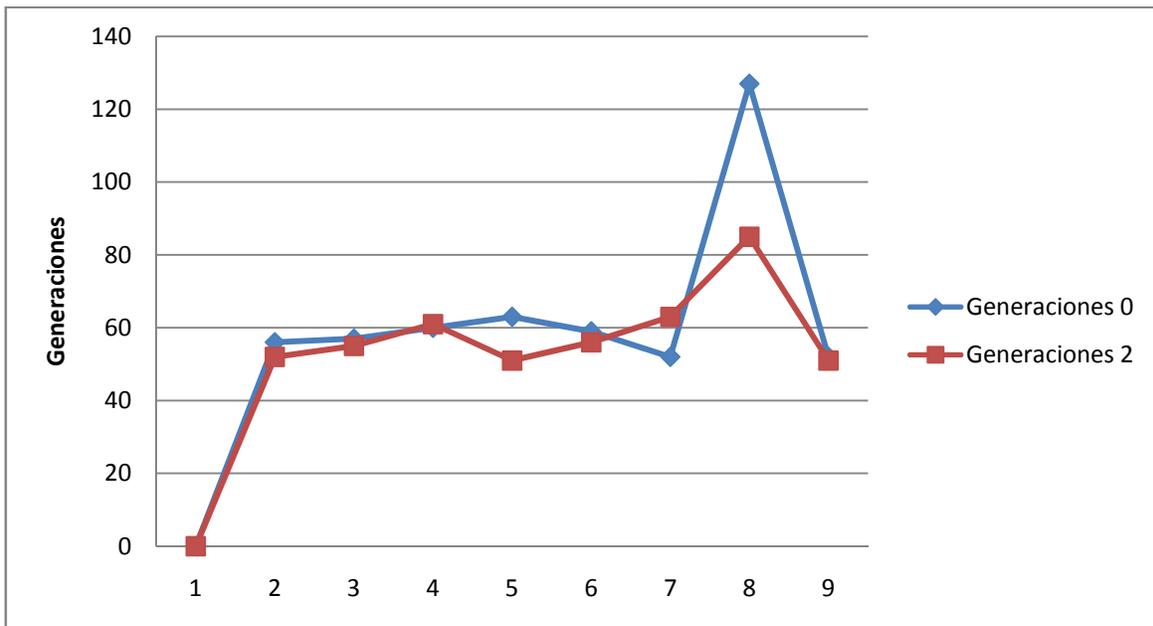


Figura 13: Comparación grafica del número de generaciones para diferentes estados del motor en ambos diseños.

Como se puede apreciar en la figura anterior, al Diseño 0 le toma en casi todos los estados analizados un mayor número de generaciones detener el AG, mientras que en el Diseño 2 el AG concluye con un número mejor de generaciones por lo que el tiempo es menor, como se analizó anteriormente.

### **3.5 Fundamentación del diseño seleccionado e implementación.**

El resultado de las comparaciones anteriores muestra que el Diseño 2 estima estadísticamente mejor las potencias de salida que el Diseño 0, con un 95% de confianza. No se pudo comprobar con igual nivel de confianza, que mejorar la estimación de la eficiencia y el error. En el análisis de los estadísticos descriptivos de muestras tomadas, con tamaño 8, del tiempo, de las diferencias de potencias y de eficiencias y del error, de los Diseños 0 y 2, el segundo muestra generalmente mejor comportamiento. Por lo anterior se decide entonces implementar el Diseño 2. La población será de 100 individuos, la  $Pc = 0.75$  y la  $Pm = 0.05$ , el tipo de selección Remainder, el cruzamiento por Heurística, y la mutación Uniforme.

A continuación se explica el funcionamiento de los operadores genéticos seleccionados.

#### **El operador de selección Remainder:**

Como su nombre lo indica el operador Remainder trabaja con restos. El mismo crea una nueva población donde almacenará los cromosomas seleccionados, estos pueden estar repetidos en dependencia de cuán buena es su función de aptitud. Se genera un coeficiente para cada individuo, mientras mejor es el individuo, más adaptado, mayor es el valor del coeficiente. La parte entera indica las veces que se insertará ese individuo en la nueva población, mientras que la parte fraccionaria indica la probabilidad de volver a insertarse una vez más.

#### **El operador de cruzamiento por Heurística:**

Este operador de cruzamiento escoge dos individuos en orden (1 y 2, 3 y 4, ..., n-1 y n) de la población intermedia, aplicándole la operación aritmética que se muestra

a continuación, utilizando dos padres, crea un nuevo individuo con características de ambos padres.

$$Child = Parent1 + ratio * (Parent2 - Parent1)$$

donde:

*Child*: es el individuo hijo.

*Parent1*: es el cromosoma padre de mejor función de aptitud.

*ratio*: es una constante definida por MATLAB como 1,5.

*Parent2*: es el otro cromosoma que interviene en el cruzamiento.

### **El operador de mutación Uniforme:**

Este operador analiza cada cromosoma a mutar, y analiza gen por gen, en caso de cumplirse que el número aleatorio creado para cada gen es menor que la  $P_m$ , entonces se modifica dicho gen de forma aleatorio siempre que esté dentro del rango posible de dicho gen.

Para la implementación se crearon varios métodos, con el propósito de que el trabajo no se tornara engorroso, estos son:

#### **StarGen ();**

Maneja todo el proceso del algoritmo.

#### **Populate ();**

Crea la población inicial.

#### **RePopulate ();**

Construye la población que irá a la siguiente generación.

#### **ParaSalud ();**

Calcula la función de adaptabilidad, el valor del error.

**SeleccionRemainder();**

Selecciona los individuos a intervenir en el cruzamiento y mutación.

**Cruzar ();**

Se efectúa el cruce entre dos padres.

**Mutar ();**

Se muta cada cromosoma uniformemente.

### **3.6 Conclusiones**

En este capítulo se obtiene un diseño suficientemente bueno, Diseño 2. Utilizando las pruebas realizadas con el software matemático estadístico STATGRAPHICS, se comprueba que su rendimiento con respecto al diseño creado por el CEEMA es mejor en cuanto a tiempo de ejecución, medias de la potencia de salida y de la eficiencia estimadas. La implementación del algoritmo en lenguaje C# introduce mejoras notables en cuanto a tiempo de uso del procesador.

## **Conclusiones.**

Con la realización de este trabajo se arribaron a las siguientes conclusiones:

- Se realiza una investigación en el campo de los Algoritmos Genéticos, ampliando los conocimientos de su funcionamiento y constatando las facilidades intrínsecas de su arquitectura para la estimación de parámetros operacionales de los motores eléctricos asíncronos.
- Se proponen cinco diseños diferentes de AGs, variando los operadores genéticos, así como los parámetros probabilísticos de cruzamiento y mutación.
- Se comparan los diseños propuestos utilizando para ello pruebas estadísticas, lo cual resultó en la selección del mejor diseño atendiendo a las medias de eficiencia y potencia de salida estimadas y al error.
- Se construye un AG más adecuado para la estimación de los parámetros operacionales, implementándose en lenguaje de programación C#, el cual constituye el núcleo del "Sistema informático para el cálculo de la eficiencia de los motores eléctricos asíncronos".

## **Recomendaciones.**

- Evaluar el rendimiento de las estimaciones del diseño propuesto utilizando para ello mayor cantidad de datos experimentales.
- Extender los resultados de la presente investigación, al análisis simultáneo de varios estados de carga del motor eléctrico asincrónico, siendo necesaria la reconstrucción la función de aptitud y el rediseño de los cromosomas.

## Referencias Bibliográficas.

1. **Darwin, C.** *On the Origin of Species by Means of Natural Selection.* London : s.n., 1859.
2. **Holland, J.** *Adaptation in Natural and Artificial Systems.* 1975.
3. **DAVIS, L.** *Handbook of Genetic Algorithm.* New York : s.n., 1991.
4. **Michalewicz, Z.** *Genetic Algorithms + Data Structures = Evolution Programs.* Berlín : s.n., 1992.
5. **Reeves, C.** *Modern Heuristic Techniques for Combinatorial Problems.* s.l. : Blackwell Scientific Publications, 1993.
6. **Parejo, Carmen Cortés.** *Algoritmos genéticos y problemas de visibilidad.* Sevilla : s.n., 1996.
7. **Goldberg, D.** *Genetics Algorithms in Search, Optimization and Machine Learning.* 1989.
8. **Koza, John R.** *Genetic Programming. On the Programming of Computers by Means of Natural Selection.* 1992.
9. **López, Ing. Jorge.** [Online] 1997.  
[www.grupoceca.info/Biblioteca/Memorias/C\\_Genetica.pdf](http://www.grupoceca.info/Biblioteca/Memorias/C_Genetica.pdf).
10. **Goldberg, D.** *Genetics Algorithms in Search, Optimization and Machine Learning.* 1989.  
p. 9.
11. **Alander, J.T.** *On optimal population size of genetic algorithms.* 1992. pp. 65-70.
12. **Goldberg, D E and Richardson, J T.** *Genetic algorithms with sharing for multimodal function optimization.* 1987.
13. **Golberg, D.E.** *Genetic Algorithms in Search Optimization, and machine Learning.* 1989.  
p. 12.
14. **Whitley, D.** *The GENITOR algorithm and selection pressure: Why rank based allocation of reproductive trials is best.* 1989. pp. 116-121.
15. **Ruiz, Rubén, Maroto, Concepción and Alvarez, Javier.** *New Genetic Algorithms for the Permutation Flowshop Scheduling Problem.* Valencia : s.n., 2003.
16. **Sandikci, Burhaneddin.** *Genetic Algorithms. Department of Industrial Engineering.* Ankara : s.n., 2000.

17. **Dipankar, Dasgupta and Zbigniew, Michalewicz.** *Evolutionary Algorithms in Engineering Applications.* 1997.
18. **Man, K F, Tang, K F and Kwong, S.** *Genetic Algorithms: Concepts and Designs.* London : s.n., 1999.
19. **Tekeshi, Yamada and Nakano, Ryohei.** *Genetic Algorithms for job-shop Scheduling Problems.* Kyoto : s.n., 1997.
20. **Ferreira, Candia.** *Combinatorial Optimization.* 2003.
21. **Davis, L.** *Applying adaptive algorithms to epistatic domains.* 1985. pp. 162-164.
22. **Schaffer, J D, et al.** *A study of control parameters affecting online performance of genetic algorithms for function optimization.* 1989. pp. 51-60.
23. **De JONG, K.** *An Analysis of the Behavior of a Class of Genetic Adaptive Systems.* University Microfilms. 1975.
24. **Jong, K.A. De.** *An analysis of the behavior of a class of genetic adaptive systems.* University of Michigan. 1975. Tesis Doctoral.
25. **Schaffer, J D, et al.** *A study of control parameters affecting online performance of genetic algorithms for function optimization.* 1989.
26. **Ackley, D.H.** *A Connectionist Machine for Genetic Hillclimbing.* 1987. pp. 100-107, Publicación.
27. **Fogarty, T.C.** *Varying the probability of mutation in the genetic algorithm.* 1989. pp. 104-109, Publicación.
28. **Michalewicz, Z and Janikow, C Z.** *Handling constraints in genetic algorithms.* 1991. pp. 151-157.
29. **Rudolph, G.** *Convergence analysis of canonical genetic algorithms.* 1994. pp. 269-288.
30. **Davis, T E and Principe, J C.** *A Markov chain framework for the simple genetic algorithm.* *Evolutionary.* 1993.
31. **Suzuki, J.** *A Markov chain analysis on simple genetic algorithms.* 1995. pp. 655-659.
32. **Liepins, G.E.** *On global convergence of genetic algorithms.* *Neural and Stochastic Methods in Image and Signal Processing.* 1992. pp. 61-65.

33. **Chakraborty, U K and Dastidar, D G.** *Using reliability analysis to estimate the number of generations to convergence in genetic algorithms.* 1993. pp. 199-209.
34. **Eiben, A E, Aarts, E HL and Van Hee, K M.** *Global convergence of genetic algorithms: An infinite Markov chain analysis.* Eindhoven University of Technology. 1990.
35. **D.E., Goldberg.** *Genetic Algorithms in Search, Optimization and Machine Learning.* 1989. p. 19.
36. **Haque, T., y col.** *Parameter determination for induction motors.* 1994. pp. 45-49.
37. **Nolan, R, Pillay, P and Haque, T.** *Application of genetic algorithms to motor parameter determination.* 1994. pp. 47-54.
38. **Nangsue, P, Pillay, P and Conry, S E.** *Evolutionary algorithms for induction motor parameter determination.* 199. pp. 447-453.
39. **Pillay, P, Nolan, R and Haque, T.** *Application of genetic algorithms to motor parameter determination for transient torque calculations.* 1997. 1273-1282.
40. **Pillay, P., y col.** *In-situ induction motor efficiency determination using the genetic algorithm.* 1998.
41. **Phumiphak, T and Chatuthai, C.** *Estimation of induction motor parameters based on field test coupled with genetic algorithm.* 2002. pp. 1119-1203.
42. **Gómez Saduy, Julio.** *Determinación de la Eficiencia de los Motores Asíncronos con Tensiones Desbalanceadas en Condiciones de Campo.* 2006. Tesis Doctoral.

## Bibliografía

1. **Genéticos, Algoritmos.** [En línea] 1998. <http://html.rincondelvago.com/algoritmos-geneticos.html>.
2. Algoritmos Genéticos. [En línea] <http://eddyalfaro.galeon.com/geneticos.html>.
3. **Marczyk, Adam.** Algoritmos genéticos y computación evolutiva. *Algoritmos genéticos y computación evolutiva*. [En línea] 2004. <http://the-geek.org/docs/algen>.
4. **Rocío, Rubén, Rossana, Rafael.** Algoritmos Genéticos. [En línea] 2002. <http://www.depi.itch.edu.mx/apacheco/expo/html/ai14/ga.html>.
5. **Reeves, C.** *Modern Heuristic Techniques for Combinatorial Problems*. s.l. : Blackwell Scientific Publications, 1993.
6. **Arias, Mario Alberto Villalobos.** *ALGORITMOS GENÉTICOS: ALGUNOS RESULTADOS DE CONVERGENCIA*. Departamento de Matemáticas. 2003. PDF.
7. **Pose, Marcos Gestal.** *Algoritmos Genéticos*. Tecnologías de la Información y las Comunicaciones. PDF.
8. **Moujahid, Abdelmalik, Inza, Iñaki y Larrañaga, Pedro.** *Algoritmos Genéticos*. Departamento de Ciencias de la Computación e Inteligencia Artificial. PDF.
9. **Rodríguez-Piñero, Piedad Tolmos.** *Introducción a los algoritmos genéticos y sus aplicaciones*. Madrid : s.n. PDF.
10. **Caballero Fernández, Rafael, y otros.** *Algoritmos genéticos para la resolución de problemas de Programación por Metas Entera. Aplicación a la Economía de la Educación*. Departamento de Economía Aplicada. Málaga : s.n. PDF.
11. **Jara, Rene, Omegna, Mitzi y Verdugo, Luis.** *Algoritmos Genéticos*. PDF.
12. **Liera, Marco Antonio Castro.** La Paz : s.n., 2007. PDF.

## Anexos:

ANEXO A: Corridas para el Diseño 1, en régimen Balanceado y Desbalanceado, variando las probabilidades de cruzamiento y mutación.

Diseño 1	Balanceado		0,7 y 0,01	87,68	19097,04
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
Corrida 1	22052,26	92,64	0,707349	4,96	2955,22
Corrida 2	18487,02	92,38	1,11784	4,70	610,02
Corrida 3	18672,78	92,37	1,09433	4,69	424,26
Corrida 4	22043,1	92,34	0,696906	4,66	2946,06
Corrida 5	22038,81	92,26	0,697765	4,58	2941,77
Corrida 6	22734,09	92,68	0,900652	5,00	3637,05
Corrida 7	22096,7	92,55	0,789292	4,87	2999,66
Corrida 8	22273,77	92,3	0,696751	4,62	3176,73
Corrida 9	23558,12	92,77	0,821028	5,09	4461,08
Corrida 10	22410,69	92,31	0,857097	4,63	3313,65

Diseño 1	Balanceado		0,75 y 0,05	87,68	19097,04
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
Corrida 1	20615,3	92,48	0,813527	4,80	1518,26
Corrida 2	21542,58	92,69	0,686929	5,01	2445,54
Corrida 3	22270,25	92,56	0,820654	4,88	3173,21
Corrida 4	21486,1	92,23	0,691295	4,55	2389,06
Corrida 5	22075,12	92,15	0,754625	4,47	2978,08
Corrida 6	21987,52	92,04	0,810142	4,36	2890,48
Corrida 7	22070,69	92,3	0,695491	4,62	2973,65
Corrida 8	21145,23	92,56	0,854621	4,88	2048,19
Corrida 9	22124,2	92,16	0,854628	4,48	3027,16
Corrida 10	21515,1	92,21	0,697513	4,53	2418,06

[ANEXOS]

<b>Diseño 1</b>	<b>Balanceado</b>		<b>0,8 y 0,1</b>	<b>87,68</b>	<b>19097,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	21479,28	92,69	0,691919	5,01	2382,24
<b>Corrida 2</b>	21343,78	92,68	0,702582	5,00	2246,74
<b>Corrida 3</b>	22073,49	92,28	0,714553	4,60	2976,45
<b>Corrida 4</b>	22338,34	92,64	0,696679	4,96	3241,30
<b>Corrida 5</b>	22451,23	92,45	0,714562	4,77	3354,19
<b>Corrida 6</b>	21895,17	92,05	0,685213	4,37	2798,13
<b>Corrida 7</b>	22184,8	92,63	0,707365	4,95	3087,76
<b>Corrida 8</b>	22459,35	92,2	0,665211	4,52	3362,31
<b>Corrida 9</b>	21458,21	92,56	0,699872	4,88	2361,17
<b>Corrida 10</b>	22282,2	92,65	0,692896	4,97	3185,16

<b>Diseño 1</b>	<b>Desbalanceado</b>		<b>0,7 y 0,01</b>	<b>87,52</b>	<b>18939,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	21337,84	91,77	0,713037	4,25	2398,80
<b>Corrida 2</b>	21082,78	92,06	0,828524	4,54	2143,74
<b>Corrida 3</b>	22134,52	92,39	0,917838	4,87	3195,48
<b>Corrida 4</b>	22046,8	92,15	0,924075	4,63	3107,76
<b>Corrida 5</b>	22124,29	90,12	0,856423	2,60	3185,25
<b>Corrida 6</b>	21456,24	91,64	0,892131	4,12	2517,20
<b>Corrida 7</b>	21458,13	92,01	0,856423	4,49	2519,09
<b>Corrida 8</b>	22567,12	92,56	0,775463	5,04	3628,08
<b>Corrida 9</b>	21631,25	91,21	0,900124	3,69	2692,21
<b>Corrida 10</b>	22063,48	92,2	0,914302	4,68	3124,44

<b>Diseño 1</b>	<b>Desbalanceado</b>		<b>0,75 y 0,05</b>	<b>87,52</b>	<b>18939,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	19889,62	92,1	0,822194	4,58	950,58
<b>Corrida 2</b>	21190,4	92,12	0,708704	4,60	2251,36
<b>Corrida 3</b>	20043,3	92,04	0,82162	4,52	1104,26
<b>Corrida 4</b>	20605,4	91,66	0,742393	4,14	1666,36
<b>Corrida 5</b>	19982,12	91,81	0,742153	4,29	1043,08
<b>Corrida 6</b>	21224,17	92,01	0,746215	4,49	2285,13
<b>Corrida 7</b>	21455,15	91,75	0,706046	4,23	2516,11
<b>Corrida 8</b>	22126,23	91,46	0,792645	3,94	3187,19
<b>Corrida 9</b>	21784,5	91,35	0,812642	3,83	2845,46
<b>Corrida 10</b>	21122,65	92,12	0,833495	4,60	2183,61

[ANEXOS]

<b>Diseño 1</b>	<b>Desbalanceado</b>	<b>0,8 y 0,1</b>	<b>87,52</b>	<b>18939,04</b>	
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	21956,68	91,84	0,718035	4,32	3017,64
<b>Corrida 2</b>	21751,41	91,01	0,798115	3,49	2812,37
<b>Corrida 3</b>	20403,04	92,07	0,817596	4,55	1464,00
<b>Corrida 4</b>	21076,2	91,81	0,719488	4,29	2137,16
<b>Corrida 5</b>	21546,23	91,82	0,784521	4,30	2607,19
<b>Corrida 6</b>	21035,1	91,9	0,745126	4,38	2096,06
<b>Corrida 7</b>	21228,16	92,23	0,71736	4,71	2289,12
<b>Corrida 8</b>	22034,19	92,05	0,742156	4,53	3095,15
<b>Corrida 9</b>	21759,18	91,79	0,812045	4,27	2820,14
<b>Corrida 10</b>	21390,49	91,81	0,703628	4,29	2451,45

[ANEXOS]

ANEXO B: Corridas para el Diseño 2, en régimen Balanceado y Desbalanceado, variando las probabilidades de cruzamiento y mutación.

Diseño 2	Balanceado		0,7 y 0,01	87,68	19097,04
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	19181,19	88,07	0,000206	0,39	84,15
<b>Corrida 2</b>	19181,03	88,03	0,00012329	0,35	83,99
<b>Corrida 3</b>	19316,51	88,51	0,00021049	0,83	219,47
<b>Corrida 4</b>	19231,45	88,16	0,0001253	0,48	134,41
<b>Corrida 5</b>	19523,1	88,56	0,0003216	0,88	426,06
<b>Corrida 6</b>	19426,35	88,79	0,0001425	1,11	329,31
<b>Corrida 7</b>	19458,31	88,35	0,00035812	0,67	361,27
<b>Corrida 8</b>	19095,16	88,17	0,00023417	0,49	1,88
<b>Corrida 9</b>	19721,12	88,34	0,00033214	0,66	624,08
<b>Corrida 10</b>	19342,11	88,5	0,00011675	0,82	245,07

Diseño 2	Balanceado		0,75 y 0,05	87,68	19097,04
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	19181,19	88,07	0,000206	0,39	84,15
<b>Corrida 2</b>	19181,03	88,03	0,00012329	0,35	83,99
<b>Corrida 3</b>	19202,23	88,16	0,0001205	0,48	105,19
<b>Corrida 4</b>	19164,33	88,09	0,0001325	0,41	67,29
<b>Corrida 5</b>	19105,28	88,24	0,00011457	0,56	8,24
<b>Corrida 6</b>	19110,31	88,15	0,0001224	0,47	13,27
<b>Corrida 7</b>	19351,24	88,01	0,00011275	0,33	254,20
<b>Corrida 8</b>	19086,39	88,21	0,0001366	0,53	10,65
<b>Corrida 9</b>	19122,11	88,64	0,0001911	0,96	25,07
<b>Corrida 10</b>	19141,14	89,01	0,0002101	1,33	44,10

[ANEXOS]

<b>Diseño 2</b>	<b>Balanceado</b>		<b>0,8 y 0,1</b>	<b>87,68</b>	<b>19097,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	19181,19	88,07	0,000206	0,39	84,15
<b>Corrida 2</b>	19181,03	88,03	0,00012329	0,35	83,99
<b>Corrida 3</b>	19123,12	88,26	0,0001205	0,58	26,08
<b>Corrida 4</b>	19111,35	88,16	0,00031251	0,48	14,31
<b>Corrida 5</b>	19205,65	88,25	0,0002314	0,57	108,61
<b>Corrida 6</b>	19322,15	87,98	0,0003664	0,30	225,11
<b>Corrida 7</b>	19178,33	88,09	0,00021657	0,41	81,29
<b>Corrida 8</b>	19205,47	87,91	0,00024822	0,23	108,43
<b>Corrida 9</b>	19186,32	88,26	0,00015422	0,58	89,28
<b>Corrida 10</b>	19245,37	88,11	0,0006123	0,43	148,33

<b>Diseño 2</b>	<b>Desbalanceado</b>		<b>0,7 y 0,01</b>	<b>87,52</b>	<b>18939,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	16972,34	87,25	0,00150252	0,27	1966,70
<b>Corrida 2</b>	19034,67	88,16	0,00070536	0,64	95,63
<b>Corrida 3</b>	19146,54	88,48	0,0001205	0,96	207,50
<b>Corrida 4</b>	19121,98	88,06	0,00024746	0,54	182,94
<b>Corrida 5</b>	19235,46	88,59	0,00016547	1,07	296,42
<b>Corrida 6</b>	19124,32	88,24	0,00012654	0,72	185,28
<b>Corrida 7</b>	19432,66	88,35	0,00063258	0,83	493,62
<b>Corrida 8</b>	19647,51	88,27	0,00035125	0,75	708,47
<b>Corrida 9</b>	19064,23	88,61	0,00033617	1,09	125,19
<b>Corrida 10</b>	19119,2	88,09	0,00016425	0,57	180,16

<b>Diseño 2</b>	<b>Desbalanceado</b>		<b>0,75 y 0,05</b>	<b>87,52</b>	<b>18939,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	19120,15	87,91	0,00013654	0,39	181,11
<b>Corrida 2</b>	19223,34	88,06	0,00051258	0,54	284,30
<b>Corrida 3</b>	19605,11	88,15	0,00023717	0,63	666,07
<b>Corrida 4</b>	19101,23	88,01	0,00043214	0,49	162,19
<b>Corrida 5</b>	19204,3	87,79	0,0001366	0,27	265,26
<b>Corrida 6</b>	19211,35	88,35	0,0001911	0,83	272,31
<b>Corrida 7</b>	19168,46	87,96	0,00014529	0,44	229,42
<b>Corrida 8</b>	19164,21	88,34	0,00021049	0,82	225,17
<b>Corrida 9</b>	19192,18	88,1	0,00063258	0,58	253,14
<b>Corrida 10</b>	19092,6	88,04	0,00037035	0,52	153,56

[ANEXOS]

<b>Diseño 2</b>	<b>Desbalanceado</b>		<b>0,8 y 0,1</b>	<b>87,52</b>	<b>18939,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	19059,34	88,06	0,00037358	0,54	120,30
<b>Corrida 2</b>	19003,12	88,56	0,00026441	1,04	64,08
<b>Corrida 3</b>	19254,35	88,25	0,00035246	0,73	315,31
<b>Corrida 4</b>	19821,56	88,14	0,00012587	0,62	882,52
<b>Corrida 5</b>	19036,37	88,96	0,00062012	1,44	97,33
<b>Corrida 6</b>	19602,11	88,06	0,00035698	0,54	663,07
<b>Corrida 7</b>	19210,32	88,24	0,00021457	0,72	271,28
<b>Corrida 8</b>	19254,63	88,31	0,00035413	0,79	315,59
<b>Corrida 9</b>	19109,12	88,01	0,00012246	0,49	170,08
<b>Corrida 10</b>	19225,81	87,88	0,00011113	0,36	286,77

[ANEXOS]

ANEXO C: Corridas para el Diseño 3, en régimen Balanceado y Desbalanceado, variando las probabilidades de cruzamiento y mutación.

<b>Diseño 3</b>	<b>Balanceado</b>		<b>0,7 y 0,01</b>	<b>87,68</b>	<b>19097,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	17229,81	88,06	0,222704	0,38	1867,23
<b>Corrida 2</b>	17456,84	87,19	0,192204	0,49	1640,20
<b>Corrida 3</b>	15579,75	86,85	0,186217	0,83	3517,29
<b>Corrida 4</b>	21558,5	92,69	0,685674	5,01	2461,46
<b>Corrida 5</b>	17352,18	87,86	0,135852	0,18	1744,86
<b>Corrida 6</b>	19248,88	88,38	0,422466	0,70	151,84
<b>Corrida 7</b>	18678,45	89,19	0,0309007	1,51	418,59
<b>Corrida 8</b>	19032,95	89,84	0,225111	2,16	64,09
<b>Corrida 9</b>	19218,69	88,52	0,252879	0,84	121,65
<b>Corrida 10</b>	15597,25	86,85	0,176111	0,83	3499,79

<b>Diseño 3</b>	<b>Balanceado</b>		<b>0,75 y 0,05</b>	<b>87,68</b>	<b>19097,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	16936,71	87,09	0,107297	0,59	2160,33
<b>Corrida 2</b>	15822,94	86,61	0,162619	1,07	3274,10
<b>Corrida 3</b>	15646,48	86,81	0,173947	0,87	3450,56
<b>Corrida 4</b>	19160,07	88,33	0,073119	0,65	63,03
<b>Corrida 5</b>	19191,3	88,4	0,0169478	0,72	94,26
<b>Corrida 6</b>	16917,3	88,52	0,133238	0,84	2179,74
<b>Corrida 7</b>	20501,73	88,95	0,0997895	1,27	1404,69
<b>Corrida 8</b>	18964,8	88,89	1214736	1,21	132,24
<b>Corrida 9</b>	19264,12	89,23	0,124526	1,55	167,08
<b>Corrida 10</b>	20015,19	89,92	0,096541	2,24	918,15

[ANEXOS]

<b>Diseño 3</b>	<b>Balanceado</b>		<b>0,8 y 0,1</b>	<b>87,68</b>	<b>19097,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	19188,14	88,17	0,003727	0,49	91,10
<b>Corrida 2</b>	18359,24	88,25	0,044785	0,57	737,80
<b>Corrida 3</b>	16450,91	86,87	0,130622	0,81	2646,13
<b>Corrida 4</b>	20553,81	90,21	0,316458	2,53	1456,77
<b>Corrida 5</b>	18766,24	88,01	0,131893	0,33	330,80
<b>Corrida 6</b>	17369,53	86,96	0,349307	0,72	1727,51
<b>Corrida 7</b>	20363,11	90,12	0,583348	2,44	1266,07
<b>Corrida 8</b>	18295	88,13	0,128687	0,45	802,04
<b>Corrida 9</b>	15976,82	86,58	0,19004	1,10	3120,22
<b>Corrida 10</b>	21230,3	90,66	0,569184	2,98	2133,26

<b>Diseño 3</b>	<b>Desbalanceado</b>		<b>0,7 y 0,01</b>	<b>87,52</b>	<b>18939,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	19788,54	91,58	0,709294	4,06	849,50
<b>Corrida 2</b>	17216,83	87,27	0,212677	0,25	1722,21
<b>Corrida 3</b>	19456,54	88,46	0,198137	0,94	517,50
<b>Corrida 4</b>	18195,01	88,89	0,298719	1,37	744,03
<b>Corrida 5</b>	16668,36	87,23	0,176844	0,29	2270,68
<b>Corrida 6</b>	17554,01	88,43	0,306367	0,91	1385,03
<b>Corrida 7</b>	22118,98	89,11	0,395876	1,59	3179,94
<b>Corrida 8</b>	16805,82	86,83	0,202011	0,69	2133,22
<b>Corrida 9</b>	20983,22	92,12	0,713636	4,60	2044,18
<b>Corrida 10</b>	16411,43	88,01	0,328582	0,49	2527,61

<b>Diseño 3</b>	<b>Desbalanceado</b>		<b>0,75 y 0,05</b>	<b>87,52</b>	<b>18939,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	19588,74	91,68	0,6724	4,16	649,70
<b>Corrida 2</b>	15845,01	85,83	0,401769	1,69	3094,03
<b>Corrida 3</b>	20914,16	90,71	0,565912	3,19	1975,12
<b>Corrida 4</b>	18502,93	87,54	0,157348	0,02	436,11
<b>Corrida 5</b>	15446,87	86,56	0,472436	0,96	3492,17
<b>Corrida 6</b>	18394,97	86,39	0,631057	1,13	544,07
<b>Corrida 7</b>	20462,85	90,93	0,543951	3,41	1523,81
<b>Corrida 8</b>	19564,16	90,12	0,654123	2,60	625,12
<b>Corrida 9</b>	16854,25	88,92	0,124685	1,40	2084,79
<b>Corrida 10</b>	19668,1	89,99	0,264453	2,47	729,06

[ANEXOS]

<b>Diseño 3</b>	<b>Desbalanceado</b>		<b>0,8 y 0,1</b>	<b>87,52</b>	<b>18939,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	17684,76	87,91	0,101703	0,39	1254,28
<b>Corrida 2</b>	19062,45	88,34	0,040851	0,82	123,41
<b>Corrida 3</b>	19073,17	88,13	0,008984	0,61	134,13
<b>Corrida 4</b>	18713,38	88,23	0,0997003	0,71	225,66
<b>Corrida 5</b>	18040,79	89,72	0,600756	2,20	898,25
<b>Corrida 6</b>	17942,43	89,5	0,389603	1,98	996,61
<b>Corrida 7</b>	17188,78	87,01	0,48224	0,51	1750,26
<b>Corrida 8</b>	18919,67	88,74	0,206482	1,22	19,37
<b>Corrida 9</b>	18438,48	87,62	0,261713	0,10	500,56
<b>Corrida 10</b>	14173,01	85,35	0,423997	2,17	4766,03

[ANEXOS]

ANEXO D: Corridas para el Diseño 4, en régimen Balanceado y Desbalanceado, variando las probabilidades de cruzamiento y mutación.

<b>Diseño 4</b>	<b>Balanceado</b>		<b>0,7 y 0,01</b>	<b>87,68</b>	<b>19097,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	23793,76	92,49	0,995439	4,81	4696,72
<b>Corrida 2</b>	21226,62	92,67	0,711782	4,99	2129,58
<b>Corrida 3</b>	22169,67	92,65	0,69249	4,97	3072,63
<b>Corrida 4</b>	22142,56	92,52	0,710121	4,84	3045,52
<b>Corrida 5</b>	21052,54	91,65	0,652844	3,97	1955,50
<b>Corrida 6</b>	22415,6	92,53	0,911023	4,85	3318,56
<b>Corrida 7</b>	21856,39	92,9	0,452183	5,22	2759,35
<b>Corrida 8</b>	21457,51	91,57	0,657891	3,89	2360,47
<b>Corrida 9</b>	21493,52	92,55	0,452863	4,87	2396,48
<b>Corrida 10</b>	22301,02	91,87	0,552714	4,19	3203,98

<b>Diseño 4</b>	<b>Balanceado</b>		<b>0,75 y 0,05</b>	<b>87,68</b>	<b>19097,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	22004,85	92,18	0,696762	4,50	2907,81
<b>Corrida 2</b>	21496,96	92,59	0,754969	4,91	2399,92
<b>Corrida 3</b>	22082,92	92,66	0,690879	4,98	2985,88
<b>Corrida 4</b>	22012,65	91,86	0,514264	4,18	2915,61
<b>Corrida 5</b>	21536,54	92,63	0,498521	4,95	2439,50
<b>Corrida 6</b>	22058,2	92,38	0,684515	4,70	2961,16
<b>Corrida 7</b>	21654,32	92,97	0,698213	5,29	2557,28
<b>Corrida 8</b>	21147,55	92,41	0,710014	4,73	2050,51
<b>Corrida 9</b>	21511,38	91,4	0,541782	3,72	2414,34
<b>Corrida 10</b>	22045,47	91,86	0,751142	4,18	2948,43

[ANEXOS]

<b>Diseño 4</b>	<b>Balanceado</b>		<b>0,8 y 0,1</b>	<b>87,68</b>	<b>19097,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	22309,51	92,51	0,695371	4,83	3212,47
<b>Corrida 2</b>	22345,97	92,65	0,694153	4,97	3248,93
<b>Corrida 3</b>	22531,06	92,4	0,87523	4,72	3434,02
<b>Corrida 4</b>	21581,25	92,35	0,854711	4,67	2484,21
<b>Corrida 5</b>	22357,31	91,05	0,698541	3,37	3260,27
<b>Corrida 6</b>	21568,2	92,35	0,598546	4,67	2471,16
<b>Corrida 7</b>	21896,44	92,87	0,685241	5,19	2799,40
<b>Corrida 8</b>	22563,57	91,95	0,784952	4,27	3466,53
<b>Corrida 9</b>	22145,71	92,34	0,515584	4,66	3048,67
<b>Corrida 10</b>	22401,23	92,18	0,647581	4,50	3304,19

<b>Diseño 4</b>	<b>Desbalanceado</b>		<b>0,7 y 0,01</b>	<b>87,52</b>	<b>18939,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	21985,39	92,21	0,907123	4,69	3046,35
<b>Corrida 2</b>	22074,52	92,23	0,912883	4,71	3135,48
<b>Corrida 3</b>	21098,82	92,12	0,714792	4,60	2159,78
<b>Corrida 4</b>	21485,44	91,89	0,821451	4,37	2546,40
<b>Corrida 5</b>	21532,12	92,15	0,956421	4,63	2593,08
<b>Corrida 6</b>	22054,23	92,35	0,923415	4,83	3115,19
<b>Corrida 7</b>	21685,74	92,64	0,904125	5,12	2746,70
<b>Corrida 8</b>	22003,16	92,51	0,714669	4,99	3064,12
<b>Corrida 9</b>	21458,5	91,86	0,852141	4,34	2519,46
<b>Corrida 10</b>	21865,23	92,05	0,792564	4,53	2926,19

<b>Diseño 4</b>	<b>Desbalanceado</b>		<b>0,75 y 0,05</b>	<b>87,52</b>	<b>18939,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	21172,72	92,2	0,848944	4,68	2233,68
<b>Corrida 2</b>	21606,58	92,58	0,862792	5,06	2667,54
<b>Corrida 3</b>	21545,51	91,84	0,716569	4,32	2606,47
<b>Corrida 4</b>	21056,32	91,56	0,754123	4,04	2117,28
<b>Corrida 5</b>	20375,62	92,57	0,785963	5,05	1436,58
<b>Corrida 6</b>	21165,33	92,35	0,895241	4,83	2226,29
<b>Corrida 7</b>	21546,78	92,03	0,521486	4,51	2607,74
<b>Corrida 8</b>	21745,45	91,53	0,895621	4,01	2806,41
<b>Corrida 9</b>	21023,5	92,17	0,785156	4,65	2084,46
<b>Corrida 10</b>	21871,59	92,25	0,854783	4,73	2932,55

[ANEXOS]

<b>Diseño 4</b>	<b>Desbalanceado</b>		<b>0,8 y 0,1</b>	<b>87,52</b>	<b>18939,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	20757,48	92,28	0,733374	4,76	1818,44
<b>Corrida 2</b>	20955,43	92,03	0,729827	4,51	2016,39
<b>Corrida 3</b>	21416,19	92,21	0,690035	4,69	2477,15
<b>Corrida 4</b>	21354,21	92,18	0,854216	4,66	2415,17
<b>Corrida 5</b>	21651,25	92,65	0,754692	5,13	2712,21
<b>Corrida 6</b>	20654,29	91,95	0,754136	4,43	1715,25
<b>Corrida 7</b>	21012,45	91,45	0,745589	3,93	2073,41
<b>Corrida 8</b>	21854,11	92,67	0,845112	5,15	2915,07
<b>Corrida 9</b>	20986,87	92,86	0,664132	5,34	2047,83
<b>Corrida 10</b>	20479,42	91,81	0,778956	4,29	1540,38

[ANEXOS]

ANEXO E: Corridas para el Diseño 5, en régimen Balanceado y Desbalanceado, variando las probabilidades de cruzamiento y mutación.

<b>Diseño 5</b>	<b>Balanceado</b>		<b>0,7 y 0,01</b>	<b>87,68</b>	<b>19097,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	19256,78	92,45	0,992509	4,77	159,74
<b>Corrida 2</b>	23179,34	92,24	1,00189	4,56	4082,30
<b>Corrida 3</b>	21296,17	92,51	0,705776	4,83	2199,13
<b>Corrida 4</b>	21145,25	91,56	0,896514	3,88	2048,21
<b>Corrida 5</b>	22457,54	91,45	0,758964	3,77	3360,50
<b>Corrida 6</b>	21547,25	91,98	0,699874	4,30	2450,21
<b>Corrida 7</b>	19896,36	92,46	0,785236	4,78	799,32
<b>Corrida 8</b>	20541,31	92,54	0,854125	4,86	1444,27
<b>Corrida 9</b>	21588,22	92,66	0,847144	4,98	2491,18
<b>Corrida 10</b>	20952,95	92,74	0,710025	5,06	1855,91

<b>Diseño 5</b>	<b>Balanceado</b>		<b>0,75 y 0,05</b>	<b>87,68</b>	<b>19097,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	22207,33	92,64	0,692431	4,96	3110,29
<b>Corrida 2</b>	21806,91	92,61	0,733889	4,93	2709,87
<b>Corrida 3</b>	22190,19	92,26	0,818724	4,58	3093,15
<b>Corrida 4</b>	22321,25	91,89	0,547825	4,21	3224,21
<b>Corrida 5</b>	21426,35	92,65	0,658741	4,97	2329,31
<b>Corrida 6</b>	22285,21	92,45	0,745896	4,77	3188,17
<b>Corrida 7</b>	21859,39	91,41	0,854125	3,73	2762,35
<b>Corrida 8</b>	21854,17	92,87	0,457852	5,19	2757,13
<b>Corrida 9</b>	22056,6	92,39	0,89471	4,71	2959,56
<b>Corrida 10</b>	21457,56	91,97	0,544578	4,29	2360,52

[ANEXOS]

<b>Diseño 5</b>	<b>Balanceado</b>		<b>0,8 y 0,1</b>	<b>87,68</b>	<b>19097,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	22231,3	92,67	0,714212	4,99	3134,26
<b>Corrida 2</b>	21477,8	92,65	0,691903	4,97	2380,76
<b>Corrida 3</b>	22028,31	92,22	0,790988	4,54	2931,27
<b>Corrida 4</b>	22147,52	92,14	0,558755	4,46	3050,48
<b>Corrida 5</b>	21865,36	92,56	0,658744	4,88	2768,32
<b>Corrida 6</b>	21858,25	91,89	0,785411	4,21	2761,21
<b>Corrida 7</b>	21479,25	91,45	0,855244	3,77	2382,21
<b>Corrida 8</b>	22414,38	91,66	0,547896	3,98	3317,34
<b>Corrida 9</b>	21854,6	92,97	0,68778	5,29	2757,56
<b>Corrida 10</b>	22005,37	92,94	0,758412	5,26	2908,33

<b>Diseño 5</b>	<b>Desbalanceado</b>		<b>0,7 y 0,01</b>	<b>87,52</b>	<b>18939,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	22149,97	92,43	0,914528	4,91	3210,93
<b>Corrida 2</b>	20099,43	92,14	0,830594	4,62	1160,39
<b>Corrida 3</b>	20828,19	92,09	0,830446	4,57	1889,15
<b>Corrida 4</b>	21254,36	92,25	0,847411	4,73	2315,32
<b>Corrida 5</b>	21456,25	92,17	0,855419	4,65	2517,21
<b>Corrida 6</b>	20452,36	91,95	0,774521	4,43	1513,32
<b>Corrida 7</b>	20017,35	91,25	0,62584	3,73	1078,31
<b>Corrida 8</b>	22512,39	92,68	0,854714	5,16	3573,35
<b>Corrida 9</b>	21594,31	92,64	0,900142	5,12	2655,27
<b>Corrida 10</b>	20142,27	92,17	0,657841	4,65	1203,23

<b>Diseño 5</b>	<b>Desbalanceado</b>		<b>0,75 y 0,05</b>	<b>87,52</b>	<b>18939,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	21773,9	92,24	0,880832	4,72	2834,86
<b>Corrida 2</b>	20099,57	92,11	0,825184	4,59	1160,53
<b>Corrida 3</b>	20781,16	92,24	0,72761	4,72	1842,12
<b>Corrida 4</b>	21543,22	92,21	0,85224	4,69	2604,18
<b>Corrida 5</b>	22148,25	92,14	0,785412	4,62	3209,21
<b>Corrida 6</b>	20257,55	91,56	0,901425	4,04	1318,51
<b>Corrida 7</b>	21489,35	91,69	0,65584	4,17	2550,31
<b>Corrida 8</b>	22438,24	92,45	0,689541	4,93	3499,20
<b>Corrida 9</b>	20014,25	92,47	0,714583	4,95	1075,21
<b>Corrida 10</b>	21147,25	91,68	0,811569	4,16	2208,21

[ANEXOS]

<b>Diseño 5</b>	<b>Desbalanceado</b>		<b>0,8 y 0,1</b>	<b>87,52</b>	<b>18939,04</b>
	Potencia S	Eficiencia	Error	Dif Efi	Dif Pot
<b>Corrida 1</b>	21460,3	92,19	0,695717	4,67	2521,26
<b>Corrida 2</b>	20598,78	92,08	0,838411	4,56	1659,74
<b>Corrida 3</b>	20810,23	92,15	0,726833	4,63	1871,19
<b>Corrida 4</b>	23154,15	92,11	0,889254	4,59	4215,11
<b>Corrida 5</b>	21453,25	91,56	0,854761	4,04	2514,21
<b>Corrida 6</b>	22356,12	91,45	0,665415	3,93	3417,08
<b>Corrida 7</b>	22568,45	91,68	0,774521	4,16	3629,41
<b>Corrida 8</b>	21494,45	91,96	0,896541	4,44	2555,41
<b>Corrida 9</b>	20032,12	92,89	0,64587	5,37	1093,08
<b>Corrida 10</b>	20459,13	92,69	0,798923	5,17	1520,09