



UNIVERSIDAD DE QUINTANA ROO
DIVISIÓN DE CIENCIAS E INGENIERÍA

**DIMENSIONAMIENTO ÓPTIMO DE UN SISTEMA DE
GENERACIÓN DE ENERGÍA RENOVABLE MEDIANTE
UN ALGORITMO COMPUTACIONAL EVOLUTIVO**

TRABAJO DE TESIS
PARA OBTENER EL GRADO DE

INGENIERO EN SISTEMAS DE ENERGÍA

PRESENTA
MIGUEL HERNÁN GONZÁLEZ MARTÍNEZ

DIRECTOR
DR. VÍCTOR MANUEL SÁNCHEZ HUERTA

ASESORES
DR. GLISERIO ROMELI BARBOSA POOL
M.E.S. ROBERTO ACOSTA OLEA
M.C. EMMANUEL TORRES MONTALVO
DR. FERNANDO ENRIQUE FLORES MURRIETA





UNIVERSIDAD DE QUINTANA ROO
DIVISIÓN DE CIENCIAS E INGENIERÍA

TRABAJO DE TESIS BAJO LA SUPERVISIÓN DEL COMITÉ
DE ASESORÍA Y APROBADA COMO REQUISITO PARA
OBTENER EL GRADO DE:

INGENIERO EN SISTEMAS DE ENERGÍA

COMITÉ DE TESIS

DIRECTOR:


DR. VÍCTOR MANUEL SÁNCHEZ HUERTA

ASESOR:


DR. GLISERIO ROMELI BARBOSA POOL

ASESOR:


M.E.S. ROBERTO ACOSTA OLEA



CHETUMAL, QUINTANA ROO, MÉXICO, ABRIL DE 2015.

Agradecimientos

Primeramente le doy gracias a Dios por permitirme estar vivo y poder concluir esta etapa de mi vida.

A mis padres, a mi madre Pilar Martínez Cervantes y a mi padre Miguel Ángel González Gómez, gracias por haberme inculcado el deseo de salir adelante, por cada uno de los esfuerzos que hicieron para que hoy sea posible realizar uno de mis sueños, a ustedes les debo todo.

A mis hermanas, Aracely Isabel González Martínez y Jessica Janeth González Martínez gracias por demostrarme su cariño y por estar conmigo siempre a pesar de la distancia.

A mis tíos, Roberto Ismael González Pech y Yara Patricia Domínguez Santos gracias por haberme tratado como un hijo, por aconsejarme y apoyarme en todo momento.

A mis profesores, por haberme transmitido el interés por seguir aprendiendo, en especial a mi director de tesis Dr. Víctor Manuel Sánchez Huerta, por el apoyo y los consejos a lo largo de mi estancia en la universidad.

Agradezco a la División de Ciencias e Ingeniería el apoyo recibido mediante el proyecto interno UQROO/DCI/PI/09/2014.

Agradezco el apoyo recibido de la red temática de hidrógeno, con el número de proyecto CONACYT 252003, de igual forma el apoyo recibido del proyecto SEP-PROMEPI/103.5/14/10385.

Dedicatoria

A mis padres por brindarme su amor y su confianza en todo momento. Les agradezco su valioso esfuerzo.

ÍNDICE

CAPÍTULO 1. Introducción	1
1.1 Introducción	1
1.2 Problemática	2
1.3 Solución propuesta.....	2
1.4 Justificación	3
1.5 Objetivo general.....	3
1.6 Objetivos específicos	3
Capítulo 2. Sistemas de generación híbridos	4
2.1 Introducción	4
2.2 Configuración y operación	4
2.2.1 Generador eólico.....	5
2.2.2 Módulos fotovoltaicos	6
2.2.3 Celda de combustible.....	8
2.2.4 Electrolizador.....	9
2.3 Estrategias de control de generación de energía.....	10
2.3.1 Sobreproducción	11
2.3.2 Sobredemanda.....	11
2.3.3 Formulación del problema	11
2.3.4 Función de aptitud	12
2.4 Costos de capital y mantenimiento anualizado.....	12
2.4.1 Costos de reemplazo anualizado.....	13
2.4.2 Costo de la electricidad.....	13
2.5 Restricciones de funcionamiento	13
2.5.1 Restricción 1: energía almacenada en el tanque de hidrogeno	14
2.5.2 Restricción 2: confiabilidad (LPSP)	14
CAPÍTULO 3. Datos de los recursos renovables en sitio y demanda eléctrica	15
3.1 Introducción	15
3.2 Recurso solar	15
3.2.1 Recurso eólico	16

3.2.2 Demanda	18
CAPÍTULO 4. Conceptos básicos de optimización	19
4.1 Introducción	19
4.1.1 Formulación matemática de un problema de optimización	19
4.1.2 Parámetros de optimización.....	20
4.1.3 Funciones objetivo.....	20
4.1.4 Continuidad.....	21
4.1.5 Modalidad	22
4.1.6 Funciones de restricción	24
4.1.7 Algunas aplicaciones de los algoritmos genéticos.....	24
4.2 Algoritmos de optimización	25
4.2.1 Algoritmos de optimización determinísticos	25
4.2.2 Algoritmos de optimización estocásticos	26
4.3 Características sobresalientes	27
4.3.1 La aleatoriedad.....	27
4.3.2 Simplicidad	28
4.3.3 Eficiencia	28
4.3.4 Robustez	29
4.3.5 Versatilidad.....	29
4.4 Clasificación	29
4.4.1 Algoritmos físicos.....	30
4.4.1.1 Algoritmo de monte Carlo	30
4.4.1.2 Algoritmo de recocido simulado	30
4.5 Algoritmos evolutivos	30
4.6 Terminología evolutiva.....	31
4.6.1 Gen.....	31
4.6.2 Cromosomas	31
4.6.3 Aptitud	32
4.6.4 Individuo	32
4.6.5 Población	32
4.6.6 Elitismo	33

4.7 Población inicial	33
4.8 Algoritmos genéticos	34
4.8.1 Características diferenciadoras entre métodos tradicionales y algoritmos genéticos	35
4.8.2 Algoritmo genético canónico.....	36
4.8.3 Operadores básicos	38
4.8.3.1 Reproducción	38
4.8.3.2 Selección por ruleta	38
4.8.3.3 Selección por clasificación	38
4.8.3.4 Selección por torneo	39
4.8.3.5 Operador cruce.....	40
4.8.3.6 Operador mutación	41
CAPITULO 5. Resultados de simulación y conclusiones	43
5.1 Introducción	43
5.2 Influencia de los parámetros de cruce y mutación del algoritmo genético.....	43
5.3 Parámetros utilizados en el algoritmo genético	44
5.4 Datos de entrada y población inicial del algoritmo genético.....	46
5.5 Criterios de parada para el algoritmo genético	48
5.6 Análisis de resultados	48
5.7 Conclusiones.....	53

ÍNDICE DE FIGURAS

Figura 1. Esquema del sistema de generación renovable.....	5
Figura 2. Generador eólico.....	6
Figura 3. Módulo fotovoltaico.....	7
Figura 4. Celda de combustible.....	8
Figura 5. Electrolizador.....	9
Figura 6. Diagrama de flujo de la estrategia.....	10
Figura 7. Gráfica del perfil solar.....	16
Figura 8. Gráfica del perfil de recurso eólico.....	17
Figura 9. Gráfica del perfil de demanda.....	18
Figura 10. Gráfica de una función objetivo multimodal.....	21
Figura 11. Gráfica de una función objetivo discontinua unidimensional.....	22
Figura 12. Gráfica de una función objetivo multimodal de dos dimensiones.....	22
Figura 13. Gráfica de una función objetivo unimodal unidimensional.....	23
Figura 14. Gráfica de una función objetivo unimodal de dos dimensiones.....	23
Figura 15. Diagrama de flujo del algoritmo genético simple.....	37
Figura 16. Ejemplo del método de la ruleta.....	39
Figura 17. Diagrama de flujo del algoritmo genético implementado.....	45
Figura 18. (a) perfil de irradiancia. (b) perfil de viento.....	49
Figura 19. Perfil de la demanda eléctrica.....	49
Figura 20. Resultados para demanda constante de 1kW.....	50
Figura 21. Resultados para demanda variable.....	50
Figura 22. Gráfica de la energía equivalente de hidrogeno para el caso de la demanda variable.....	52
Figura 23. Gráfica de la energía equivalente de hidrogeno para el caso de la demanda constante.....	52

CAPÍTULO 1. Introducción

1.1 Introducción

El crecimiento constante de la población mundial ocasiona un incremento en la demanda de energía que le permita satisfacer sus necesidades básicas así como permitirle su crecimiento económico. Convencionalmente, la generación de energía se realiza principalmente a partir de combustibles fósiles que además de ser recursos no renovables implican una importante emisión de partículas contaminantes. Ante este panorama, la investigación y desarrollo de sistemas de generación de energía a partir de fuentes renovables se ha convertido en un tema prioritario en la agenda de energía de todos los gobiernos del mundo.

Los sistemas de generación eólico-fotovoltaico han sido estudiados extensamente en las últimas dos décadas. Debido a la intermitencia y disponibilidad del recurso solar y eólico es que estos sistemas requieren de un sistema de almacenamiento de energía. Tradicionalmente, las baterías han sido utilizadas como el medio de almacenamiento de energía; sin embargo su uso implica ciertos aspectos negativos al ambiente con respecto a los materiales que se utilizan en su fabricación.

El desarrollo de la tecnología del hidrógeno como medio de almacenamiento de energía la posiciona como una opción ecológica y viable para su integración en los sistemas de generación de energía a partir de fuentes renovables. El uso de hidrógeno como un medio de almacenamiento de energía implica la integración de equipo adicional al sistema de energía como lo son el electrolizador, tanque de almacenamiento y la celda de combustible.

Actualmente, los costos de módulos fotovoltaicos, turbinas eólicas, electrolizador y celdas de combustible son aún altos por lo que un aspecto crítico en el diseño de un sistema de generación de energía híbrido solar-eólico-celda de combustible es la optimización de la capacidad de estos elementos.

1.2 Problemática

Hoy en día el dimensionamiento óptimo de los sistemas híbridos de generación de energía renovables es un tema comúnmente abordado, ya que al ser diseñados de manera correcta estos representan un costo total neto muy bajo.

Por otra parte el diseño óptimo de un sistema de generación de energía aún es muy complejo dada la naturaleza aleatoria de las fuentes renovables y de la demanda.

Actualmente el dimensionamiento está basado en reglas basadas en la experiencia del diseñador y considerando factores de seguridad para no dejar la carga sin energía. Estos dimensionamientos no consideran los valores instantáneos de los recursos renovables del sitio ni de la carga eléctrica.

Usualmente estos métodos resuelven el problema de dimensionamiento basándose en variación paramétrica que integran los elementos del sistema, esto representa una gran desventaja para los métodos tradicionales de optimización, ya que al ser métodos enumerativos recorren todo el espacio de todas las posibles combinaciones de parámetros que podrían representar la mejor configuración del sistema híbrido y esto implica una demanda de recurso computacional muy alta y por consecuencia tiempos de cálculo muy elevados, además de que consideran por separado la parte técnica de la parte económica.

1.3 Solución propuesta

En esta tesis se explora el uso de un algoritmo computacional de inteligencia artificial para el dimensionamiento óptimo de un sistema híbrido de generación de energía renovable.

Se propone el desarrollado de un algoritmo genético que evalúe el menor costo total anualizado tomando en cuenta datos de la demanda, radiación solar y recurso eólico disponibles en el sitio, así como los costos de adquisición, mantenimiento y remplazo para cada uno de los componentes del sistema. Al ser los algoritmos genéticos métodos de

búsqueda global precisan tiempos de cálculo relativamente razonables en comparación de los métodos enumerativos. De esta manera se cumple con el compromiso entre la integración de la parte técnica con la parte económica del sistema de generación renovable.

1.4 Justificación

En el presente trabajo se estudiará el dimensionamiento óptimo de un sistema de generación renovable híbrido eólico-solar con almacenamiento de hidrógeno, minimizando los costos del sistema que satisfaga la energía demandada por una carga aislada. El método de optimización utilizado está basado en una técnica de programación evolutiva conocida como algoritmo genético. Se plantea la generación de energía del sistema híbrido con base a la insolación y el perfil del viento disponible en sitio, con objeto de satisfacer una demanda eléctrica determinada. Los resultados se presentan para una carga de una instalación doméstica que se encuentra en la región sur-este de la ciudad de Chetumal México.

1.5 Objetivo general

Dimensionar de manera óptima un sistema de generación renovable híbrido eólico-solar con almacenamiento de hidrógeno mediante algoritmos genéticos.

1.6 Objetivos específicos

- Dimensionar el sistema de generación renovable, considerando el recurso en sitio y la carga para un usuario domestico
- Determinar la función objetivo a minimizar que describa la estrategia de control del sistema de generación renovable
- Considerar el caso de estudio para la ciudad de Chetumal

Capítulo 2. Sistemas de generación híbridos

2.1 Introducción

Cuando dos o más sistemas de generación de energía se asocian en una sola instalación para la generación de energía eléctrica, surge lo que se denomina un sistema híbrido. Estos sistemas están compuestos generalmente por fuentes energéticas renovables cuyos recursos son prácticamente inagotables y de ser necesario se hace uso de fuentes no renovables, como por ejemplo motores de combustión interna (generador diésel), dejándolos en la mayoría de los casos solo para funciones de emergencia. La principal ventaja de un sistema híbrido es la posibilidad del aprovechamiento conjunto y optimizado de los recursos locales disponibles, pudiendo así garantizar altos niveles de calidad, confiabilidad y rendimiento en la producción de energía eléctrica. Además estos sistemas pueden estar aislados o conectados a la red eléctrica, por tanto los sistemas híbridos representan actualmente una solución viable para las exigencias energéticas.

2.2 Configuración y operación

El sistema de generación renovable está compuesto por una turbina eólica y módulos fotovoltaicos como medios de generación de energía, y emplea un sistema de almacenamiento de energía electrolizador-tanque-celda de combustible, la configuración del sistema de generación se aprecia en la figura 1.




Figura 1. Esquema del sistema de generación renovable.

2.2.1 Generador eólico

Los aerogeneradores operan bajo un principio simple, un generador eólico es un generador eléctrico movido por una turbina que es accionada por el viento. En este caso, la energía cinética proporcionada por el aire en movimiento, suministra energía mecánica, que a través de un sistema de transmisión mecánico, hace girar el rotor de un generador, normalmente un generador trifásico, que convierte la energía mecánica rotacional en energía eléctrica.

La potencia de salida $P_W(t)$ del generador eólico está en función de la velocidad del viento $v(t)$. En este trabajo se emplea la ecuación (1) para calcular la potencia generada por el aerogenerador considerando que este tiene una potencia nominal de 4 kW.

$$\begin{cases} P_W(t) = P_{nom}, & V_{nom} < v(t) < V_{co} \\ P_W(t) = \frac{1}{2} \cdot \rho \cdot A_{eol} \cdot C_p \cdot v(t)^3, & V_{ci} < v(t) < V_{nom} \\ P_W(t) = 0, & v(t) < V_{ci}, v(t) > V_{co} \end{cases} \quad (1)$$

En donde, V_{co} es la velocidad del viento máxima que soporta el generador eólico antes de que se proteja para no dañarse, V_{ci} velocidad del viento mínima en que el generador eólico comienza a generar energía, V_{nom} es la velocidad nominal, ρ es la densidad del aire, A_{eol} es el área de barrido del rotor (m^2), C_p es la eficiencia de la turbina eólica.



Figura 2. Generador eólico.

2.2.2 Módulos fotovoltaicos

Los módulos fotovoltaicos son dispositivos electrónicos basados en materiales semiconductores, y son los encargados de captar y convertir la radiación solar en energía eléctrica por medio del efecto fotoeléctrico. Las características de tensión y corriente producidas por los módulos fotovoltaicos dependen en gran medida de la cantidad de radiación recibida, de la temperatura y otros factores meteorológicos de la zona donde son instalados, así como de los parámetros constructivos del mismo (ver tabla 1). Actualmente el

material más utilizado en la fabricación de las celdas fotovoltaicas es el silicio (monocristalino, policristalino y amorfo). La tendencia en la disminución de los costos de fabricación de los módulos fotovoltaicos ha permitido alcanzar precios de 0.50 dólares por watt (M. Munsell, 2015).

Tabla 1. Eficiencias de distintas tecnologías fotovoltaicas

<i>Material</i>	<i>Eficiencia (%)</i>
<i>Monocristalino</i>	20
<i>policristalino</i>	15
<i>amorfo</i>	10
<i>arseniuro de galio</i>	30
<i>sulfuro de cadmio</i>	10
<i>célula multiunion</i>	40

La conversión de la energía proveniente de los datos de insolación por el arreglo de módulos fotovoltaicos se obtiene a partir de la ecuación (2).

$$P_s(t) = G(t) \cdot A_s \cdot \eta_s \quad (2)$$

Donde $G(t)$ es el nivel de insolación (KW/m^2), A_s y η_s son el área y la eficiencia de los módulos fotovoltaicos, respectivamente.



Figura 3. Módulo fotovoltaico.

2.2.3 Celda de combustible

Las celdas de combustible, muchas veces denominadas Células de Combustible (del inglés *Fuel Cells*) son sistemas electroquímicos en los que la energía de una reacción química se convierte directamente en electricidad.

Su principio de funcionamiento es inverso al de una electrólisis. Por ejemplo, en la electrólisis del agua, se separa este compuesto en sus dos componentes, hidrógeno y oxígeno, mientras que en una pila de combustible se obtendría una corriente eléctrica por medio de la reacción entre estos dos gases. Dependiendo del tipo de pilas de combustible, se obtienen eficiencias entre un 35 % hasta un 60 %.

Un modelo de pila de combustible simplificado se utiliza en este trabajo. Se supone que la celda de combustible funciona en un punto de operación fija, de modo que su potencia de salida ($P_{FC}(t)$) se puede evaluar a partir de la ecuación (3),

$$P_{FC}(t) = \eta_{FC} [P_{load}(t)/\eta_{inv} - P_{gen}(t)] \quad (3)$$

Donde η_{FC} y η_{inv} son la eficiencia de la celda de combustible y del inversor, respectivamente. $P_{load}(t)$ es la demanda, y $P_{gen}(t)$ es la potencia total generada por el arreglo fotovoltaico y el generador eólico, calculado como expresa la ecuación (4).

$$P_{gen}(t) = P_v(t) + P_s(t) \quad (4)$$



Figura 4. Celda de combustible.

2.2.4 Electrolizador

El funcionamiento del electrolizador es inverso al de la pila de combustible: aplicando energía eléctrica en corriente directa (DC) al agua se obtiene hidrógeno diatómico (H_2) y oxígeno (O_2). Este proceso se denomina “electrólisis del agua”. Una célula electrolítica está compuesta por un ánodo, un cátodo, un electrolito y un diafragma, el cual permite el paso de corriente pero no el paso de gases a través del mismo.

Se supone que el electrolizador funciona en un punto de operación constante, de manera que el hidrógeno producido por el electrolizador es proporcional a su eficiencia. La energía equivalente del hidrógeno extraído del electrolizador y almacenada en los tanques de depósito (tk) es descrita por la ecuación (5).

$$E_{tk}(t) = \eta_{elec} \cdot (E_{gen}(t) - E_{load}(t)/\eta_{inv}) \quad (5)$$

Donde η_{elec} es la eficiencia del electrolizador.



Figura 5. Electrolizador.

2.3 Estrategias de control de generación de energía

La estrategia de operación del sistema de generación renovable es una analogía de la operación de un sistema de generación convencional, en que los medios de generación más económicos son utilizados como generación base y los más costosos en los momentos de mayor demanda de energía. En este trabajo se utiliza la generación del generador eólico como generación base y la energía de los módulos fotovoltaicos y la celda como energía complementaria.

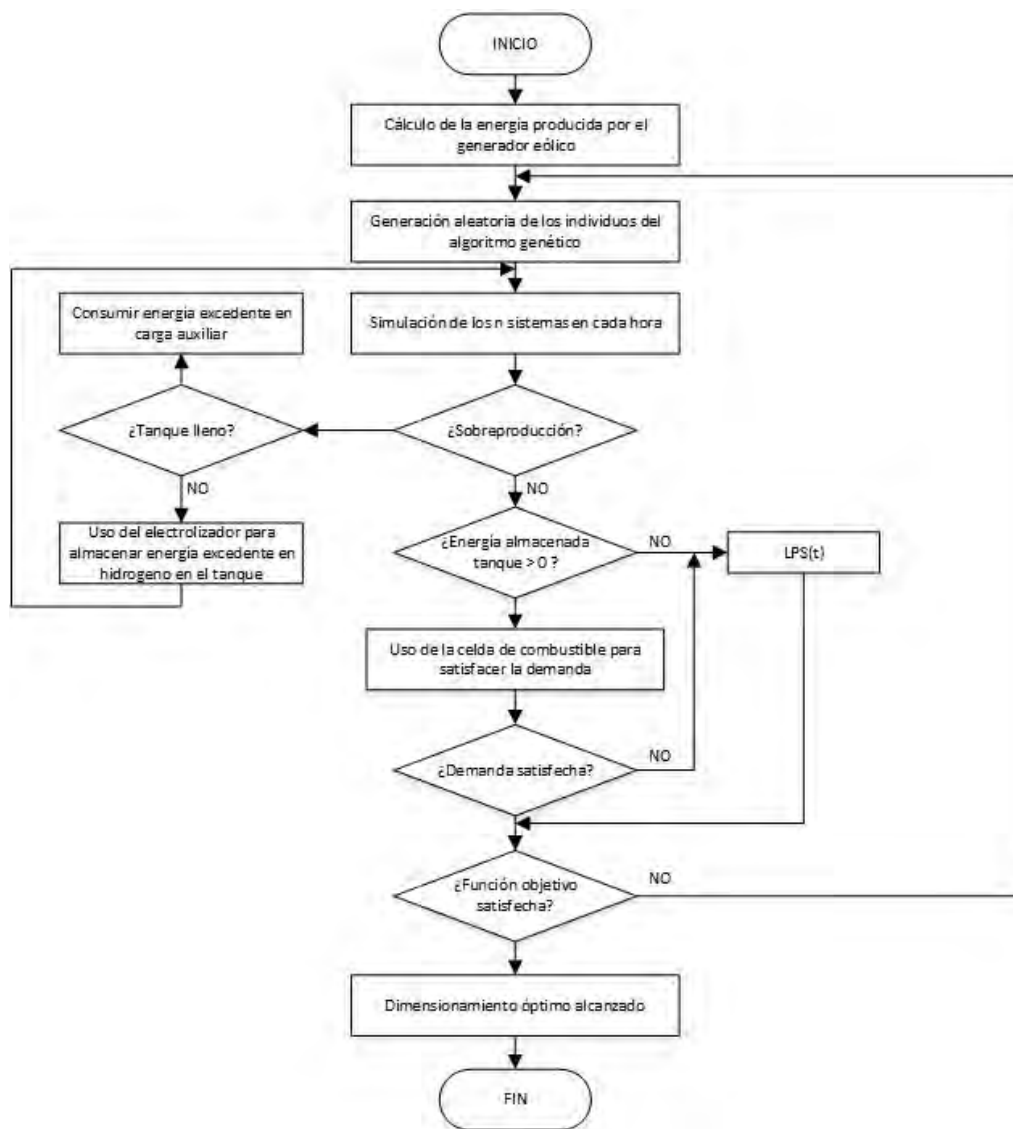


Figura 6. Diagrama de flujo de la estrategia.

En la evaluación de la operación de cada sistema de generación híbrido se consideran los casos de sobreproducción y sobredemanda, los cuales se describen a continuación.

2.3.1 Sobreproducción

En este caso, la energía generada por el generador eólico y los módulos fotovoltaicos es mayor a la energía demandada por la carga, por lo que la energía excedente es enviada al electrolizador para almacenarla en el tanque como hidrógeno. La ecuación (6) describe la energía equivalente almacenada en el tanque de hidrógeno.

$$E_{tk}(t) = E_{tk}(t - 1) + (E_{gen}(t) - E_{load}(t)/\eta_{inv})\eta_{elec} \quad (6)$$

2.3.2 Sobredemanda

En este caso la energía demandada es mayor a la energía generada por el generador eólico y el arreglo de módulos fotovoltaicos, por lo que la diferencia de energía debe ser suministrada por la celda de combustible. La celda de energía recupera la energía equivalente en hidrógeno almacenada en el tanque produciendo una disminución en la energía almacenada como lo describe la ecuación (7). Cuando la energía generada como la almacenada por el sistema híbrido no satisface la demanda entonces existe la pérdida de suministro de energía (LPS (t)) para la hora particular t y este parámetro se calcula con base en la ecuación (14).

$$E_t(t) = E_{load}(t) - (E_{gen}(t) + E_t(t - 1))/\eta_{Fc} \quad (7)$$

2.3.3 Formulación del problema

El principal objetivo del dimensionamiento del sistema híbrido es minimizar los costos totales, los cuales incluyen los costos de inversión, operación y mantenimiento. En este trabajo se utilizó el método de costos anualizados para el cálculo de los costos del sistema híbrido. El costo anualizado del sistema está formado por los costos anualizados de capital y

de operación y mantenimiento de cada componente del sistema. En el caso del electrolizador y celda de combustible se tienen que incluir los costos de su reemplazo ya que tienen un tiempo de vida menor al del proyecto. La función objetivo es descrita por la ecuación (8).

$$F^{obj} = \min\{\sum_{m=WTG,PV,elec,FC,tk}(C_{AC_m} + C_{OM_m}) + \sum_{n=elec,FC} C_{REMP_n}\} \quad (8)$$

2.3.4 Función de aptitud

El proceso de optimización del algoritmo genético debe considerar las restricciones descritas en las secciones 2.5.1 y 2.5.2 diferentes técnicas para el manejo de restricciones en algoritmos evolutivos han sido propuestas en la literatura especializada. La técnica seleccionada en este trabajo para el manejo de restricciones consiste en penalizar la función objetivo. La función de aptitud está formada por la función objetivo más los términos que penalizan a los individuos que no la satisfacen y está expresada por la ecuación (9).

$$F^{apt} = F^{obj} + abs\left\{\sum_{t=1}^n \left(K_1(LPSP_{obj} - LPSP_n) + K_2(E_{tk_{Cl_n}} - E_{tk_{CF_n}})\right)\right\} \quad (9)$$

2.4 Costos de capital y mantenimiento anualizado

El costo de capital anualizado de cada elemento del sistema se calcula a partir de la ecuación (10). El costo de mantenimiento y operación se considera constante durante el transcurso del tiempo de vida del proyecto, el cual se integra al costo anual total del sistema.

$$C_{AC} = C_{INV} \cdot FCR(i_r, N_p) = \frac{i_r(1+i_r)^{N_p}}{(1+i_r)^{N_p}-1} \quad (10)$$

Donde C_{INV} es el costo de inversión, i_r y N_p son la tasa de interés anual y la vida útil del elemento, respectivamente. FCR es el factor de recuperación de capital.

2.4.1 Costos de reemplazo anualizado

La celda de combustible y el electrolizador tienen un tiempo de vida menor al tiempo de vida del proyecto, por lo que se debe considerar el costo anualizado de su reemplazo. El costo anualizado de reemplazo del electrolizador y la celda de combustible está descrito por la ecuación (11).

$$C_{REMP} = C_R \cdot \frac{i_r}{(1+i_r)^{N_H}-1} \quad (11)$$

Donde C_R es el costo de sustitución y N_H la vida útil del componente reemplazado.

2.4.2 Costo de la electricidad

Estos datos representan el costo de la generación de electricidad por las fuentes comprendidas en el sistema de generación renovable. Este cálculo se obtiene de considerar los costos anualizados de los sistemas de generación renovables, sus costos de operación y mantenimiento y el costo de reemplazo anualizados y luego dividiéndolo por la producción de energía anual, como se describe en (12).

$$COE = \frac{C_{AC} + C_{REMP}}{AEP} \quad (12)$$

Donde COE es el costo de la electricidad, y AEP es la producción de energía anual del sistema de generación renovable.

2.5 Restricciones de funcionamiento

La primera restricción se relaciona con la energía máxima que puede ser almacenada en los tanques de almacenamiento de acuerdo con la ecuación (13).

$$0 \leq E_{tk}(t) \leq E_{tk \max} \quad (13)$$

2.5.1 Restricción 1: energía almacenada en el tanque de hidrogeno

Esta restricción tiene que ver con que al final de un periodo de 24 horas de funcionamiento del sistema híbrido la energía almacenada en el tanque en forma de hidrógeno no sea cero, para con ello permitir que el sistema híbrido pueda repetir otro periodo de operación de 24 horas. Esta restricción mantendrá el nivel promedio de energía almacenada como hidrógeno cercano al nivel de energía inicial en el tanque.

2.5.2 Restricción 2: confiabilidad (LPSP)

Por otra parte, una segunda restricción (LPSP), está relacionada con las pérdidas de suministro de energía. El LPSP es la probabilidad de que tanto el sistema de generación como de almacenamiento de energía deje sin suministro de energía a la carga por un periodo de tiempo y es un indicador de la confiabilidad del sistema. La técnica de LPSP se utilizó para dimensionar la cantidad de energía equivalente en hidrógeno que debe almacenarse para satisfacer la demanda de la carga. En este trabajo se utiliza un valor de LPSP de 0.0003 que equivale a la pérdida en el suministro de energía de un día en un periodo de 10 años. El valor de LPSP se calcula a partir de la ecuación (14).

$$LPSP = \frac{\sum_{t=1}^T LPS(t)}{\sum_{t=1}^T E_{carga}(t)} \quad \text{donde:} \quad LPS(t) = E_{carga}(t) - (E_{gen}(t) + E_{tk}(t-1) \cdot \eta_{Fc}) \quad (14)$$

donde $E_{gen}(t)$ es la energía producida por el generador eólico y el arreglo de módulos fotovoltaicos en la hora particular t , y puesto que el análisis se realiza en intervalos de una hora, se considera que la energía es equivalente a la potencia eléctrica de acuerdo con la ecuación (15).

$$E_{gen}(t) = P_{gen}(t) = P_v(t) + P_s(t) \quad (15)$$

CAPÍTULO 3. Datos de los recursos renovables en sitio y demanda eléctrica

3.1 Introducción

Para el dimensionamiento y optimización de sistemas híbridos de energía es necesario realizar una evaluación de los recursos energéticos renovables en sitio y establecer un patrón de consumo energético (la demanda eléctrica). Se deben obtener todas las variables para definir el comportamiento del sistema, partiendo de los datos de demanda energética y de los datos climatológicos.

En este capítulo se hace una descripción de los recursos renovables empleados en sitio y de la demanda eléctrica. Se muestran los datos de insolación y velocidad de viento en un modelo de 24 horas promedio anual correspondiente a la ciudad de Chetumal, Quintana Roo ($18^{\circ}30'13''N$ $88^{\circ}18'19''O$).

Como primer paso, se determina el perfil de carga, posteriormente se analizan y estiman los recursos solar y eólico disponibles en el lugar. Con esta información se procede al dimensionamiento del sistema híbrido óptimo para el perfil de carga propuesto.

3.2 Recurso solar

La radiación solar es un proceso complejo y variable, ya que en su incidencia influyen factores atmosféricos, meteorológicos y de geometría solar, y la mejor manera de estimar este recurso es mediante una serie de mediciones, aunque este proceso requiere de una inversión económica y tiempo considerables.

Las mediciones de radiación para el presente trabajo fueron hechas utilizando la estación meteorológica ubicada en la Universidad de Quintana Roo, para la recolección de datos se utilizó la estación meteorológica “vantage pro2 plus” marca “DAVIS” la cual incluye medición de rayos ultravioleta y radiación solar, las mediciones se realizaron durante un periodo de un año.

La figura 7 muestra la curva del perfil de radiación solar media diaria anual obtenida durante las mediciones en sitio.

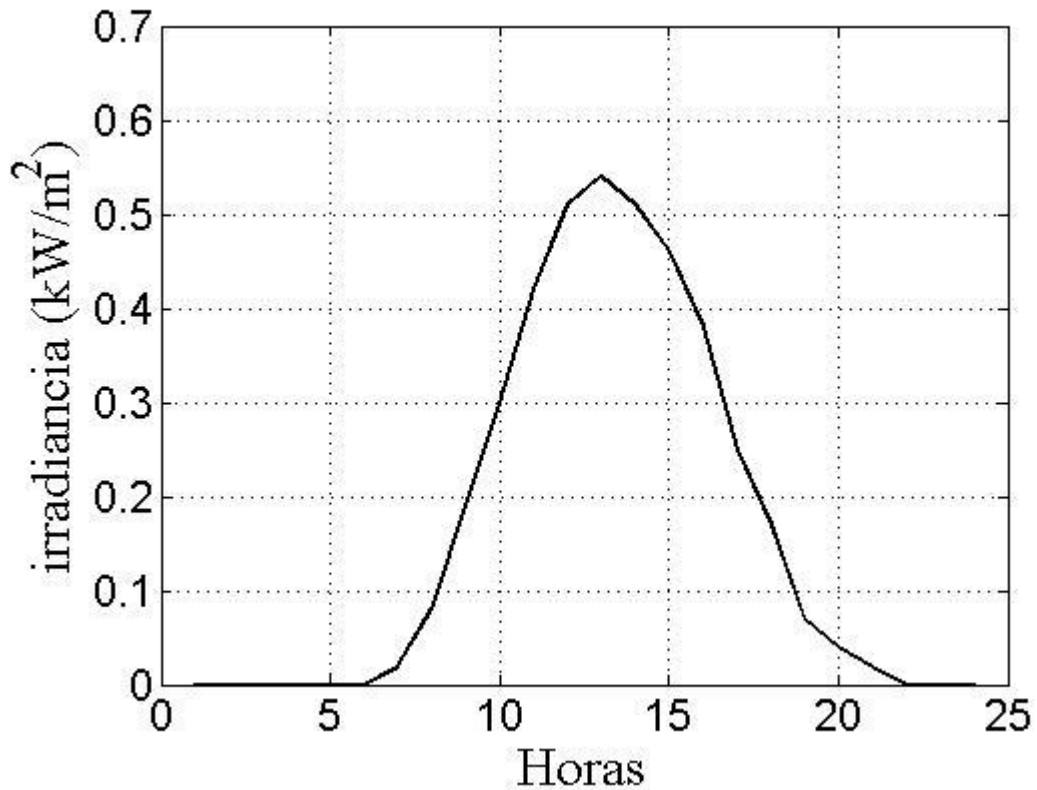


Figura 7. Gráfica del perfil solar.

En la figura 7 se aprecia la curva característica de radiación solar para una superficie horizontal, obtenida de un promedio de mediciones anuales para cada hora del año. Se observan niveles constantes de radiación a lo largo de las horas pico de producción, esto es un buen indicador para la implementación de un sistema de generación con módulos fotovoltaicos.

3.2.1 Recurso eólico

Para estimar el recurso eólico se utilizó la estación meteorológica “vantage pro2 plus” marca “DAVIS”, instalada aproximadamente a 10 m de altura en el edificio “F” ubicado en la Universidad de Quintana Roo. Fueron evaluadas las condiciones energéticas eólicas del lugar con el fin de conocer los parámetros característicos del viento. Estos valores se encuentran

representados en la Figura 8, Donde se muestra la velocidad promedio anual del viento para cada hora del día.

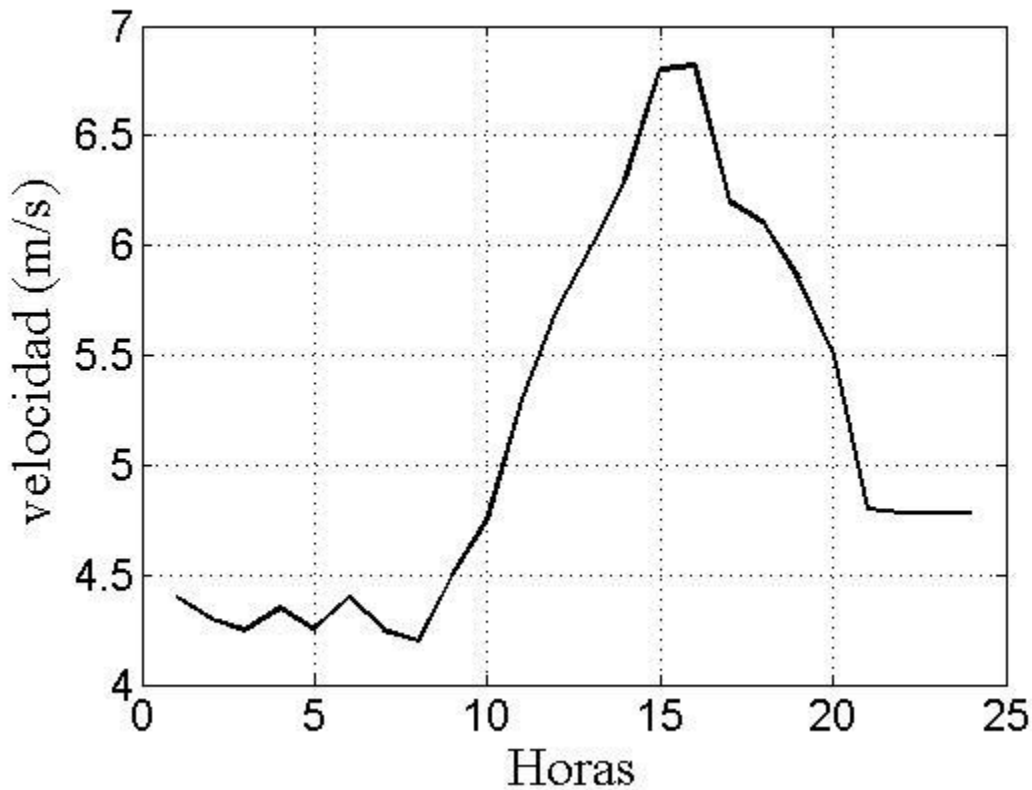


Figura 8. Gráfica del perfil de recurso eólico.

En la figura 8 se muestran las condiciones de viento medidas en el sitio, la gráfica representa las velocidades promedio (m/s) anuales del viento para cada hora del día, siendo la velocidad mínima 4.2 m/s y la máxima 6.82 m/s, estas velocidades son adecuadas para poner en marcha un sistema de generación conformado por generadores eólicos, lo cual es benéfico para los objetivos del presente trabajo ya que se plantea la generación de energía mediante turbinas eólicas como fuente primaria de suministro de energía para el sistema híbrido.

3.2.2 Demanda

El perfil de la demanda eléctrica fue tomado de una serie de mediciones realizadas en sitio en un periodo de un año y se muestra en la figura 9, Se asume que tanto la generación como la demanda de energía se mantienen constantes en cada intervalo de una hora.




Figura 9. Gráfica del perfil de demanda.

En la figura 9 se observa el perfil de demanda eléctrica para una instalación típica residencial, estos datos son usados en conjunto con los perfiles solar y eólico para el dimensionamiento óptimo del sistema híbrido de energía.

CAPÍTULO 4. Conceptos básicos de optimización

4.1 Introducción

A lo largo de la historia del ser humano, la humanidad se ha enfrentado a problemas de optimización y ha hecho grandes esfuerzos para resolverlos. A grandes rasgos, la optimización es el proceso de encontrar la mejor manera de utilizar los recursos disponibles, mientras que al mismo tiempo no viola ninguna de las restricciones que se imponen. De manera más exacta, se puede decir que se quiere definir un sistema matemáticamente, identificar sus variables y las condiciones que deban cumplir, definir las propiedades del sistema, y luego buscar el estado del sistema (valores de las variables) que proporciona las más deseables (más grandes o más pequeñas) propiedades. Este proceso en general se conoce como optimización.

4.1.1 Formulación matemática de un problema de optimización

Un problema de optimización en general se define matemáticamente como:

$$\text{Encontrar } x^* = [x_1^* \quad x_2^* \cdots x_N^*] \in D^N = D_1 \cap D_2 \cap \dots \cap D_N \quad (16)$$

Donde

$$f_i^{\min}(x^*) \leq f_i^{\min}(x) \forall x = [x_1 \quad x_2 \cdots x_N] \in D^N, \quad 1 \leq i \leq N_{f^{\min}},$$

$$f_i^{\max}(x^*) \geq f_i^{\max}(x) \forall x \in D^N, \quad 1 \leq i \leq N_{f^{\max}},$$

$$c_i^{\bar{}}(x^*) = 0, \quad 1 \leq i \leq N_{c^{\bar{}}},$$

$$c_i^{\dagger}(x^*) > 0, \quad 1 \leq i \leq N_{c^{\dagger}},$$

$$c_i^{\ominus}(x^*) < 0, \quad 1 \leq i \leq N_{c^{\ominus}}.$$

Donde x^* es la solución óptima en el espacio de búsqueda de N dimensiones D^N . N es el número de parámetros de optimización, o la dimensión del problema de optimización. D_i , ya sea continua o discreta, es el espacio de búsqueda de x_i , el i -ésimo parámetro de optimización. D_i y D_j no son necesariamente idénticas, desde el punto de vista de cualquier

tipo o tamaño. x es un vector de N dimensiones de parámetros de optimización. $f_i^{min}(x)$ es la i -ésima función objetivo a ser minimizada, $N_{f^{min}}$ es el número de funciones objetivo a ser minimizadas. $f_i^{max}(x)$ es la i -ésima función objetivo para ser maximizada, $N_{f^{max}}$ es el número de funciones objetivo a ser maximizadas. $c_i^-(x)$ es la i -ésima función de restricción o condición de igualdad, N_{c^-} es el número de funciones de restricción de igualdad. $c_i^+(x)$ es la i -ésima función de restricción positiva, N_{c^+} es el número de funciones de restricción positivas. $c_i^-(x)$ es la i -ésima función de restricción negativa, N_{c^-} es el número de funciones de restricción negativas.

Un problema de optimización está conformado por tres ingredientes esenciales: parámetros de optimización x ; funciones objetivo, $f_i^{min}(x)$ y $f_i^{max}(x)$; y las funciones de restricción, $c_i^-(x)$, $c_i^+(x)$ y $c_i^-(x)$.

En la práctica, las funciones objetivo y restricciones del problema de optimización pueden ser planteadas de diferentes maneras. Sin embargo, entre mejor sea la formulación de las funciones objetivo y restricciones, el problema de optimización será descrito de mejor forma y puede ser la diferencia para encontrar su solución óptima. Cualquier conocimiento del problema de optimización debe ser expresado en las funciones objetivo y restricciones del problema de optimización.

4.1.2 Parámetros de optimización

Los parámetros de optimización (x) son críticos para un problema de optimización. Estos afectan el valor de las funciones objetivo y las restricciones. Si no hay parámetros de optimización, no se puede definir las funciones objetivo y de restricción. Un parámetro de optimización puede ser continuo, discreto, o incluso simbólico.

4.1.3 Funciones objetivo.

Una función objetivo $f(x)$ es lo que se quiere optimizar, ya sea para minimizar una función objetivo $f_i^{min}(x)$ o bien maximizarla $f_i^{max}(x)$, dependiendo de las propiedades deseables del problema de optimización. Casi todos los problemas de optimización tienen funciones

objetivo. Sin embargo, en algunos casos el usuario particularmente desea obtener la mejor combinación de elementos por lo que no hay ninguna razón para definir una función objetivo. Este tipo de problema por lo general se llama un problema de viabilidad. Por otra parte, en algunos problemas de optimización, hay más de una función objetivo. Una función objetivo tiene al menos un óptimo global, y puede tener múltiples óptimos locales como se muestra en la Figura 10.




Figura 10. Gráfica de una función objetivo multimodal.

Una función objetivo tiene algunos rasgos característicos. Estas características son muy importantes para la elección de algoritmos de optimización para resolver el problema de optimización de interés. Una función objetivo puede tener diferentes características como se describe a continuación.

4.1.4 Continuidad

Una función objetivo puede ser continua, como se muestra en la Figura 10, o discontinua, como se muestra en la Figura 11.




Figura 11. Gráfica de una función objetivo discontinua unidimensional.

4.1.5 Modalidad

Una función objetivo $f(x)$ es unimodal si existe una única solución al problema de optimización. Por otra parte, si existe más de un óptimo, el problema de optimización es considerado multimodal. La figura 10 muestra una función objetivo multimodal unidimensional y la figura 12 muestra una función objetivo multimodal de dos dimensiones donde el punto es el punto óptimo x^* .



Figura 12. Gráfica de una función objetivo multimodal de dos dimensiones.

Una función objetivo unimodal unidimensional se dibuja en la Figura 13, mientras que una función objetivo unimodal de dos dimensiones se dibuja en la Figura 14.




Figura 13. Gráfica de una función objetivo unimodal unidimensional.




Figura 14. Gráfica de una función objetivo unimodal de dos dimensiones.

4.1.6 Funciones de restricción

Las restricciones permiten a los parámetros de optimización asumir ciertos valores, pero excluyen a otros. Las restricciones no son absolutamente necesarias para un problema de optimización. De hecho, el campo de la optimización sin restricciones es grande e importante para el cual una gran cantidad de algoritmos y software están disponibles. Sin embargo, se ha argumentado que casi todos los problemas realmente tienen limitaciones. Por ejemplo, cualquiera de los parámetros de optimización que indica el número de objetos en un sistema sólo puede tener sentido si es menor que el número de partículas elementales en el universo conocido. Sin embargo, en la práctica, las respuestas que tengan sentido en términos de la física subyacente a menudo pueden ser obtenidas sin poner limitaciones a los problemas de optimización. A veces, las funciones de restricción y funciones objetivo para un problema de optimización son intercambiables, dependiendo de la prioridad de las propiedades deseables.

4.1.7 Algunas aplicaciones de los algoritmos genéticos

La optimización tiene un historial consistente a través de una amplia gama de la ciencia, la ingeniería, la industria y el comercio. De hecho, muchos problemas de optimización vienen directamente desde las aplicaciones del mundo real.

A continuación se describen algunas de las aplicaciones donde los algoritmos genéticos han tenido participación.

- **Optimización:** Los algoritmos genéticos se han utilizado en una amplia variedad de tareas de optimización, incluyendo optimización numérica, así como problemas de optimización combinatoria, tales como el diseño de circuitos.
- **Programación automática:** los algoritmos genéticos se han utilizado para desarrollar programas para tareas específicas y para diseñar otras estructuras computacionales, como celulares autómatas y clasificación de redes.
- **Aprendizaje automático:** Los algoritmos genéticos se han utilizado para muchas aplicaciones de aprendizaje automático, incluyendo tareas de clasificación y predicción, tales como la predicción del clima o de estructura de proteínas.

- modelos económicos: Los algoritmos genéticos han sido utilizados para modelar los procesos de innovación, el desarrollo de estrategias de oferta, y el surgimiento de los mercados económicos.
- Modelos del sistema inmunológico: Los algoritmos genéticos se han utilizado para modelar diversos aspectos del sistema inmunológico natural, incluyendo la mutación somática durante la vida de un individuo.

4.2 Algoritmos de optimización

La optimización ha sido durante mucho tiempo objeto de estudio intensivo. Se han propuesto numerosos algoritmos de optimización. En general, estos algoritmos se pueden dividir en dos categorías principales, deterministas y estocásticos. Los algoritmos híbridos que combinan características deterministas y estocásticos son estocásticos en esencia y son considerados como tal. Sin embargo, es aceptable tratarlos como una tercera categoría desde el punto de vista de la pureza.

4.2.1 Algoritmos de optimización determinísticos

Un algoritmo de optimización determinista siempre obtendrá la misma solución con el mismo número de evaluaciones de la función objetivo independientemente del tiempo en que se inicia, si el espacio de búsqueda, el punto de partida, y las condiciones de terminación no se han modificado. Si el algoritmo se ejecuta varias veces en el mismo equipo, el tiempo de búsqueda para cada corrida será exactamente el mismo. En otras palabras, la optimización determinista es clonable.

La dimensión es un buen criterio para la clasificación de los algoritmos de optimización deterministas. Los algoritmos de optimización deterministas en consecuencia se dividen en algoritmos de optimización deterministas dimensionales unidimensionales y multidimensionales. Algunos algoritmos determinísticos multi-dimensionales necesitan la ayuda de algoritmos de optimización deterministas unidimensionales.

4.2.2 Algoritmos de optimización estocásticos

Los algoritmos de optimización deterministas han sido objeto de muchas décadas de desarrollo intensivo. Hoy en día, muchos algoritmos de optimización deterministas han aparecido en los libros de texto de diferentes niveles. Algunos de ellos incluso se han aplicado como subrutinas intrínsecas en paquetes de software comercial y han tenido un éxito considerable.

Sin embargo, los algoritmos de optimización deterministas se han enfrentado más y más a serios desafíos que surgen de las diversas aplicaciones del mundo real. Casos de fracaso se han ido acumulando rápidamente. Sus debilidades inherentes han sido expuestas con frecuencia. La mayoría de los algoritmos de optimización deterministas son matemáticamente elegantes. Sin embargo, nunca son fáciles de usar. Un usuario puede ser requerido para proporcionar no sólo las funciones objetivo y de restricción, sino también sus derivadas. Este requisito es invariablemente tedioso y puede resultar prohibitivo. El cálculo de derivadas puede imponer sobrecarga importante de computación. La sobrecarga se vuelve aún peor cuando el cálculo de derivadas tiene que ser hecho a través de aproximación de diferencias finitas.

La mayoría de los algoritmos de optimización determinista implican restricciones excesivas sobre los parámetros de optimización, funciones objetivo y las funciones de restricciones. La mayoría de los algoritmos de optimización determinista sólo se aplican a los parámetros de optimización continuos reales. Convexidad, continuidad y diferenciabilidad de funciones objetivo y de restricción son las consecuencias más comunes asumidas por los algoritmos de optimización determinista. Desafortunadamente, muchos de los problemas de aplicación en el mundo real no satisfacen ni siquiera una de estas suposiciones. Es evidente que la mayoría de los algoritmos de optimización deterministas exigen uno o más puntos de partida. Los buenos puntos de partida son críticos para el éxito de los algoritmos de optimización deterministas. Pobres puntos de partida pueden tener un efecto adverso significativo en la eficiencia de algoritmos de optimización determinista, o incluso hacer que fallen.

Muy a menudo, los buenos puntos de partida no pueden ser elegidos por casualidad. Una buena elección depende en gran medida del conocimiento a priori que puede requerir años de experiencia. Cuando tal conocimiento a priori no está disponible, los usuarios por lo general tienen que utilizar el método de prueba y error para localizar puntos de partida antes de iniciar el proceso de optimización. El enfoque multi-arranque aleatorio es la otra opción para este problema. La eficiencia computacional es la característica más prometedora de la mayoría de los algoritmos de optimización deterministas. Sin embargo, como la tecnología informática avanza rápidamente con cada día que pasa, las expectativas de la gente con respecto a la eficiencia se han incrementado significativamente. Como tal, en las últimas décadas, las personas han fijado cada vez más su atención a los algoritmos de optimización estocásticos, especialmente los algoritmos evolutivos.

4.3 Características sobresalientes

Los algoritmos de optimización estocásticos tienen muchas características interesantes. Algunas de estas características son controversiales. Sin embargo, la optimización estocástica ha ido ganando cada vez más popularidad y aceptación.

4.3.1 La aleatoriedad

Como se mencionó anteriormente, la optimización determinista es clonable. En contraste, como su nombre indica, los resultados obtenidos a partir de un algoritmo de optimización estocástico son en general impredecible debido a la aleatoriedad. En la práctica, nunca se puede ser capaz de obtener soluciones óptimas idénticas, aunque las soluciones obtenidas pueden diferir sólo muy ligeramente.

Sin embargo, desde el punto de vista de la aplicación práctica, dos resultados matemáticamente diferentes se consideran idénticos si ambos cumplen con el requisito de tolerancia impuesta por la aplicación práctica.

Una controversia que acompaña a los algoritmos de optimización estocásticos es su prueba de éxito absoluto, ya sea teórica o numéricamente. Ningún algoritmo de optimización estocástica garantiza el éxito absoluto, aunque el porcentaje de fracaso podría ser muy

pequeño. Una búsqueda por un algoritmo de optimización estocástico puede perder la solución óptima. Esto constituye un gran desafío para toda la comunidad de optimización estocástica. Los matemáticos que trabajan en ella están muy lejos de una conclusión satisfactoria.

4.3.2 Simplicidad

Los algoritmos de optimización estocásticos son en general matemáticamente más simples que los algoritmos deterministas. La mayoría de los algoritmos de optimización estocásticos generan su solución inicial a través de un proceso de inicialización inherente, y así evitar ser perturbados por la elección de un punto de partida. La mitigación de la fuerte dependencia de ensayo y error o un conocimiento a priori en adivinar puntos de partida es una enorme ventaja a los ojos de muchos profesionales de optimización.

Otra controversia en cuanto a los algoritmos de optimización estocásticos es su fundamento matemático riguroso. La mayoría de los algoritmos de optimización estocásticos se inspiran en fenómenos naturales que la humanidad ha estado luchando por entender.

Cada algoritmo de optimización estocástico tiene al menos un parámetro de control intrínseco. El rendimiento de los algoritmos de optimización estocásticos más o menos depende de estos parámetros de control intrínsecos. Es bien sabido que el ajuste de estos parámetros de control para un mejor rendimiento suele ser muy tedioso. En este sentido, los algoritmos de optimización estocásticos no son tan simples como la gente ha creído.

4.3.3 Eficiencia

Los algoritmos de optimización estocásticos por lo general requieren más evaluaciones de la función objetivo para encontrar la solución óptima en comparación con los algoritmos de optimización determinista, dado que ambos tienen éxito. En otras palabras, son computacionalmente más costosos o menos eficiente.

4.3.4 Robustez

Esta es la tercera controversia en cuanto a los algoritmos de optimización estocásticos se refiere. Los algoritmos de optimización estocásticos pueden ocasionalmente perder la solución óptima, incluso si todo es favorable. Por otro lado, los algoritmos de optimización estocásticos son generalmente capaces de precisar una solución cuasi-óptima dentro de un amplio espacio de búsqueda, mientras que los algoritmos de optimización deterministas generalmente no lo hacen en la misma situación. En la mayoría de las aplicaciones prácticas, una solución cuasi-óptima es bienvenida. Muy a menudo, se acepta de inmediato. En el caso de que no sea aceptable, se pueden tomar ciertas medidas para refinarla.

4.3.5 Versatilidad

La mayoría de los algoritmos de optimización estocástica no imponen restricciones a los problemas de optimización. Además, muchos algoritmos de optimización estocásticos se aplican a los parámetros de optimización discretos o incluso simbólicos, así como los reales. En este sentido, la optimización estocástica es versátil.

4.4 Clasificación

Los algoritmos de optimización estocásticos se pueden dividir en dos grandes categorías de acuerdo a sus orígenes: algoritmos físicos y algoritmos evolutivos.

Algunas personas consideran las redes neuronales artificiales y los sistemas inmunológicos artificiales como algoritmos de optimización estocástica. De hecho, pueden ser utilizados para resolver ciertos problemas de optimización. Sin embargo, antes de resolver el problema de optimización, el entrenamiento tiene que ser llevado a cabo. Estos algoritmos no pueden lograr la optimización por sí mismos sin la ayuda de conjuntos de entrenamiento. Por esta razón, no se consideran como algoritmos de optimización estocástica.

4.4.1 Algoritmos físicos

Los algoritmos de optimización estocásticos en esta categoría están inspirados en fenómenos físicos. El algoritmo de Monte Carlo y el algoritmo de recocido simulado son dos de los algoritmos más destacados en esta categoría.

4.4.1.1 Algoritmo de monte Carlo

El algoritmo de Monte Carlo, llamado así por un famoso casino de la ciudad de Mónaco, se basa en un muestreo aleatorio repetido para encontrar una solución óptima. El uso de la aleatoriedad y la naturaleza repetitiva del proceso son análogas a las actividades realizadas en un casino.

Originalmente fue practicado bajo nombres más genéricos como el muestreo estadístico. En la década de 1940, los físicos que trabajan en proyectos de armamento nuclear en el Laboratorio Nacional de Los Álamos acuñaron el nombre actual.

4.4.1.2 Algoritmo de recocido simulado

El algoritmo de recocido simulado imita el proceso de recocido en la metalurgia, una técnica que implica el calentamiento y enfriamiento controlado de un material para aumentar el tamaño de sus cristales y reducir defectos. Por analogía con este proceso físico, cada paso del algoritmo de recocido simulado sustituye a la solución actual por una nueva solución con una probabilidad que depende de la diferencia de los valores de la función objetivo en los dos puntos de la solución y la temperatura. La función de distribución de probabilidad más a menudo implementada es la distribución de probabilidad de Boltzmann, que es $p(x, y, T) = \exp\{-[f(y) - f(x)]/(k T)\}$ donde k es la constante de Boltzmann.

4.5 Algoritmos evolutivos

Los algoritmos evolutivos son algoritmos de búsqueda y optimización que recreando los mecanismos primordiales de la evolución Darwiniana, intentan reproducir las mismas características de robustez y simplicidad existente en la naturaleza para evolucionar hacia mejores soluciones en problemas computacionales. La selección natural es el fundamento de

la teoría de la evolución de Darwin. El estudio de los algoritmos evolutivos se inició en la década de 1960. A un número de investigadores creativos independientes se les ocurrió la idea de imitar el mecanismo de la evolución biológica y desarrolló tres principales algoritmos evolutivos, es decir, algoritmos genéticos, programación evolutiva, y estrategias de evolución. Otros algoritmos evolutivos incluyen algoritmos miméticos, búsqueda dispersa, migración de auto-organización y búsqueda tabú.

En las últimas décadas, los algoritmos de enjambre, incluyendo la optimización de colonia de hormigas, algoritmo de abejas, algoritmos culturales, la optimización de enjambre de partículas, han surgido dentro de la comunidad de la computación evolutiva. Los algoritmos de enjambre, como su nombre lo indica, imitan las conductas humanas o animales.

4.6 Terminología evolutiva

Para la conveniencia de la siguiente descripción, varias terminologías esenciales que se encuentran frecuentemente en la computación evolutiva son definidas.

4.6.1 Gen

El gen es el componente básico de todos los algoritmos evolutivos. Generalmente hay dos clases de genes: real, donde un gen es un número real; y alfabético, donde un gen toma un valor de un conjunto del alfabeto. Los conjuntos alfabeto más comunes son los conjuntos binarios, octales, decimales y hexadecimales.

4.6.2 Cromosomas

El cromosoma es otro bloque esencial de todos los algoritmos evolutivos. En la naturaleza, los organismos tienen ciertas características que influyen en su capacidad de sobrevivir y reproducirse. Estas características están representadas por cadenas largas de información contenida en los cromosomas del organismo. Los cromosomas son estructuras de las moléculas compactas entrelazadas de ADN, que se encuentran en el núcleo de las células orgánicas. Cada cromosoma contiene un gran número de genes, donde un gen es la unidad de la herencia. Los genes determinan muchos aspectos de la anatomía y la fisiología a través del control de la producción de proteínas. Cada individuo tiene una secuencia única de genes.

El cromosoma es una representación simbólica de los parámetros de optimización (x). Los genes se concatenan en los cromosomas en la siguiente forma.

$$g = \overbrace{g_{11} \dots g_{1L_1}}^{x_1} \overbrace{g_{21} \dots g_{2L_2}}^{x_2} \dots \overbrace{g_{N1} \dots g_{NL_N}}^{x_N}$$

Donde g_{ij} es la i -ésima representación del gen x_i , y L_i es el número de genes en la subcadena para x_i .

4.6.3 Aptitud

En el modelo darwiniano de la evolución, los individuos con las mejores características tienen la mejor oportunidad de sobrevivir y reproducirse. Con el fin de determinar la capacidad de un individuo para sobrevivir, se utiliza una función matemática para cuantificar que tan buena es la solución representada por un cromosoma. La aptitud es la medida de la bondad de un cromosoma. Está directamente relacionado con los valores de la función objetivo y de restricción a través de una operación de escalado.

4.6.4 Individuo

En una sociedad real, un individuo es un ser vivo. Sin embargo, en la comunidad de la computación evolutiva, un individuo es un agregado de cromosomas, valores de los parámetros de optimización x , y los valores de la función objetivo (incluyendo restricción). Los atributos adicionales de un individuo pueden incluir valor de aptitud (fitness), generación, velocidad, edad, sexo, e incluso la memoria.

4.6.5 Población

Una población es una congregación de individuos. Una característica importante de una población es su edad, expresado en términos de generación. Es el objeto sobre el que todos los algoritmos evolutivos trabajan. En promedio, estadísticamente hablando, una población posterior es mejor que una población anterior.

La característica más importante de una población P^n de la generación n que contiene individuos N_p es su diversidad que puede definirse como

$$d(P^n) = \min_{1 \leq i \neq j \leq N_p} s(P^{n,i}, P^{n,j}) \quad (17)$$

Si el mejor individuo de la población P^n , $P^{n,best}$, y el peor individuo $P^{n,worst}$ son identificables, es computacionalmente más eficiente para redefinir la diversidad de la población como

$$d(P^n) = s(P^{n,best}, P^{n,worst}) \quad (18)$$

En la práctica, ambas funciones de diversidad deben aplicarse con cuidado. Matemáticamente, la primera definición es más razonable, también es más beneficiosa para la preservación de la diversidad; Sin embargo, es mucho más caro computacionalmente. Por otro lado, la última definición puede exagerar el rendimiento de un individuo y discriminar las características genéticas de un individuo.

4.6.6 Elitismo

Un algoritmo evolutivo funciona a través de la utilización iterativa de operadores genéticos. Estos operadores genéticos pueden producir la pérdida de una buena solución encontrada en una generación, en generaciones posteriores. En vista a esto, se sugiere una política en la cual siempre se incluye el mejor individuo de una población anterior (P^{n-1}), en una población posterior (P^n) a fin de preservarlo de la posible acción negativa de los operadores genéticos. A esta estrategia se le conoce como elitismo. Se ha demostrado formalmente que el elitismo asegura la convergencia de los métodos evolutivos.

4.7 Población inicial

Los algoritmos evolutivos son estocásticos, algoritmos de búsqueda basados en la población. Por tanto, cada algoritmo evolutivo mantiene una población de soluciones candidatas. El primer paso en la aplicación de un algoritmo evolutivo para resolver un problema de optimización es generar una población inicial. La forma estándar de la generación de una población inicial es asignar un valor aleatorio desde el dominio permitido a cada uno de los

genes de cada cromosoma. El objetivo de la selección aleatoria es asegurar que la población inicial es una representación uniforme de todo el espacio de búsqueda. Si las regiones del espacio de búsqueda no están cubiertas por la población inicial, es probable que estas partes serán ignoradas por el proceso de búsqueda.

El tamaño de la población inicial tiene consecuencias en términos de complejidad computacional y de habilidades de exploración. Un gran número de personas aumenta la diversidad, mejorando así las capacidades de exploración de la población. Sin embargo, cuanto más individuos, mayor será la complejidad computacional por generación. Mientras que el tiempo de ejecución por generación incrementa, puede ser el caso de que se necesiten menos generaciones para localizar una solución aceptable. Una pequeña población, por otro lado representará una pequeña parte del espacio de búsqueda. Si bien la complejidad de tiempo por generación es baja, el algoritmo evolutivo puede necesitar más generaciones para converger que para una población grande. En el caso de una pequeña población, el algoritmo evolutivo puede ser obligado a explorar más del espacio de búsqueda mediante el aumento de la tasa de mutación.

4.8 Algoritmos genéticos

Los algoritmos genéticos son, posiblemente, los primeros modelos algorítmicos desarrollados para simular sistemas genéticos, forman parte de los algoritmos evolutivos, que constituye una familia de modelos computacionales inspirados en la evolución natural, Los principios básicos de los algoritmos genéticos fueron establecidos por J.H. Holland.

Esta técnica se basa en los mecanismos de selección que utiliza la naturaleza, de acuerdo a los cuales los individuos más aptos de una población son los que sobreviven, al adaptarse más fácilmente a los cambios que se producen en su entorno. Los algoritmos genéticos recrean el proceso de la selección natural utilizando una población inicial de individuos, que evolucionan al ser sometidos a una serie de operadores, siendo los individuos con mayor aptitud los que sobreviven y generan descendencia a lo largo de la ejecución del algoritmo.

Estos algoritmos brindan una posible solución a determinado problema, siendo dicha solución un individuo perteneciente a la población formada por las soluciones que se estén considerando. Una característica importante de esta clase de algoritmos es el poco conocimiento específico que precisan del problema al que se aplican, para su funcionamiento. Los algoritmos genéticos tienen aplicaciones significativas en casos donde los métodos tradicionales fallan ya que permiten la resolución de problemas con poca demanda computacional.

El poder de los algoritmos genéticos proviene del hecho de que se trata de una técnica robusta, además, son considerados como optimizadores de funciones, y pueden tratar con éxito una gran variedad de problemas provenientes de diferentes áreas. Si bien no se garantiza que el algoritmo genético encuentre la solución óptima del problema, existe evidencia empírica de que se encuentran soluciones de un nivel aceptable.

Existen muchos métodos de optimización que han sido desarrollados en investigación matemática y operativa. Los algoritmos genéticos se suelen describir como métodos de búsqueda global, que no hacen uso de información del gradiente. De este modo, las funciones no diferenciables así como las funciones con múltiples óptimos locales constituyen clases de problemas a los cuales se les puede aplicar especialmente los algoritmos genéticos.

4.8.1 Características diferenciadoras entre métodos tradicionales y algoritmos genéticos

Se puede observar que el algoritmo genético difiere sustancialmente de los métodos de búsqueda y optimización más tradicionales. Las cuatro diferencias más significativas son:

- Los algoritmos genéticos trabajan con una codificación de las soluciones, en vez de con las soluciones.

- Los algoritmos genéticos realizan una búsqueda utilizando una población de posibles soluciones, en vez de con una única solución. Así se obtiene, generalmente, un conjunto de soluciones viables para el problema en estudio.
- Los algoritmos genéticos no requieren información auxiliar; sólo la función objetivo y de aptitud. Esto permite resolver problemas con poco conocimiento específico.
- Los algoritmos genéticos usan reglas de transición probabilísticas y no determinísticas. Los operadores que actúan durante la ejecución de un algoritmo genético se aplican con una determinada probabilidad (Dufo Lopez R., 2007).

4.8.2 Algoritmo genético canónico

El algoritmo genético canónico o algoritmo genético simple fue el primer modelo introducido e investigado por [J.H. Holland (1975)]. La mayoría de las teorías actuales sobre algoritmos genéticos son aplicadas al modelo introducido por Holland, así como a variaciones del mismo, que se conoce en la literatura especializada como el algoritmo genético canónico.

Es de utilidad considerar la ejecución de un algoritmo genético como un proceso que implica dos fases: inicialización y evolución. La inicialización genera aleatoriamente una población inicial (P^0). Tras crear una población inicial, se aplica un muestreo para generar una población intermedia donde cada cadena se evalúa mediante la función de evaluación y recibe un valor según su aptitud (“fitness”). Entonces P^0 evoluciona en P^1 , P^1 se convierte en P^2, \dots, P^n , Hasta que se cumplan las condiciones de terminación. Mientras que evoluciona de P^n a P^{n+1} , las tres operaciones evolutivas: selección, cruce y mutación se ejecutan en secuencia. El proceso que va desde una población actual a la población siguiente constituye una generación en la ejecución de un algoritmo genético. En el algoritmo genético canónico cada miembro de la población está constituido por una cadena binaria de longitud LC que corresponde a la codificación del problema. Cada cadena suele denominarse comúnmente

como cromosoma. En la figura 15 se muestra el diagrama de flujo general del algoritmo genético simple.

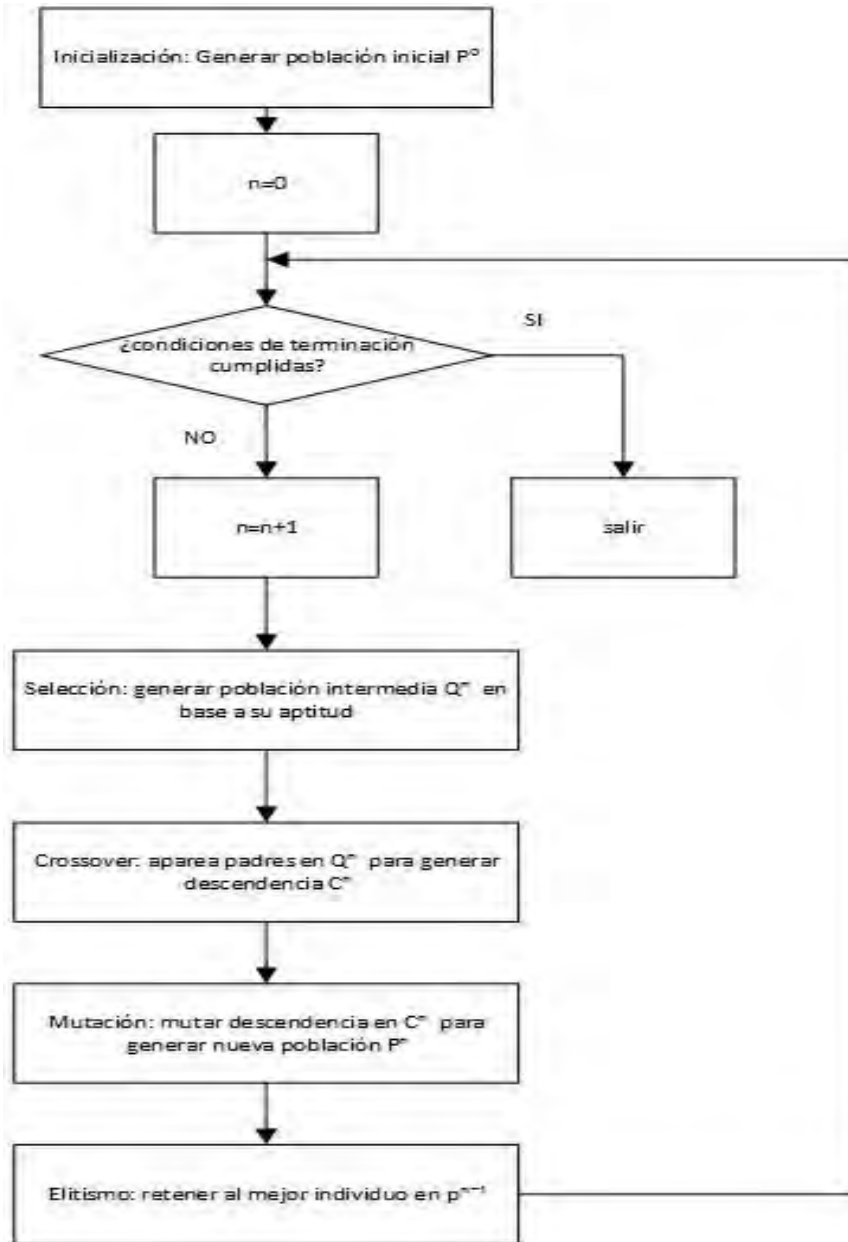


Figura 15. Diagrama de flujo del algoritmo genético simple

4.8.3 Operadores básicos

Los principales operadores utilizados en la implementación de los algoritmos genéticos, son la reproducción, el cruce y la mutación. Existen otros operadores que pueden ser usados en la implementación de un algoritmo genético, sin embargo los que se describen a continuación son los que determinan las características fundamentales en el funcionamiento de estos algoritmos.

4.8.3.1 Reproducción

La reproducción es uno de los principales operadores en los algoritmos evolutivos, y se relaciona directamente con el concepto darwiniano de la supervivencia del más apto. El principal objetivo de los operadores de selección es hacer hincapié en las mejores soluciones. El operador de selección se cree que es responsable de la convergencia de los algoritmos genéticos. Selecciona buenos individuos sobre la base de sus valores de aptitud (fitness) y produce una población temporal. Esto se puede lograr por muchos esquemas diferentes, pero los métodos más comunes son la rueda de ruleta, clasificación y torneos de selección.

4.8.3.2 Selección por ruleta

La idea esencial detrás de la selección por ruleta es que, la probabilidad de selección de un individuo en la población de padres es proporcional a su valor de aptitud. Recibe su nombre debido a su analogía con la rueda de ruleta en un casino.

4.8.3.3 Selección por clasificación

La idea de la selección por clasificación (ranking) es muy simple. Todos los individuos en la población de padres son clasificados de acuerdo a su aptitud (fitness). Los individuos con clasificación más alta (altos valores de aptitud) son seleccionados para la reproducción.

4.8.3.4 Selección por torneo

Como su nombre lo indica, la selección por torneo implementa un torneo para decidir cuáles son los miembros de la población de padres que serán candidatos para reproducirse, Los individuos que resulten ganadores serán seleccionados.

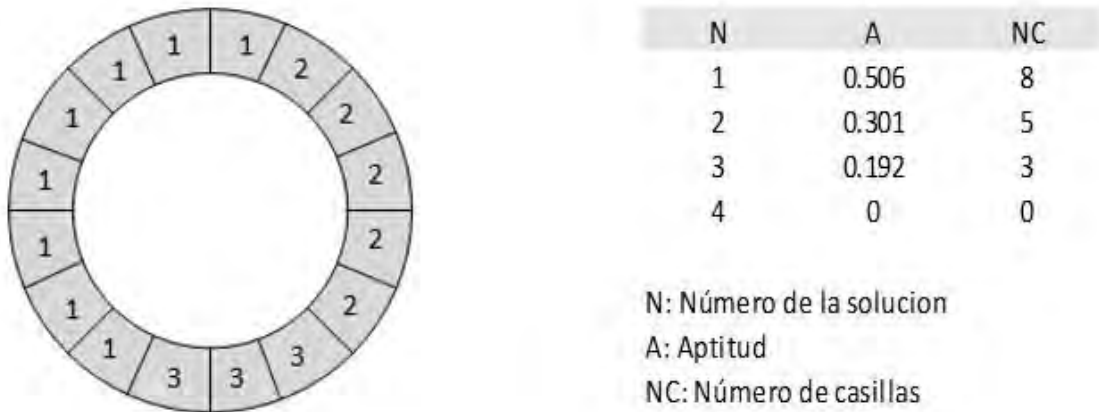


Figura 16. Ejemplo del método de la ruleta

En la figura 16 se representa un ejemplo del método de la ruleta con los valores asociados a ella. En este caso se trata de una población formada por cuatro soluciones (individuos). Lo primero que se debe decidir es el número total de casillas que poseerá la ruleta, que será igual al número de copias que se realizarán de las soluciones. En este caso, dado que solamente existen 4 soluciones, se ha optado por considerar 16 casillas. La aptitud proporcionará el número de casillas que ocupará cada una de las soluciones. Ocho corresponden a la primera, cinco corresponden a la segunda, tres a la tercera y ninguna a la cuarta. Cuanto mayor número de casillas tenga una solución mayor será la probabilidad de que ésta sea seleccionada para el cruce.

4.8.3.5 Operador cruce

Los operadores de cruce se pueden dividir en tres categorías principales en función de la aridad (es decir, el número de padres que utiliza) del operador. Esto se traduce en tres clases principales de operadores de cruce:

- **Asexual**, donde un descendiente es generado por un padre.
- **Sexual**, donde dos padres son usados para producir uno o dos descendientes.
- **Multi-recombinacion**, donde más de dos padres son usados para producir uno o más descendientes.

Cuando se ha llevado a cabo el muestreo y la reproducción, la construcción de la población intermedia está completa y se procede a realizar la mezcla de soluciones. Para este proceso se aplica el operador de cruce (crossover) a parejas de individuos seleccionados.

Por ejemplo, si las siguientes cadenas (padres) son seleccionadas y se cruzan,

100 011110110
010 010011101

Entonces dos nuevas soluciones (hijos) se obtienen:

100 010011101
010 011110110

La mezcla se lleva a cabo seleccionando aleatoriamente un punto de las cadenas e intercambiando los trozos que quedan a derecha e izquierda de dicho punto. En el ejemplo se ha tomado el punto que se encuentra entre los bits número tres y número cuatro. Las cadenas que se cruzan se seleccionan utilizando la ruleta mostrada anteriormente, por lo que las soluciones con mayor aptitud poseerán más probabilidades de intervenir en cruces y, por lo tanto, de influir en las soluciones que formarán la siguiente generación. El cruce es un operador que realiza una búsqueda de soluciones no aleatoria, ya que este operador parte de

la información existente para obtener nuevas soluciones e intentar mejorar las soluciones que se han obtenido hasta entonces.

La tasa de cruce (CR) es el factor que determina el número de cadenas que se cruzan en cada generación. Si la población es N , entonces a $N \cdot CR$ cadenas se les aplica el operador de cruce en cada generación. El operador de cruce se ha creído ser la principal herramienta de búsqueda de algoritmos genéticos.

4.8.3.6 Operador mutación

En la evolución natural, la mutación es un proceso aleatorio cuyo objetivo es la introducción de nuevo material genético en un individuo existente; es decir, para añadir diversidad a las características genéticas de la población. Para cada bit en la población, existe una determinada probabilidad de que sea mutado. La tasa de mutación que suele utilizarse en los algoritmos genéticos es artificialmente alta, sin embargo, esta representa un valor pequeño, para garantizar que las buenas soluciones no estén distorsionadas demasiado. Mientras que en el proceso de la evolución natural la tasa de mutación es muy baja, en los algoritmos genéticos interesan tasas de mutación mayores, de no ser así, los algoritmos tardarían demasiado tiempo en converger.

La mutación añade un carácter aleatorio a la búsqueda de soluciones que realizan los algoritmos genéticos y es necesario para evitar que, tras unas pocas generaciones, todas las soluciones sean muy similares entre sí, lo cual puede producir un estancamiento del algoritmo genético en algún mínimo (o máximo) local del problema que se desea resolver. En el caso de los algoritmos genéticos, al no aplicar mutación, se alcanzan soluciones que no son capaces de evolucionar y mejorar al pasar de una generación a otra. Se produciría una convergencia prematura (óptimo local) y se alcanzaría, en algunos casos, una solución que podría encontrarse relativamente lejos del óptimo global.

Para este operador no se utiliza la ruleta mostrada anteriormente, ya que es un operador puramente aleatorio. No tiene en cuenta la presencia de la existencia de algunos individuos

de la población (soluciones) más fuertes (con mayor aptitud) que otros. Todos los bits de todas las cadenas poseen la misma probabilidad de sufrir una mutación. Por ejemplo, el efecto de la mutación en una cadena binaria:

10011**1**01101

Si la mutación afecta al bit número seis, la cadena que se obtiene es:

10011**0**01101

Ya que el bit número seis tenía un valor 1 y pasa a ser un valor 0. Si hubiese sido un 0 hubiese pasado a ser un 1.

La tasa de mutación (MR) es el número que determina las mutaciones que se producen en cada generación. Si N es la población y LC es la longitud de la cadena (número de genes) entonces $MR \cdot N \cdot LC$ bits cambian sus valores en cada una de las generaciones. Generalmente MR es pequeño comparado con la tasa de cruce.

CAPITULO 5. Resultados de simulación y conclusiones

5.1 Introducción

En este capítulo se presentan los resultados obtenidos en simulación así como los parámetros utilizados en la codificación del algoritmo genético, se habla sobre el grado de influencia que presentan los operadores del algoritmo (tasa de cruce, tasa de mutación y tamaño de la población) en el proceso de optimización, así como la elección de los valores adecuados de las tasas. En el proceso de optimización es preciso conocer cuándo debe considerarse que el proceso de búsqueda del algoritmo ha finalizado, por esta razón se estudian los criterios de parada para el algoritmo implementado. Finalmente se presentan los resultados para dos ejemplos de optimización con demanda constante de 1kW (un kilo Watt) y para el caso de una demanda variable.

5.2 Influencia de los parámetros de cruce y mutación del algoritmo genético

Una de las dificultades que pueden presentarse al utilizar algoritmos genéticos es la de una posible convergencia prematura, haciendo que el proceso de búsqueda se atasque en soluciones que no permitan alcanzar la solución óptima (mínimos locales). Es importante que al implementar los algoritmos genéticos se elijan tasas de cruce y mutación adecuadas, debido a que estos parámetros son los responsables de dar lugar a buenas soluciones.

En la literatura científica especializada se recomiendan determinados valores para las tasas de cruce y mutación que dan lugar a buenas soluciones (para la tasa de cruce de 0.4 a 0.9, y para la tasa de mutación valores de 0.001 a 0.01).

En el presente trabajo se ha partido de dichos valores y se han ido modificando hasta obtener soluciones que satisfacen de mejor manera el problema planteado. En los experimentos realizados se observa que, tasas de cruce altas arriba de 0.9 comienzan a reflejar una convergencia muy rápida del algoritmo hacia una solución. Por otra parte una tasa de mutación con valores entre 0.01 y 0.3 no refleja una tendencia marcada a converger prematuramente, sin embargo no es recomendable abusar de la tasa de mutación, ya que si

bien el operador de mutación nos ayuda a introducir nuevo material genético que no nos proporciona la tasa de cruce, el abuso en la tasa de este operador puede ocasionar que las soluciones no converjan, dado que tendríamos soluciones muy diferentes entre sí.

Otro factor que nos ayuda a generar diversidad y que además causa un impacto importante en la búsqueda de buenas soluciones, es el tamaño de la población. En la bibliografía especializada no se recomiendan ciertos valores específicos para la población, estos valores dependen del problema al que sean aplicados y el diseñador en base a su experiencia debe ajustarlos.

En las pruebas realizadas en este trabajo se utiliza una población de 600 individuos la cual nos genera un espacio de búsqueda adecuado para encontrar buenas soluciones, también se observa que a mayor tamaño de la población se ralentiza el algoritmo provocando mayor costo computacional y en consecuencia tiempos de análisis más prolongados.

5.3 Parámetros utilizados en el algoritmo genético

El algoritmo que se va a evaluar es el algoritmo genético con codificación real con las siguientes características:

- Operación de Ranking lineal.
- Operador de selección: Stochastic Universal Sampling.
- Tasa de cruce: 0.5
- Tasa de mutación: 0.2
- Máxima generación: 100
- Tamaño de la población: 600 individuos

En la figura 17 se muestra el diagrama de flujo del algoritmo genético implementado, donde muestra los pasos que se siguen en un algoritmo. Cabe mencionar que al haberse ejecutado las operaciones de selección, cruce y mutación se ha obtenido una nueva generación de individuos en el algoritmo genético.

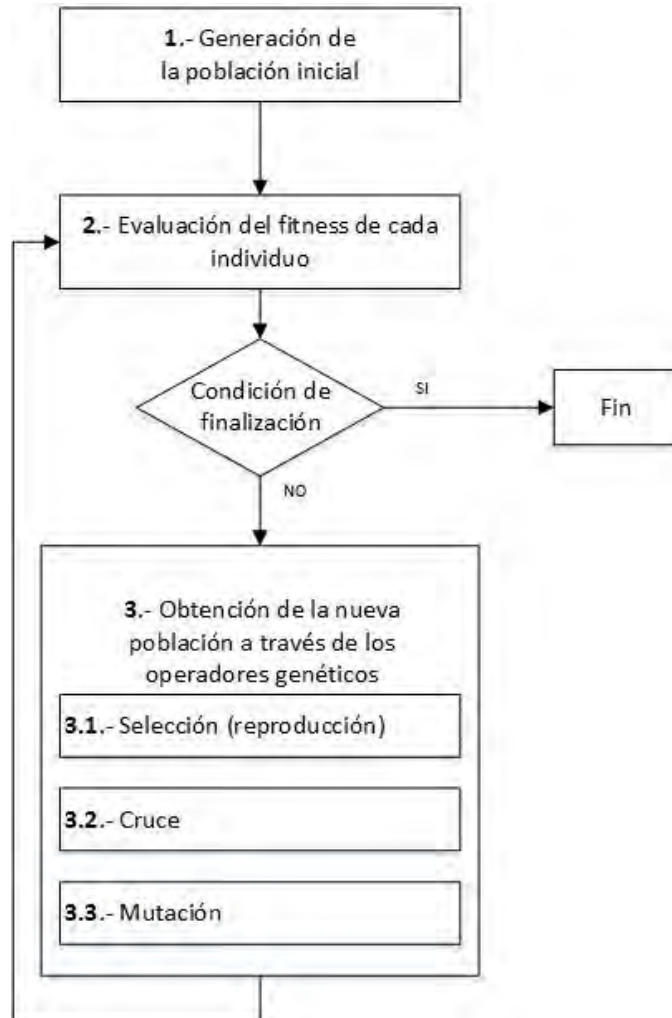


Figura 17. Diagrama de flujo del algoritmo genético implementado

5.4 Datos de entrada y población inicial del algoritmo genético

Los datos de entrada para la optimización del sistema híbrido con el algoritmo genético corresponden a los costos iniciales, costos de operación y mantenimiento de cada uno de los componentes del sistema. De igual forma, se introducen las eficiencias y tiempo de vida de cada elemento, así como del recurso eólico y solar disponible en el sitio además de la demanda de energía en cada hora por un periodo de 24 horas. El algoritmo genético determina el número de módulos del arreglo fotovoltaico así como la energía inicial de almacenamiento de hidrógeno necesario en el tanque para satisfacer la demanda de energía de la carga y satisfacer el LPSP deseado. Para ello, el optimizador genera dos vectores con n individuos (según el tamaño de la población, en este caso utilizamos 600 individuos) cada uno, donde un vector representa el número de módulos fotovoltaicos y otro corresponde a la energía inicial de almacenamiento de hidrógeno en el tanque, obteniendo así n combinaciones diferentes de módulos fotovoltaicos y energía almacenada inicial de combustible como la energía complementaria. Cada uno de los n sistemas es evaluado durante un periodo de 24 horas a partir de la estrategia de operación que muestra el diagrama de flujo de la figura 6.

En la tabla 2 se muestran los parámetros propuestos para la configuración del sistema híbrido de energía renovable.

Tabla 2. Parámetros del sistema propuesto

Parámetros del sistema	
Potencia nominal WTG (P_W)	4 kW
Potencia nominal FC	3 kW
Potencia nominal electrolizador	3 kW
Corte en la velocidad del viento (V_{ci})	2.5 m/s
Cut-in-Velocidad nominal del viento (V_{nom})	12.5 m/s
Cut out - Velocidad de corte de viento (V_{co})	20 m/s
Eficiencia aerogenerador (C_p)	0.5
Eficiencia de módulos fotovoltaicos (η_s)	0.20
Eficiencia de celda de combustible (η_{FC})	0.5
Eficiencia del inversor (η_{inv})	0.95
Eficiencia del electrolizador (η_{elec})	0.74
Precio aerogenerador	\$3000
Precio por modulo fotovoltaico	\$450
Precio celda de combustible	\$10000
Precio del electrolizador	\$10000
Precio del inversor	\$2500
Precio del tanque de reserva	\$2500
Costo operación y mantenimiento (O&M) turbina eólica	\$72/año
Costo operación y mantenimiento (O&M) módulos solares	\$10/mod/año
Costo operación y mantenimiento (O&M) celda de combustible	\$800/año
Costo operación y mantenimiento (O&M) electrolizador	\$70/año
Tasa de interés anual (i)	3.75 %
Tasa de inflación anual (f)	1.5 %
Tiempo de vida del proyecto (N_p)	20 años
Tiempo de vida del electrolizador y celda de combustible (N_H)	5 años

5.5 Criterios de parada para el algoritmo genético

Cuando se aplican algoritmos genéticos a un problema de optimización, es necesario determinar cuándo debe considerarse que el proceso de búsqueda de soluciones ha finalizado. Existen dos criterios, el primero es la detención del algoritmo cuando este ha alcanzado el máximo número de generaciones y el segundo criterio es cuando el 95 % de los individuos de la población están en un radio fijado alrededor del mejor individuo de esa población. Se estima que en esas condiciones el algoritmo se ha extinguido, ha perdido su capacidad de exploración.

Para el presente trabajo se ha decidido que el criterio de parada para el algoritmo genético sea cuando este haya alcanzado el número máximo de generaciones.

5.6 Análisis de resultados

Se presentan dos ejemplos de dimensionamiento con el método de optimización propuesto. El primer ejemplo considera una demanda constante de 1 kW y el segundo considera una demanda de energía variable. La figura 18(a) muestra los datos de insolación, la figura 18(b) muestra la velocidad de viento en un modelo de 24 horas promedio anual correspondiente a la ciudad de Chetumal, Quintana Roo, México ($18^{\circ}31'21.4''N$ $88^{\circ}16'11.3''O$). El perfil de la demanda eléctrica fue tomado de una serie de mediciones realizadas durante un periodo de un año y se muestra en la figura 19. Se asume que tanto la generación como la demanda de energía se mantienen constantes en cada intervalo de una hora.




Figura 18. (a) perfil de irradiancia. (b) perfil de viento.

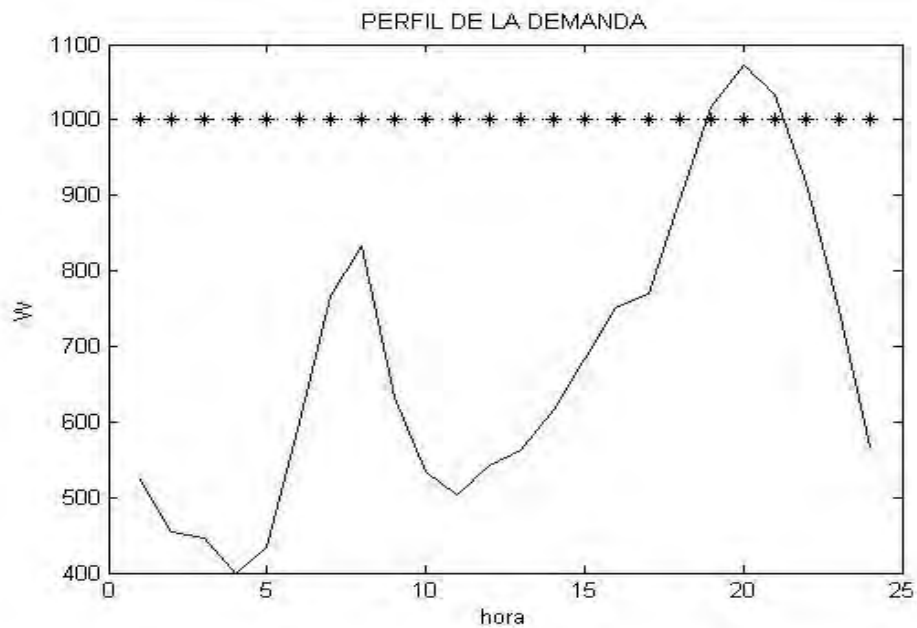


Figura 19. Perfil de la demanda eléctrica

En la figura 19 se observa el perfil de demanda eléctrica, la línea continua en color azul representa la demanda variable y la línea punteada marcada con (*) representa la demanda constante de 1kW.

Las figuras 20 y 21 muestran los resultados del sistema híbrido óptimo que cumple con satisfacer la energía demandada al costo más bajo. La figura 20 muestra los resultados para el ejemplo de la demanda constante de 1 kW y en la figura 21 para la demanda variable. La línea en color negro muestra la demanda de energía de la carga y las barras en color azul la energía entregada por el sistema híbrido. Se observa que las configuraciones óptimas del sistema híbrido satisfacen durante las 24 horas la demanda para ambos ejemplos.




Figura 20. Resultados para demanda constante de 1kW

En la figura 20 se observa que, la energía demandada por la carga es completamente suministrada por la configuración del sistema híbrido durante las 24 horas.

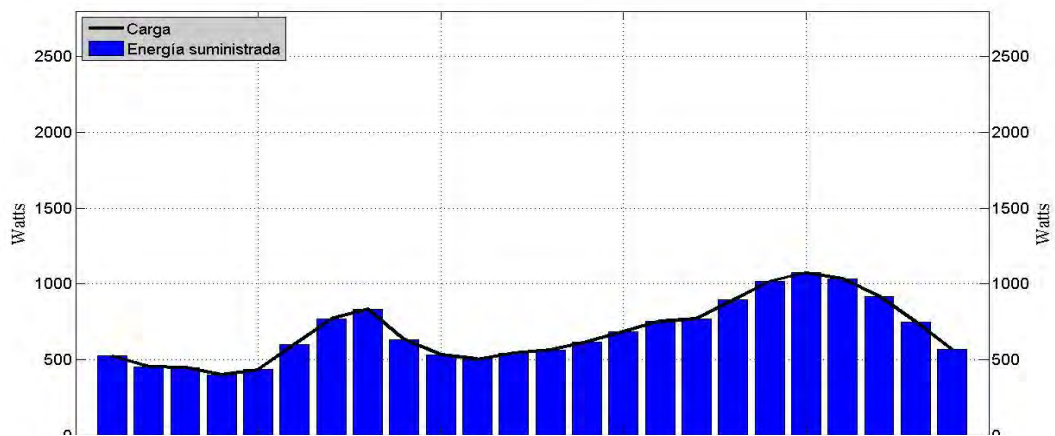


Figura 21. Resultados para demanda variable

En la figura 21 se observa que, el sistema híbrido suministra la energía necesaria para satisfacer la demanda variable para cada hora de operación.

Los resultados de la configuración y costos totales anualizados para las demandas constante y variable se muestran en las tablas 3 y 4.

Tabla 3. Configuración óptima del sistema para la demanda variable

		promedio	desviación	%
generadores eólicos	1	1	-----	-----
módulos	17	17.6093705	0.00052878	0.003
energía almacenada en tanque	4.58 kWh	5626.79744	192.335759	3.9
costo total (US\$)	3650.0792	3650.08293	0.01386384	0.0003

La configuración óptima del sistema comprende 17 módulos fotovoltaicos, un generador eólico de 4kW y una celda de combustible de 3kW que suministran energía para una carga residencial variable a lo largo de un año, usando un generador de hidrogeno de 3kW (electrolizador). El costo total anualizado se estima en \$3650.1 dólares por 20 años.

Tabla 4. Configuración óptima del sistema para la demanda constante

		promedio	desviación	%
generadores eólicos	1	1	-----	-----
módulos	28	28.3719905	0.00175056	0.006
energía almacenada en tanque	8.72 kWh	8868.99091	92.8589136	1.04
costo total (US\$)	3932.5116	3932.52388	0.04594755	0.0011

La configuración óptima para el sistema con demanda constante comprende 28 módulos fotovoltaicos, un generador eólico de 4kw, un electrolizador de 3kW y una celda de combustible de 3 kW. El costo total anualizado del sistema se estima en \$3932.5 dólares por 20 años. El código computacional para realizar este trabajo fue implementado en Matlab y ejecutado en una computadora personal con procesador intel core i3 de 1.8 GHz y 4 GB de memoria RAM.

La energía almacenada en el tanque para los casos de demanda variable y constante se muestra en las figuras 22 y 23. En ambos casos se observa que los sistemas mantienen en promedio el valor inicial de la energía contenida en el tanque de almacenamiento y que durante el periodo de tiempo analizado la energía en el tanque es mayor a cero, lo cual es benéfico para los intereses de este trabajo dado que, el sistema cumple con el suministro de energía por parte del sistema de generación y de almacenamiento.

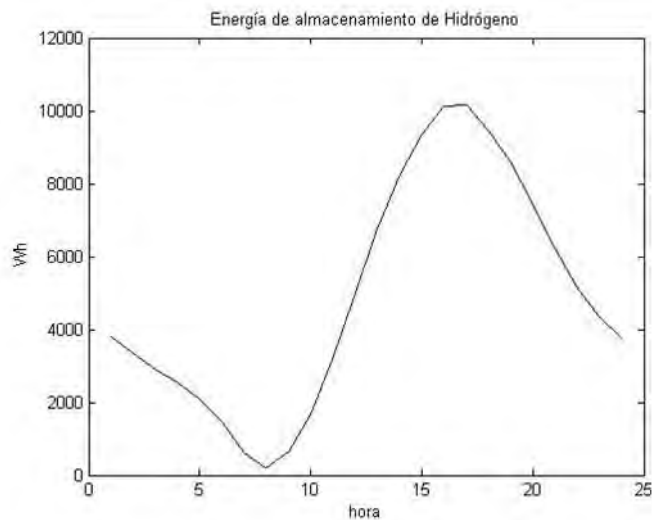


Figura 22. Gráfica de la energía equivalente de hidrogeno para el caso de la demanda variable




Figura 23. Gráfica de la energía equivalente de hidrogeno para el caso de la demanda constante

5.7 Conclusiones

Se ha presentado el dimensionamiento óptimo de un sistema de generación híbrido formulado mediante un problema de optimización, resuelto mediante un algoritmo genético, encontrando la mejor configuración del sistema que satisface el compromiso confiabilidad en el suministro de energía-costos del sistema.

Los resultados de la simulación del funcionamiento del sistema indican que la baja eficiencia del electrolizador y la celda de combustible ocasionan la necesidad de una alta capacidad de almacenamiento de energía en hidrógeno con respecto a la carga, además de una mayor capacidad de generación de energía.

El uso del hidrógeno como medio de almacenamiento de energía tiene un impacto ambiental importante. El desarrollo de nuevos materiales para el uso en electrolizadores y celdas de combustible que los hagan más eficientes impactará de forma importante en la eficiencia del sistema de almacenamiento de energía y el desempeño completo del sistema.

El algoritmo genético permite una manera fácil de optimizar sin un conocimiento profundo entre la relación de los costos del sistema de generación y la potencia generada por las diferentes fuentes.

El algoritmo genético es un método robusto ya que presenta un amplio grado de habilidad en la resolución de gran variedad de problemas de optimización. Sin embargo, si existe un buen método de optimización especializado para un problema concreto, entonces el Algoritmo Genético puede no ser la mejor herramienta de optimización para dicha aplicación.

Referencias

- A. Keyhani, M. N. (2010.). *Integration of green and renewable energy in electric power systems*. John Wiley and Sons, Inc.
- B.S. Borowy and Z.M. salameh. (1996.). *Methodology for optimally sizing the combination of a battery bank and PV array in a Wind/PV hybrid system*, *IEEE T Energy Conver*.
- C. W. Gellings. (2009). *The smart grid. Enabling energy efficiency and demand response*. The Fairmont Press Inc.
- D.B. Nelson, e. a. (2006). *Unit sizing and cost analysis of stand-alone hybrid wind/PV/fuel cell power generation systems*.
- Dufo Lopez R. (2007). *Dimensionamiento y control óptimos de sistemas híbridos aplicando algoritmos evolutivos*.
- Engelbrecht, P. A. (2007). *Computational intelligence an introduction*.
- Ferragud, F. (2012). *Control predictivo basado en modelos mediante técnicas de optimización heurística. Aplicación a procesos no lineales y multivariables*. Obtenido de <https://riunet.upv.es/bitstream/handle/10251/15995/tesisUPV1042.pdf?sequence=1>
- I. Abouzahr and R. Ramakumar. (1991). *Loss of power supply probability of stand-alone photovoltaic systems: a closed form solution approach*, *IEEE T. Energy Conver*.
- J. Samaniego, F. A. (2008). *Renewable Energy* .
- Lücken M.C.D. (2003). *algoritmos evolutivos para optimización multiobjetivo: un estudio comparativo en un ambiente paralelo asíncrono*.
- M. Munsell. (2 de marzo de 2015). Obtenido de <http://www.greentechmedia.com/research/report/global-pv-pricing-outlook-2015>
- Melanie, M. (1999). *An Introduction to Genetic Algorithms*.
- Qing, A. (2009). *Differential Evolution: Fundamentals and Applications in Electrical Engineering*.
- R. Strzelecki, G. B. (2008.). *R. StrzelecPower Electronics in Smart Electrical Energy Networks*. Editorial Springer London. .

Sánchez VM, e. a. (2009). dimensionamiento de un sistema de generación aislado eólico-solar-celda de combustible basado en el método de optimización de enjambre de partículas.

Sanchez VM, e. a. (2014). *Techno-economical optimization based on swarm intelligence algorithm for a stand-alone wind-photovoltaic-hydrogen power system at south-east region of Mexico*. Obtenido de <http://dx.doi.org/10.1016/j.ijhydene.2014.06.034>

