



UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS
INSTITUTO DE INVESTIGACIÓN EN CIENCIAS BÁSICAS Y APLICADAS
CENTRO DE INVESTIGACIONES EN INGENIERÍA Y CIENCIAS APLICADAS

**OPTIMIZACIÓN MULTI VARIABLE DE UN TRANSFORMADOR TÉRMICO CON
RECICLADO DE CALOR USANDO ALGORITMOS GENÉTICOS EN LA RED
NEURONAL ARTIFICIAL INVERSA**

TESIS PROFESIONAL
PARA OBTENER EL GRADO DE:

MAESTRO EN INGENIERÍA Y CIENCIAS APLICADAS

PRESENTA:
L. I. ULISES CRUZ JACOBO

ASESORES:
DR. JOSÉ ALFREDO HERNÁNDEZ PEREZ
DR. ROBERTO AGUSTÍN CONDE GUTIÉRREZ

SINODALES:
DRA. ARIANNA PARRALES BAHENA
DR. LUIS MANUEL GAGGERO SAGER
DR. ALBERTO ÁLVARES GALLEGOS

CUERNAVACA MOR.

AGOSTO 2018

RESUMEN

En la presente investigación, se optimizaron los valores de múltiples variables (3) de un transformador térmico por absorción (HTA), con reciclado de calor, utilizando como herramienta para optimizar Algoritmos Genéticos (GA) en una Red Neuronal inversa (ANNi), con el objetivo de incrementar su coeficiente de eficiencia (COP). Para tal efecto se desarrollaron los modelos correspondientes a la fase experimental mediante el entrenamiento de una Red Neuronal Artificial del tipo feed-forward, del modelo resultante se utilizan los valores de pesos y bias de las capas de entrada y salida, con estos valores se desarrolla el segundo modelo, la inversa, la ANNi, el tercer modelo es el generador de soluciones creado haciendo uso de GA.

Al entrenar, probar y validar la ANN, esta es capaz de predecir el valor del COP experimental del HTA, con reciclado de calor, considerando como entradas del sistema a la ANN, las temperaturas de entrada y salida de los componentes principales, de la misma forma las presiones y concentraciones registradas de la solución de trabajo; la arquitectura de red que presento resultados más precisos fue al aplicar la función de activación TANSIG en las tres neuronas de la capa oculta, logrando obtener un coeficiente de determinación R^2 de 0.9935 y además un MAPE de 1.04%, relacionando los datos experimentales y los datos simulados, mostrando una fuerte correspondencia entre ambos grupos de datos.

En las pruebas de optimización usando ANNi-GA se logró obtener incrementos en el valor del COP. Optimizando dos variables se obtiene un incremento del 0.34 a 0.38 en el valor del COP. Al optimizar tres variables el incremento del valor del COP se alcanza un incremento hasta el 0.43 del valor del COP..

ABSTRACT

This work presents an application of an inverse artificial neural network (ANNi) and genetic algorithm (GA) to perform a multi-objective optimization of an absorption heat transformer (AHT) with energy recycling as well as increase its coefficient of performance (COP). AHT use waste heat sources to obtain useful energy, by recycling part of the useful energy within the same system provides an increase in performance. An artificial neural network (ANN) was developed to predict the value of COP, based on experimental data from the equipment. A satisfactory agreement was obtained by comparing the simulated and experimental data. With the ANN model consolidated an ANNi and multi-objective optimization was applied, where the variables to be optimized were: temperature in the generator, temperature in the evaporator and temperature in the condenser. GA was chosen to solve the multi-objective functions. The results showed that when applying the ANNi-GA methodology, it is possible to carry out the multi-objective optimization since this methodology had only been used to optimize one variable at a time. The temperature in the generator turned out to be the key variable to increase the performance of AHT, followed by the evaporator and condenser, reaching a maximum value of COP of 0.43. The optimal conditions found represent a better control of the variables and a saving of energy. Finally the GA solved satisfactorily the multi-objective function proposed, making feasible the use of this tool to optimize different variables at the same time.

AGRADECIMIENTOS

Con la elaboración final de este trabajo de investigación quiero agradecer sinceramente a todos los que depositaron su confianza en mí y que me impulsaron para continuar esforzándome día a día, hasta culminar esta tesis.

Al DR. JOSÉ ALFREDO HERNÁNDEZ, por confiar en mi persona, apoyarme y creer que podía alcanzar esta meta.

Al Centro de Investigación en Ciencias Aplicadas, por permitirme realizar los estudios de maestría.

Al DR. ROBERTO AGUSTIN CONDE GUTIERREZ, por su paciencia y dedicación en enseñarme la labor de un investigador.

A mi sinodal el DR LUIS MAUEL GAGGERO SAGER, por su brindarme su conocimiento y experiencia como académicos de este centro de investigación.

Al CONSEJO NACIONAL DE CIENCIA Y TECNOLOGÍA, por la beca que me otorgo y de esta manera poder desarrollar este trabajo de investigación y obtener el grado académico

DEDICATORIAS

A DIOS, fortalecer mi fe, y por permitirme despertar cada día con la fuerza suficiente para seguir adelante.

A mi PADRE, que seguro está viendo este momento y quien me enseñó a no rendirme, a ser tenaz porque no importa que sea el intento 1000, lo importante es no rendirse, te quiero Carlitos.

A mi MADRE quien me dio la vida y me ha seguido apoyando sin importar lo difícil que sea.

A Raque, que a pesar de las dificultades no permitió que me derribaran, por tu apoyo Vida.

Finalmente a Ximena, Diego y Regina, que son mi más preciado tesoro y mi esperanza.

INDICE GENERAL

RESUMEN.....	i
ABSTRACT.....	ii
AGRADECIMIENTOS	iii
DEDICATORIAS	iv
INDICE GENERAL.....	v
LISTA DE TABLAS.....	vii
LISTA DE FIGURAS	viii
CAPITULO 1	1
INTRODUCCIÓN.....	1
1.1 JUSTIFICACIÓN	2
1.2. OBJETIVO GENERAL	3
1.3 OBJETIVOS ESPECIFICOS	3
CAPITULO 2	4
2. MARCO TEORICO.....	4
2.1 TRANSFORMADORES TERMICOS.....	4
2.1.1 CICLO DE CARNOT	4
2.1.2.TRANSFORMADORES TÉRMICOS.....	6
2.2 REDES NEURONALES ARTIFICIALES (ANN)	9
2.2.1. BASES BIOLÓGICAS.....	15
2.2.2. TIPOS DE ESTRUCTURA DE UNA ANN.....	18
2.2.3. ENTRENAMIENTO SUPERVISADO DE LA RNA.....	20
2.2.4. DESARROLLO DEL MODELO DE LA ANN	22
2.3. INVERSA DE LA RED NEURONAL ARTIFICIAL (ANNi)	25
2.3.1. ANTECEDENTES	26
2.3.2.PLANTEAMIENTO DE LA ANNi PARA OPTIMIZAR UNA VARIABLE.....	26
2.3.3.PLANTEAMIENTO DE LA ANNi PARA OPTIMIZAR MULTI VARIABLES.....	28
2.4. ALGORITMO GENÉTICO GA.....	30

2.4.1. BASES BIOLÓGICAS.....	31
2.4.2. FUNCIONAMIENTO DEL GA	32
2.4.3. OPERADORES GENÉTICOS	33
3.2. MODELO DE ANNi.	37
3.3. MODELO GA COMO GENERADOR DE SOLUCIONES.....	43
3.4. ACOPLAMIENTO DEL MODELO DE LA RED NEURONAL INVERSA Y EL ALGORITMO GENÉTICO	44
CAPITULO 4	49
4. DATOS EXPERIMENTALES	49
4.1. ANÁLISIS	49
5. APLICACIÓN DE LA METODOLOGÍA HIBRIDA EN UN TRANSFORMADOR TÉRMICO POR ABSORCIÓN CON RECICLADO DE CALOR.....	51
6. RESULTADOS.....	55
6.1. OPTIMIZACIÓN DE UNA VARIABLE USANDO ANNi-GA.....	55
6.2. OPTIMIZACIÓN DE DOS VARIABLES USANDO ANNi-GA.	57
6.3. OPTIMIZACIÓN DE TRES VARIABLES USANDO ANNi-GA.....	59
7. CONCLUSIONES.....	62
8. REFERENCIAS.....	64

LISTA DE TABLAS

1. Tabla 1 Funciones de transferencia	15
2. Tabla 2. Intervalos de las condiciones de operación experimentales usadas para calcular el valor del COP.	53
3. Tabla 3. Búsqueda de la mejor arquitectura y de la función de activación, para obtener la mejor predicción del valor del COP.	39
4. Tabla 4 Ajuste de parámetros empleados en el modelo ANNi-GA.	48
5. Tabla 5 Pruebas experimentales elegidas a las que se les aplico el modelo ANNi-GA.	49
6. Tabla 6 Comparación entre los valores experimentales y los obtenidos por el modelo ANNi-GA para una variable a la vez.	50
7. Tabla 7 Comparación entre los valores experimentales y los obtenidos por el modelo ANNi-GA para dos variables a la vez.	50
8. Tabla 8 Comparación entre los valores experimentales y los obtenidos por el modelo ANNi-GA para tres variables a la vez.	51
9. Tabla 9 Aplicación del modelo ANNi-GA para incrementar el valor Del COP optimizando una variable a la vez.	59

LISTA DE FIGURAS

1. Figura 1. Esquema de una máquina de Carnot, a) Enfriamiento, b) Calentamiento	6
2. Figura 2 Esquema de un transformador térmico por absorción para obtener agua destilada.	8
3. Figura 3 Estructura de una Red Neuronal Artificial básica	14
4. Figura 4 Esquema de la estructura básica de una neurona.	18
5. Figura 5 Organización jerárquica del sistema nervioso	19
6. Figura 6 Red Neuronal Artificial simple.	21
7. Figura 7 Red Neuronal Artificial multicapa.	22
8. Figura 8 Red Neuronal Artificial recurrente	23
9. Figura 9 Diagrama de bloques del proceso de aprendizaje supervisado	24
10. Figura 10. Efecto del sobre aprendizaje en el entrenamiento de una RNA.	25
11. Figura 11 Esquema de una Red Neuronal Artificial inversa	30
12. Figura 12 Codificación de un individuo genético	36
13. Figura 13. Esquema de la función inversa de la ANN en función de los pesos y bias generados previamente	41
14. Figura 14. Diagrama esquemático del modelo ANNi para optimizar una variable	44
15. Figura 15. Diagrama esquemático del modelo ANNi para optimizar dos variables	45
16. Figura 16. Diagrama esquemático del modelo ANNi para optimizar tres variables	46
17. Figura 17 Diagrama de flujo general para programar un AG	47
18. Figura 18 Acoplamiento ANNi-GA para optimizar múltiples variables de entrada	52
19. Figura 19 Esquema de la estrategia de optimización de múltiples variables	55
20. Figura 20 Diagrama general de obtención de una red neuronal artificial	56
21. Figura 21 Acoplamiento del algoritmo de búsqueda a la de optimización	58
22. Figura 22. La optimización para dos variables usando el modelo de ANNi-GA, aplicado a tres pruebas experimentales con valores de COPEXP a)0.26, b)0.29 y c)0.34	61
23. Figura 23. Optimización de tres variables usando el modelo ANNi-GA, aplicado a tres pruebas experimentales con valores de COPEXP, a) 0.26, b) 0.29 c) 0.34.	63

CAPITULO 1

INTRODUCCIÓN

En la actualidad el medio ambiente de nuestro planeta experimenta cambios drásticos en los diversos ecosistemas estos cambios climáticos afectan la forma de vivir de los seres vivos. El año 2016, fue registrado como el año más cálido con un incremento de 0.99 ° C en la temperatura global de acuerdo con la Administración Nacional de la Aeronáutica y del Espacio (NASA, por sus siglas en inglés). El incremento en la temperatura global se ven reflejados con el incremento de la temperatura, provocando sequías y problemas por falta de agua potable. Las actividades que contribuyen con este cambio climático centran principalmente en actividades que realizan los seres humanos a diario. Dichas actividades cumplen con el fin de satisfacer sus necesidades como vestimenta, comida, muebles, transporte, etc., implementando procesos industriales que permitan cubrir la alta demanda de dichas necesidades. Las industrias de manera continua emiten desechos contaminantes al medio ambiente ya que transforman la materia y/o la energía. Uno de los compuestos que mayor cantidad es emitida a la atmósfera es el dióxido de carbono uno de los más comunes provocando que las emisiones de calor permanezcan cerca de la superficie de la tierra que a su vez, son calentados por la radiación del sol, provocando un efecto invernadero. El dióxido de carbono es el gas de efecto invernadero más común, ya que es producido por la mayoría de los procesos industriales debido al uso de combustibles fósiles. Se considera que para el año 2040 el consumo de energía a nivel global se incrementará en un 48 %, de acuerdo con agencia de la Administración de Información Energética (EIA, por sus siglas en inglés). Los combustibles fósiles seguirán siendo los más utilizados, por lo tanto, el cambio climático seguirán incrementándose. En México, la producción de energía primaria se basa en este tipo de combustibles fósiles al utilizar cerca del 92 % registrado en 2015 por el Sistema de Información Energética (SENER). Al ser un país con yacimientos petroleros se abusa de este recurso, sin contemplar los efectos negativos producidos al medio ambiente. Por esta razón, se ha decidido aumentar el uso de energías renovables en México que generan el 25% de la electricidad; cifra que debe aumentar a 35% para el 2024 para cumplir con la Ley de Cambio Climático aprobada en 2013.

Con base en la información anterior, se concluye que es necesario fomentar el uso de las energías renovables en los procesos industriales para combatir el cambio climático, pero este es un tema complejo ya que afecta un sin número de intereses en cada país. Resulta ser más económico emplear combustibles fósiles en los procesos industriales que instalar fuentes de energía renovable y esto debido a que la tecnología necesaria para emplear la energía sustentable es aun costosa, debido a que aún no alcanza un nivel de eficiencia alto, por lo que es necesario adquirir varios equipos que den abasto a los requerimientos industriales. Con la problemática planteada, una solución inmediata y redituable para reducir el problema de la contaminación, se encuentra en implementar equipos y sistemas inteligentes de optimización en las industrias.

El objetivo es maximizar la eficiencia de los equipos y minimizar la energía empleada en los procesos industriales, logrando reducir el consumo de los combustibles fósiles y reducir los gases que provocan el efecto invernadero. Los dueños de las grandes industrias e incluso en todo proceso que se requiera el uso de algún tipo de combustible para accionar un sistema se vuelve más rentable con la adquisición e implementación de equipos recicladores de energía, ya que hacen posible el reúso de energía (térmica por lo general) dentro de la misma industria. Pero aún más importante, si se cuenta con un sistema inteligente de optimización es factible lograr que la energía y recursos empleados en las industrias se utilicen al máximo, con la finalidad de que se optimicen los recursos en la operación de los procesos y se incremente la producción, obteniendo una mayor ganancia y conveniencia para los dueños de la industria.

1.1 JUSTIFICACIÓN

Maximizar la eficiencia (COP) de un transformador térmico por absorción, mediante la optimización de hasta tres variables internas, que permitan modificar las condiciones de operación del equipo, de acuerdo a las características de operación experimental, al incrementar la eficiencia en consecuencia disminuye los gases contaminantes.

1.2. OBJETIVO GENERAL

Desarrollar el modelo que permita optimizar hasta 3 variables al mismo tiempo haciendo uso de una red neuronal inversa y algoritmos genéticos, aplicando estos modelos a un transformador térmico.

1.3 OBJETIVOS ESPECIFICOS

Obtener el modelo matemático del entrenamiento de la red neuronal haciendo uso de la base de datos experimental.

Obtener a partir del entrenamiento previo la función objetivo para optimizar una, dos y hasta 3 variables a la vez.

Generar el algoritmo genético que permita resolver las funciones objetivo, generando soluciones dentro del intervalo de operación del transformador térmico.

CAPITULO 2

2. MARCO TEORICO

2.1 TRANSFORMADORES TERMICOS

Los transformadores térmicos por absorción, tienen un auge actualmente debido sus características como son, aprovechamiento de recursos considerados desecho como ejemplo el calor residual en la mayoría de los procesos industriales, aunado a esto cuenta puede hacer suso de diversas fuentes de energía térmica (solar y geotérmica), a estas capacidades, agregamos el hecho de que utiliza menos electricidad y emite menos gases contaminantes como es el CO₂, además de usar refrigerantes no contaminantes, con lo que la afectación al medio ambiente es significativamente menor que con el uso de otras tecnologías.

Dado el incrementos en los costos de los energéticos de origen fósil, es un factor más que permitirá que el uso de este dispositivo multiplicador de calor se incremente, al hacer uso en mayor medida de energía de recicle en lugar de energía nueva.

2.1.1 CICLO DE CARNOT

A finales del siglo XVIII, las máquinas con base al trabajo derivado de la energía térmica, como la locomotora, buques, transportes y maquinaria industrial se movían en función al uso de carbón con el que se producía vapor, con lo que se realizaba un trabajo específico.

El uso de carbón para generar vapor y trabajo traía consigo un problema particular, que consistía en ¿cómo poder calcular la cantidad máxima de trabajo? que podría producir en una cantidad dada de combustible.

Nicolás Carnot, nacido el 1 de junio de 1796 en París Francia, un ingeniero militar resolvió este problema de forma deductiva, sin la implementación de un método

experimental que lograra obtener la máxima eficiencia de una máquina de vapor [1]. Carnot crea una formulación matemática de la segunda ley, en estas deducciones Carnot define el calor como un fluido “calórico”.

Definiendo la máquina de calor para cualquier dispositivo que transforma el calor en trabajo, se realizan tres tareas básicas:

- Absorción de calor de un depósito a una temperatura constante.
- Eliminación de calor hacia una salida de temperatura fría contante
- Realización del trabajo

Dentro de las máquinas de calor se encuentran las bombas de calor. La máquina de calor de Carnot es una máquina reversible de tal manera que, si se hace funcionar en un sentido, como se muestra en la **Figura 1 a)** donde se lleva el calor de una temperatura alta a una temperatura baja, y si se hace funcionar en sentido inverso **b)** lleva el calor de una temperatura baja a una temperatura alta.

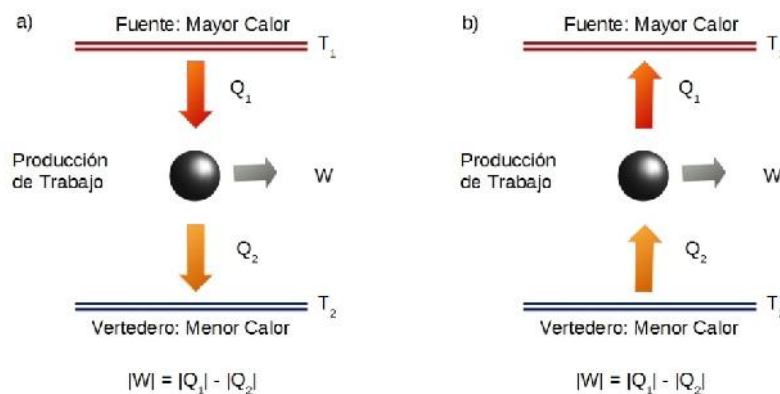


Figura 1. Esquema de una máquina de Carnot, **a)** Enfriamiento, **b)** Calentamiento

Las bombas de calor [2] son multiplicadores del calor, y el índice por el cual se mide la eficiencia de este dispositivo es el Coeficiente de Operación (COP). La clasificación de estos dispositivos es:

- a) Bombas de calor tipo 1 (Refrigeración)

b) Bombas de calor tipo 2 (Calefacción)

2.1.2. TRANSFORMADORES TÉRMICOS

Los componentes básicos para que funcione un transformador térmico tipo 2 por absorción (HTA, por sus siglas en inglés), consisten de un generador, condensador, evaporador, intercambiador de solución (economizador) y absorbedor. Tanto en el generador como el evaporador se suministra directamente el calor residual proveniente de un proceso industrial, con el fin de calentar una mezcla química que activa un ciclo termodinámico y a partir de éste, se aprovecha el calor útil proveniente del absorbedor. La relación entre el calor útil obtenido y calor suministrado es conocida como coeficiente de operación o rendimiento (COP, por sus siglas en inglés), la cual es una medida de eficiencia del transformador térmico por absorción.

Una vez acoplados los componentes básicos del transformador térmico por absorción, el funcionamiento del ciclo termodinámico es cerrado, ya que una vez finalizada la interacción entre los componentes los cuales operan bajo dos presiones distintas (baja y alta) se reinicia el ciclo. La base principal de los transformadores térmicos por absorción consiste en utilizar una mezcla química, conocida como solución de trabajo, la cual, se basa en la capacidad de ciertas sales y líquidos de absorber fluido refrigerante. La solución química más utilizada es la solución LiBr-H₂O. El ciclo inicia en el generador, el cual opera a una presión baja y cuya función es recibir el calor residual de baja calidad, ya que en su interior se encuentra la mezcla del fluido refrigerante y absorbente, que al calentarse por el calor residual comienza a evaporarse el fluido refrigerante de la solución. La mezcla absorbente sale del generador con mayor concentración y se envía al absorbedor. Por otro lado, el refrigerante evaporado se envía al condensador, que opera a la misma presión que el generador, donde se retira energía al medio ambiente. El

condensado se envía al evaporador, donde se le suministra nuevamente calor de desecho, pero este componente opera a una mayor presión, con el propósito de evaporar el condensado y enviarlo al absorbedor. El absorbedor opera bajo la misma presión que el evaporador y su función consiste en llevar a cabo una reacción exotérmica, esto sucede cuando entran en contacto la mezcla concentrada proveniente del generador y el vapor proveniente del evaporador, teniendo una elevación de temperatura y de esta manera producir energía a una mayor temperatura que aquella del calor de desecho, es decir, la energía útil del sistema para ser utilizada. Finalmente, la mezcla regresa al generador de manera diluida para reiniciar el ciclo termodinámico **Figura 2**. Entre el absorbedor y generador se añade un intercambiador de calor de soluciones, mejor conocido como economizador, ya que permite utilizar el calor sensible de la reacción exotérmica y aplicarlo en la mezcla concentrada que proviene del generador con el fin de incrementar la eficiencia del ciclo.

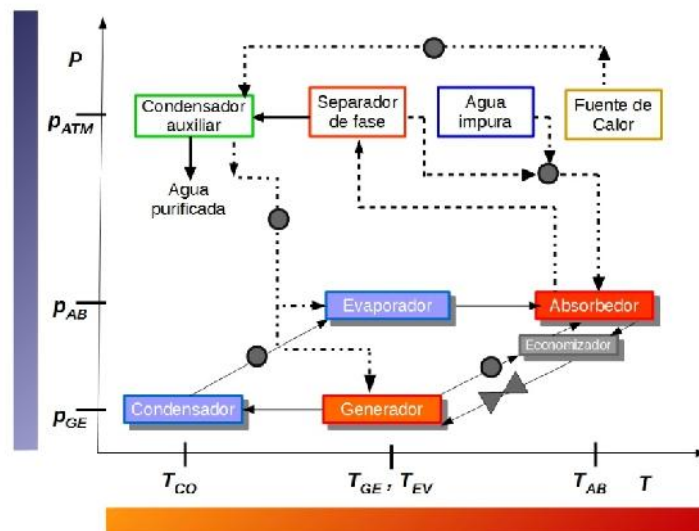


Figura 2 Esquema de un transformador térmico por absorción para obtener agua destilada.

Con la determinación del COP, se conoce el desempeño de un transformador térmico por absorción, la cual es descrita por la siguiente **Ecuación (1)**:

$$C = \frac{Q_A}{(Q_G + Q_E)} \quad (1)$$

Entre las ventajas de este tipo de bombas de calor son las siguientes:

- a) Usan poca energía mecánica
- b) Sencillez de los dispositivos que lo forman.
- c) A partir de los datos térmicos, su diseño no representa un grado alto de complejidad.

Un transformador térmico por absorción (HTA) puede elevar la temperatura de niveles bajos hasta niveles entre 60°C a 100°C, además se logra recuperar aproximadamente el 50% del calor de desecho.

Aunado al valor del COP de un HTA es necesario tener en cuenta los siguientes parámetros:

Elevación total de temperatura (GTL, por sus siglas en inglés), la cual es la diferencia entre las temperaturas del absorbedor y el evaporador.

Relación de Flujo (FR, por sus siglas en inglés), definido como la relación del flujo másico de la solución proveniente del absorbedor con el flujo másico del fluido de trabajo. Esta relación se puede expresar con respecto a las concentraciones de la mezcla de trabajo. En donde (X), es la concentración del fluido absorbente.

$$G = T_A - T_E \quad (2)$$

$$F = X_G / (X_G - X_A) \quad (3)$$

2.2 REDES NEURONALES ARTIFICIALES (ANN)

Al trabajar con redes neuronales artificiales (ANN), es normal que nos refiramos a ellas como “Redes Neuronales”, esto con la finalidad de relacionarlas con el cerebro humano, en el cual se ha basado el diseño de estas. El cerebro es una computadora altamente compleja, no lineal y con capacidad de realizar trabajos en paralelo, tiene la capacidad de organizar a las neuronas (su unidad básica), de tal forma que pueda realizar cálculos (reconocimiento de patrones, control de movimientos, percepción sensorial), muchas veces más rápido que la más rápida de las computadoras que existan al día de hoy [3]. Como ejemplo el sentido de la visión, la cual tiene la tarea de procesar información, para proveer una representación del ambiente alrededor en el que se encuentra el ser humano, siendo específico el cerebro humano empalma de manera rutinaria tareas de reconocimiento, (reconocer el rostro de un familiar dentro de una escena poco familiar), en aproximadamente 100 a 200 ms, una tarea muy compleja. Para tener un mejor desempeño, las Redes Neuronales realizan interconexiones masivas entre las células de computo más simples en el cerebro humano “la neurona”. De manera general una Red Neuronal Artificial, es una máquina que se diseña con la finalidad de modelar la manera en la que el cerebro realiza una tarea determinada. Una Red Neuronal Artificial (ANN), es un procesador masivo en paralelo, hecho a partir de simples unidades de proceso, que tienen la propiedad natural de almacenar o contener experiencia / conocimiento, que puede ser utilizada.

El modelo RNA involucra la interacción de neuronas artificiales repartidas en diferentes capas. Como sucede en el cerebro humano, las neuronas artificiales al estar conectadas entre sí se pasan información y cada conexión conlleva un valor numérico conocido como valor de peso y se le suma un factor llamado bia (valor adicional). Algunas de las ventajas por las cuales se caracterizan las RNA son las siguientes [4,5]:

Las ANN tienen las siguientes capacidades y características.

No linealidad, la no linealidad es un tipo especial de sentido que es el pensamiento distribuido a través de la red, es una propiedad muy importante, en particular si se encuentra por debajo del mecanismo de respuesta física para la generación de la señal de entrada.

Entrenamiento supervisado, (Mapeo de entradas / salidas), un paradigma de aprendizaje llamado “aprendizaje no supervisado”, que involucra el cambio de los pesos en las conexiones sinápticas de la red neuronal, mediante la aplicación de un grupo de ejemplos de entrenamiento previamente conocidos. Cada ejemplo consiste de una única señal de entrada. Se le muestra a la Red una selección aleatoria de total de los datos, con esto los pesos de las conexiones sinápticas de la red se modifican de tal manera que minimice la diferencia entre la respuesta deseada y la respuesta actual que emite la red. El entrenamiento de una red se repite con muchos ejemplos, hasta que la red alcance el estado estable en donde no encuentra cambios significativos en los pesos de las sinápticas.

Adaptable. Las Redes Neuronales Artificiales tienen implícita la capacidad de adaptar sus conexiones sinápticas, de acuerdo al medio ambiente. De manera particular una ANN es entrenada para operar en un medio ambiente específico, puede ser fácilmente reentrenada para trabajar con un cambio mínimo en la operación de acuerdo a las condiciones del medio ambiente. Más allá de esto, cuando se está operando en un medio ambiente no invariable, la Red Neuronal Artificial, puede diseñarse para que modifique los valores de sus conexiones sinápticas en tiempo real.

Respuesta probada; en el contexto de clasificación de patrones, una Red Neuronal Artificial, puede diseñarse para proveer información, no solo sobre el patrón seleccionado, también sobre el grado de confianza en la decisión que se tomó.

Información Contextual; el conocimiento se representa por cada una de las estructuras y el estado de activación de la ANN. Cada una de ellas neuronas en la red potencialmente puede ser afectada por la actividad total de cada una de las otras neuronas dentro de la ANN, en consecuencia la información es repartida de manera natural en todas las neuronas de la ANN.

Tolerancia a fallos; una ANN implementado en el hardware tiene el potencial de ser tolerante a fallos o capaz de tener un proceso de computo robusto, en el sentido de que el rendimiento se degrada mínimamente bajo condiciones adversas.

VLSI (Very Large Scale Integrated); por su naturaleza la ANN puede realizar la paralización masiva con lo que potencialmente puede realizar tareas de forma más rápida otro de sus beneficios es que puede realizar la capturar comportamientos verdaderamente complejos. Uniformidad en el análisis y diseño.

Análisis y Diseño uniforme, las ANN son reconocidas universalmente como procesadores de información, ahora bien el sentido de usar esta definición es que se manifiesta en diferentes formas:

- Neuronas, de una manera u otra, representa un componente común en todas las ANN.
- Esto en común hace posible que comparta teorías y algoritmos de aprendizaje en las diferentes aplicaciones para las ANN.
- Modularidad de las redes, pueden construirse a través de módulos integrados.

Analogía Neurobiológica, el diseño de una ANN, se origina en la analogía del cerebro, el cual es una prueba viviente de un procesamiento paralelo tolerante a fallos.

La estructura general de una ANN se compone de neuronas artificiales, (unidades de procesamiento) ordenadas de tres capas, cada capa puede tener un número indistinto de neuronas, estas capas son:

- a) La capa de entrada. En esta capa, se recibe el grupo de datos provenientes del entorno (medio ambiente), el número de las neuronas será igual a la dimensión del vector de entrada.

- b) La capa oculta. Esta capa, se compone de neuronas no lineales y están conectadas directamente a todas las neuronas de la capa de entrada, en esta capa cada neurona tiene una función de activación en esta capa se procesa la información.

- c) La capa de salida. En esta capa, una señal directa es enviada hacia el exterior, donde la señal es el resultado de la interacción de las neuronas en las capas anteriores obteniendo una salida simulada.

A este tipo de red denomina “*feed forward network*” debido a que en operación normal, la señal fluye a través de la red en una dirección, de la capa de entrada avanzando hacia delante a la salida.

El origen de las Redes Neuronales Artificiales radica en los investigadores Warren McCulloch y Walter Pitts [6], en 1943 propusieron el primer modelo tomando ventaja del proceso biológico del cerebro para aplicarlo en inteligencia artificial. En la actualidad, un modelo de ANN básico se puede describir como lo muestra la **Figura 3**.

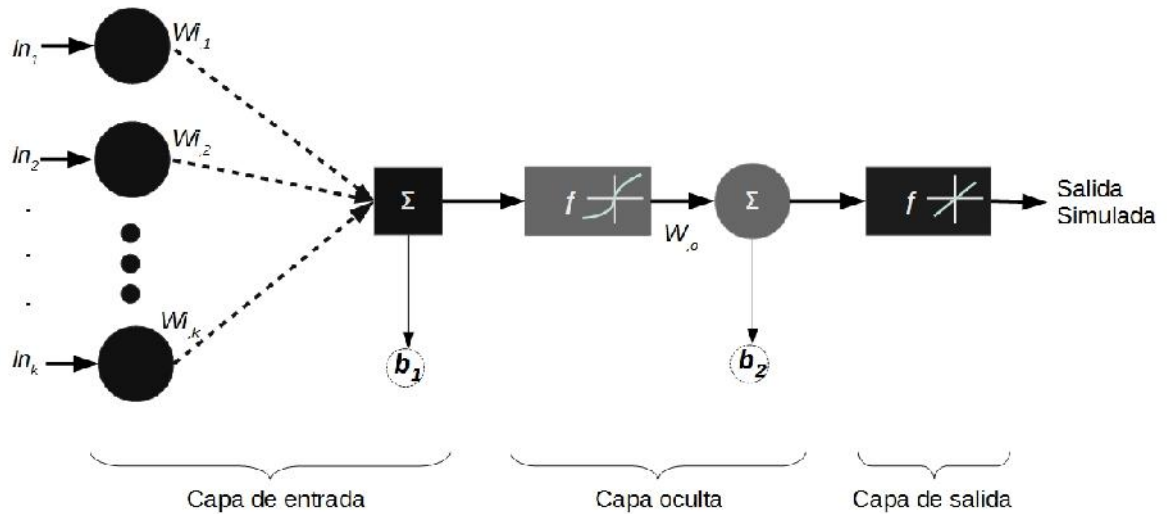


Figura 3 Modelo básico de una Red Neuronal Artificial.

En la capa de entrada del modelo ANN se introducen las variables de las cuales el modelo va aprender y simular una salida. A cada variable de entrada (In) para $(1,2...k)$, le corresponde un valor de pesos (W_i) y en adición un factor de bia ($b1$) es incluido. La suma de pesos y bia, produce una entrada (n_s) a la capa oculta, la cual es descrita como:

$$n_s = W_{i_1} \times In_1 + W_{i_2} \times In_2 + \dots + W_{i_k} \times In_k + b1 \quad (4)$$

Posteriormente, la entrada (n_s) pasa a la capa oculta, donde se utiliza una función de transferencia o activación para generar una salida. Los pesos de salida se suman provenientes de la función de activación utilizada y son agrupados en matrices para generar una salida (W_o y $b2$), la cual puede ser descrita como:

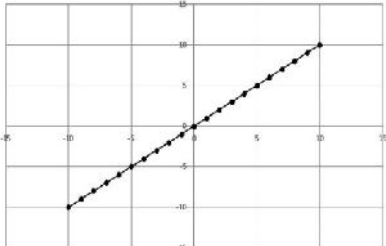
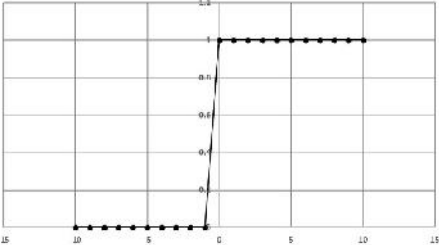
$$Out = W_o \times [f(W_{i_k} \times In_k + b1)] + b2 \quad (5)$$

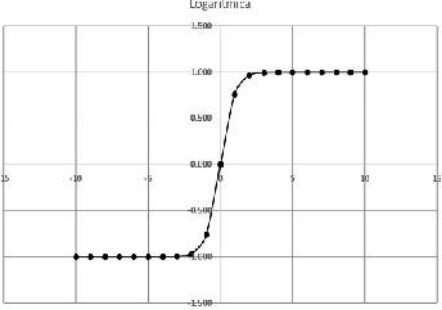
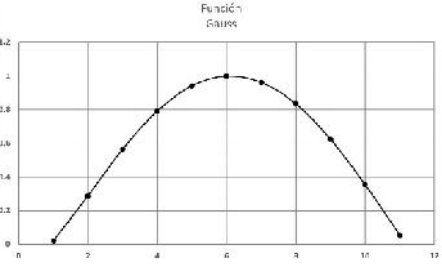
La función de transferencia f puede ser lineal o no lineal y se utiliza en la capa oculta y en la capa de salida. La **Tabla 1** muestra algunas de las funciones más usadas actualmente como:

Las funciones de activación pueden ser diferentes de una capa a otra, sin embargo deben ser iguales en la misma capa. A menudo los datos de entrada se mantienen dentro de límites, así que la función de activación de la capa oculta debe ser la apropiada.

También es posible tener más de una capa oculta, para este caso solo se agrega un grupo más de pesos.

Tabla 1 Funciones de transferencia

Nombre	Ecuación	Gráfica
Lineal	$f(x) = x \quad (6)$	 <p>Función Lineal</p>
Paso Binario	$f(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases} \quad (7)$	 <p>Paso Binario</p>

<p>Sigmoide Logarítmica</p>	$f(x) = \frac{1}{1 + e^{-x}} \quad (8)$	
<p>Tangente Sigmoideo</p>	$f(x) = t, \quad h(x) = \left(\frac{2}{1 + e^{-2x}} \right) - 1 \quad (9)$	
<p>Gauss</p>	$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (10)$	

2.2.1. BASES BIOLÓGICAS

En la naturaleza existen organismos que realizan funciones bien definidas, como es el caso de los insectos. Las hormigas y abejas son capaces de trabajar en equipo mediante una organización precisa para cuidar a la reina y continuar con la progenie. Pero no solo estos organismos cuentan con funciones definidas dignas de imitar, el mismo ser humano está compuesto de órganos que realizan funciones vitales para la supervivencia. Entre los órganos más destacados del ser humano se encuentra el cerebro, descrito desde sus inicios como el órgano más complejo. La función del cerebro consiste en recibir, integrar y procesar la información y envía diferentes señales a los órganos, con el fin de regular las múltiples funciones del organismo [7]. El cerebro está compuesto de células que interactúan entre sí mediante impulsos eléctricos, donde de acuerdo con las primeras investigaciones se calcula que existen alrededor de 100 billones de neuronas, sin embargo, en

estudios actuales señalan un promedio de 14 billones de neuronas [8]. Las neuronas son la unidad estructural y funcional del sistema nervioso que conforma el cerebro, con el fin de recibir, procesar y transmitir información a través de sus propiedades químicas y eléctricas. Como se muestra en la **Figura 4**, la estructura de una neurona está compuesta de un núcleo, dendritas, axón y terminales. El cuerpo de la neurona es la fuente de síntesis de moléculas orgánicas y son transportadas mediante impulsos eléctricos a través del axón hasta llegar a las terminales, donde forman sinapsis con otras neuronas [9].

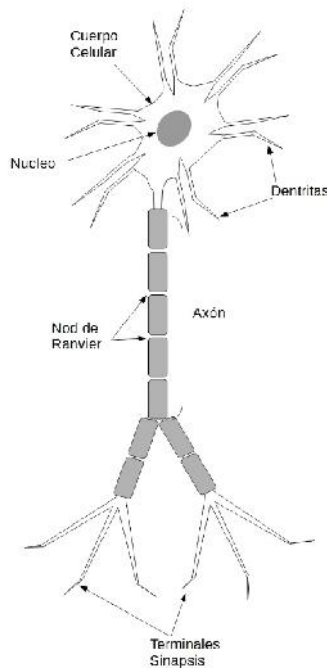


Figura 4 Esquema de la estructura básica de una neurona.

El núcleo de la neurona está encargado de sintetizar el ácido ribonucleico (ARN) y las dendritas son extensiones de las neuronas que tienen la apariencia de ramas o puntos que se extienden del cuerpo de la neurona con la función de recibir impulsos

de otras neuronas. Los nodos de Ranvier son interrupciones a lo largo del axón, con el objetivo de transmitir la información con mayor rapidez [10].




Figura 5 Organización jerárquica del sistema nervioso

Con la analogía neurobiológica, como inspiración y la gran cantidad de herramientas teóricas y computacionales que en la actualidad se han desarrollado, se puede asegurar que el entendimiento de las ANN y su aplicación a los diferentes ámbitos de la ciencia se incrementarán.

Los neurobiólogos ven a las ANN como una herramienta de investigación que ayuda a interpretar el fenómeno neurológico, por su parte los ingenieros ven a la neurobiología como una nueva forma de resolver problemas complejos. El potencial de una Red Neuronal Artificial deriva en su poder de cómputo, masivamente paralelo, de estructura distribuida, su habilidad de aprendizaje y más aún su capacidad de generalización. Generalización, la capacidad que tiene la Red Neuronal de producir salidas razonables a partir de entradas que no se presentaron

en la etapa de aprendizaje. Estas capacidades de las Redes Neuronales Artificiales, para procesar información, hacen que sean capaces de encontrar buenas soluciones aproximadas a problemas complejos, que son intratables.

2.2.2. TIPOS DE ESTRUCTURA DE UNA ANN

La forma en que las Redes Neuronales Artificiales (ANN), se estructuran se encuentra fuertemente relacionada con el algoritmo que es usado para el proceso de entrenamiento.

Las ANN se pueden clasificar de acuerdo con su estructura, dependiendo de las capas a utilizar y por la función que se desea realizar. Con base a esto, la ANN se clasifican en: simple capa, multicapa y redes recurrentes [11].

Simple capa, tiene una capa de entrada que forman los nodos origen y que proyectan directamente a la capa de salida sin embargo no puede realizar la misma función de manera inversa, por lo que este tipo de ANN es una *feed forward* en estricto sentido; a este tipo de ANN se les denomina “*single-layer network*” ya que solo en la capa oculta es en donde se encuentran las funciones de activación y es ahí en donde se lleva a cabo el cálculo de la red. Este tipo de red generalmente es usada para clasificar y filtrar patrones lineales **Figura 6**.

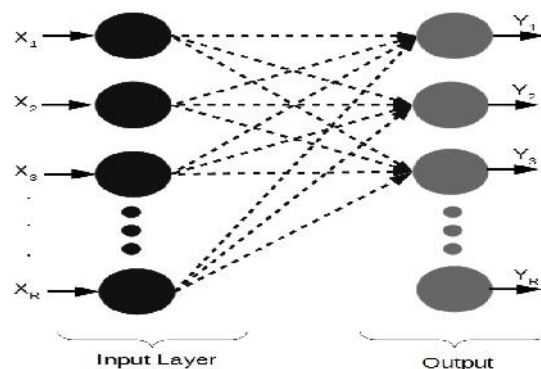


Figura 6 Red Neuronal Artificial simple.

Multicapa: la segunda clase de ANN consiste en una o más capas ocultas, donde cada capa lleva una o más neuronas. Se denomina como capa oculta debido a que esta capa solo tiene contacto directo con la capa de entrada o la de salida. Al agregar una o más capas ocultas la red es capaz de crear estadísticas de alto nivel a partir de las entradas. Esta arquitectura es más usada para clasificación de comportamientos no lineales **Figura 7**.




Figura 7 Red Neuronal Artificial multicapa.

Recurrente: este tipo de red se caracteriza por tener conexiones recurrentes donde la información fluye hacia adelante y hacia atrás a través de conexiones que comunican las neuronas con capas previas; esta característica tiene un gran impacto en las capacidad de aprendizaje y en el desempeño de la red. Por su característica de retroalimentación se utiliza esta red para identificar, optimizar sistemas, control entre otros **Figura 8**.

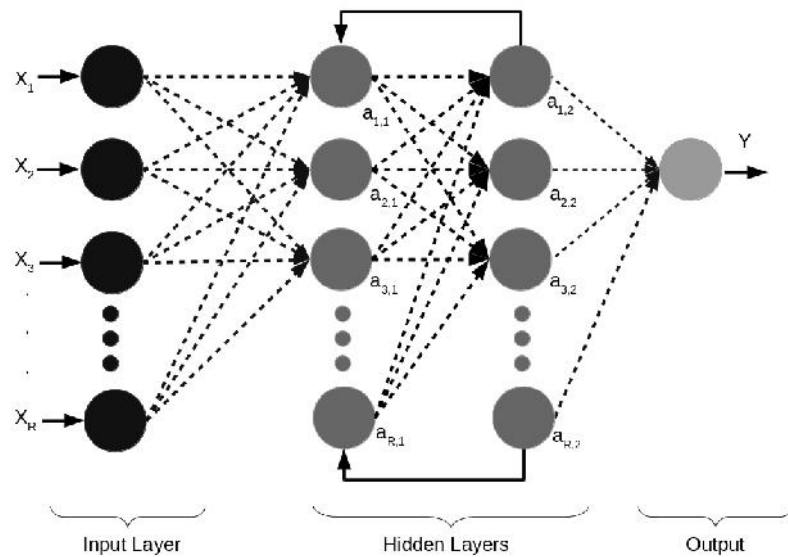


Figura 8 Red Neuronal Artificial recurrente

El conocimiento se describe como la información almacenada o los modelos usados por una persona o máquina para interpretar o predecir y generar una respuesta apropiada como salida.

El proceso más importante para una ANN es el de aprender como es el mundo real a partir de un modelo establecido, de tal forma que mientras más consistente sea el modelo mejor será la capacidad de la ANN para predecir o simular los datos de salida (respuestas). El proceso de entrenamiento de una ANN se puede dar de dos maneras, a) entrenamiento supervisado, b) entrenamiento no supervisado, estas formas de aprendizaje se ajustan a las formas en las que el ser humano aprende.

2.2.3. ENTRENAMIENTO SUPERVISADO DE LA RNA.

La principal característica del modelo RNA es que debe tener un proceso de aprendizaje. El aprendizaje puede ser supervisado o no supervisado. La diferencia entre ambos radica en que el aprendizaje supervisado se proporciona un patrón

para obtener una respuesta correcta durante el entrenamiento, mientras que en el aprendizaje no supervisado el objetivo aprender no está presente y se ajusta por observaciones. La fortaleza de las conexiones entre las neuronas, conocida como peso de la sinapsis, es usada para almacenar el conocimiento adquirido. Para realizar el proceso de aprendizaje, se realiza mediante el procedimiento conocido como algoritmo de aprendizaje (learning algorithm), como se muestra en la **Figura 9**, cuya función es modificar los pesos de las conexiones sinápticas, de manera ordenada, con la finalidad de alcanzar el objetivo deseado; este es el método tradicional para diseñar una red neuronal, esto es una aproximación a la teoría de filtro adaptativo lineal, que se ha aplicado en diversos campos (Widrow and Stearns 1985).

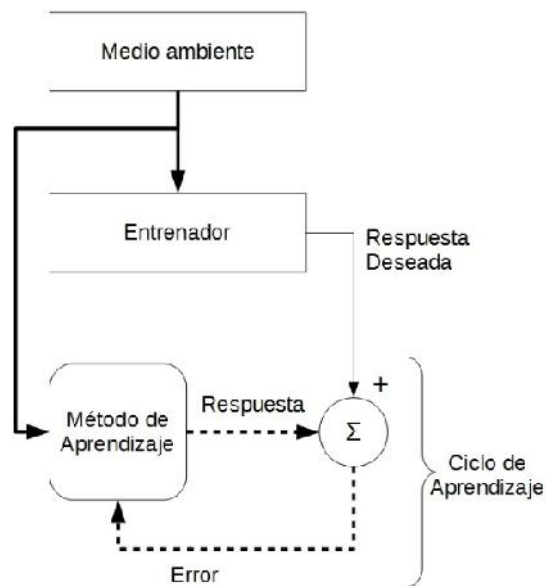


Figura 9 Diagrama de bloques del proceso de aprendizaje supervisado

Dicho algoritmo permite ajustar los coeficientes de pesos y bias de acuerdo con la salida a simular. El ajuste se realiza disminuyendo el error que hay entre el valor a simular y el predicho. Para llevar a cabo esto, se hace de manera iterativa donde el objetivo es disminuir el error y obtener una salida simulada muy cercana a la deseada. La eficiencia de este algoritmo consiste en encontrar de manera efectiva

los patrones que representen mejor la salida a simular y evitar el sobre aprendizaje [12] (el cual, esta descrito como el error creciente después de encontrar el número de neuronas óptimas, como se muestra en la **Figura 10**.

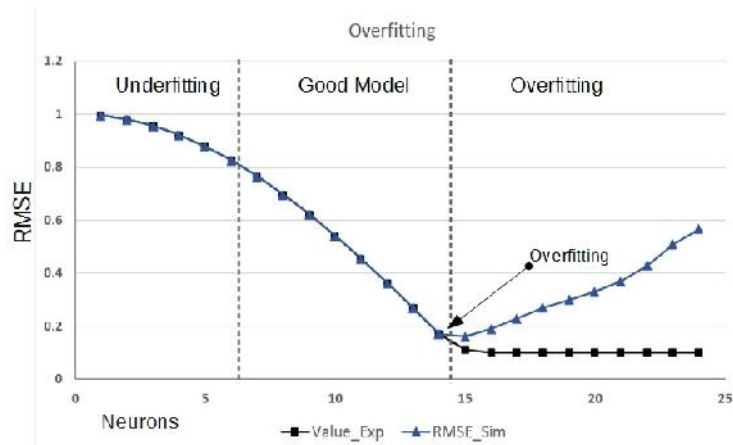


Figura 10. Efecto del sobre aprendizaje en el entrenamiento de una RNA.

Para el caso que nos ocupa de entrenamiento supervisado a partir de ejemplos, el sistema puede usar un estimado instantáneo del vector de gradiente, el uso este valor estimado, da como resultado un movimiento del punto de operación sobre el error que normalmente sigue un camino aleatorio.

Sin embargo dado el algoritmo diseñado para minimizar el costo de la función, un conjunto adecuado de ejemplos de entrada – salida y con el tiempo suficiente para realizar el entrenamiento un sistema bajo el entrenamiento supervisado puede tener una aproximación con un error mínimo.

2.2.4. DESARROLLO DEL MODELO DE LA ANN

Para llevar a cabo el desarrollo de una ANN es necesario realizar una serie de pasos fundamentales para obtener una salida simulada satisfactoria. Estos pasos se resumen en las siguientes tres tareas: generación de datos, entrenamiento de la red y selección de la red óptima. Cada una de estas tareas está relacionada, si en una de ellas ocurre una falla afecta directamente la salida a simular.

a) **Generación de datos:** Para iniciar el desarrollo de la RNA es necesario proporcionar una serie de datos, con el objetivo de adquirir información para realizar el aprendizaje. Los datos para entrenar la red pueden provenir directamente de equipos experimentales, simulaciones de métodos matemáticos o compilados de la literatura que se desea simular. Los datos antes de pasar por el proceso de entrenamiento deben ser normalizados, con el fin que los datos entren en un intervalo numérico de [0, 1], ya que durante el entrenamiento para la RNA es más fácil manejar la información de esta manera [13]. Una de las ecuaciones más utilizadas es la siguiente (11):

$$x_{i, Norm} = 0.8 \times \left(\frac{X_{i, Real} - X_{min}}{X_{max} - X_{min}} \right) + 0.1 \quad (4)$$

b) **Entrenamiento de la red:** Consiste en dividir aleatoriamente los datos normalizados en tres grupos: Entrenamiento, prueba y validación. Los datos de entrenamiento y prueba son aplicados con el fin de que el modelo RNA realice el aprendizaje y finalmente se compara con los datos de validación. El aprendizaje es realizado de manera iterativa para reducir el error entre el valor deseado y el simulado lo menor posible. El algoritmo de propagación hacia atrás se aplica con el fin de encontrar los pesos y bias ajustados que mejor representen la salida a simular. Si no se logra encontrar un valor satisfactorio es necesario aumentar el número de neuronas en la capa oculta.

c) **Selección de la óptima red:** Durante el entrenamiento del modelo RNA, se realiza una comparación entre los datos simulados y los datos de validación para detectar si es necesario modificar el algoritmo de entrenamiento o aumentar el número de neuronas en la capa oculta para mejorar la precisión de los datos simulados con respecto a los deseados. Para determinar una óptima arquitectura el modelo RNA utiliza criterios estadísticos como: Raíz

cuadrada del error medio (RMSE, por sus siglas en inglés), Porcentaje del error medio (MPE, por sus siglas en inglés) y el coeficiente de determinación (R^2) [14]. Las cuales pueden ser descritas como (12-

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_{Sim(i)} - P_{Exp(i)})^2}{n}} \quad (5)$$

$$MPE = \frac{\sum_{i=1}^n \left(\frac{P_{Exp(i)} - P_{Sim(i)}}{P_{Exp(i)}} \right)}{n} \times 100(\%) \quad (6)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (P_{Exp(i)} - P_{Sim(i)})^2}{\sum_{i=1}^n (P_{Exp(i)} - \bar{P}_{Exp})^2} \quad (7)$$

Dónde: $\bar{P} = \frac{1}{n} \sum_{i=1}^n P_i$, $P_{Si(i)}$ son los datos simulados por el modelo RNA; $P_{E(i)}$ son los datos experimentales con los cuales se desea validar el modelo RNA.

Estos criterios estadísticos son utilizados para determinar el error en la predicción del modelo RNA e identificar la correlación lineal entre los datos simulados y los datos que se desea validar. Finalmente, después de realizar estos pasos, se concluye que el modelo RNA es capaz de modelar comportamientos lineales y no lineales con una aceptable precisión.

En los procesos, existen comportamientos complejos donde es necesario simular una salida con el fin de analizar y controlar las variables de entrada, pero en la mayoría de los casos la salida a simular es difícil de modelar. La complejidad de modelar algunos procesos radica en que se llevan a cabo reacciones químicas o dependen de múltiples variables que al interactuar entre si hacen difícil el modelado, ya que no tienen un comportamiento físico. Por lo tanto, una correlación lineal simple no puede satisfacer una correcta simulación del proceso. Las Redes

Neuronales Artificiales se han aplicado como una herramienta computacional para modelar procesos y esto se debe a que son capaces de modelar comportamientos tanto lineales como no lineales.

Los investigadores Mohanraj, Jayaraj y Muraleedharan en el año 2012 [15], hacen una revisión bibliográfica científica acerca de cómo las redes neuronales artificiales han sido utilizadas para modelar diversos intercambiadores de calor, donde se encuentran involucrados sistemas de refrigeración, aire acondicionado y bombas de calor. Los investigadores concluyen con más de 90 artículos revisados, que las redes neuronales artificiales se pueden aplicar con éxito en la obtención de una simulación con una precisión aceptable.

2.3. INVERSA DE LA RED NEURONAL ARTIFICIAL (ANNi)

La Red Neuronal Artificial inversa (ANNi), es un modelo matemático empleado para optimizar variables de entrada de un proceso, el cual fue modelado previamente. El objetivo primordial es mejorar la salida del proceso a través de la búsqueda de valores óptimos que permitan operar eficientemente al proceso. El modelo ANNi utiliza como base un modelo RNA entrenado, donde los coeficientes de pesos y bias son necesarios para plantear el modelo ANNi, en este caso queda como una función objetivo ya que cuenta con valores de entrada desconocidos. La optimización de las variables de entrada se lleva a cabo por el hecho que la salida a simular es ya conocida. Cabe mencionar que, cuando solo una neurona existe en la capa oculta se puede despejar y a la vez obtener una variable de entrada, lo que permite encontrar valores óptimos que mejoran la salida de un proceso. Sin embargo, cuando existen más de una neuronal en la capa oculta está no tiene despeje y por lo tanto es necesario acoplar un algoritmo de numérico que permita encontrar una o más valores de entrada.

2.3.1.ANTECEDENTES

En el año 2009, el investigador José Alfredo Hernández Pérez [16] publicó un artículo donde se plantea por primera vez la metodología de la Red Neuronal Artificial inversa para optimizar el tiempo de secado en mango y yuca. En este trabajo de investigación partió de un modelo ANN entrenado para predecir la temperatura y la humedad cinética durante el proceso de secado para mango y yuca. Dentro de las variables de entrada se encuentran: la temperatura del aire, velocidad del aire, contracción en función del contenido de humedad, el tiempo de secado y la humedad del aire. Los resultados mostraron que, al elegir el tiempo de secado como variable a optimizar, el modelo ANNi fue capaz de obtener valores aproximadamente iguales a los experimentales. Finalmente, el modelo quedó abierto para aplicarlo en otras áreas por su capacidad de modelar procesos y optimizarlos en línea.

2.3.2.PLANTEAMIENTO DE LA ANNi PARA OPTIMIZAR UNA VARIABLE.

Como se muestra en la **Figura 11**, el modelo ANN utiliza las variables de entrada para obtener una salida simulada a través del proceso de aprendizaje de la red. Sin embargo, el modelo ANNi parte de una salida requerida por el operador de un proceso, utilizando los coeficientes de pesos y bias del modelo ANN entrenado. El modelo ANNi plantea despejar la salida simulada (sustituyéndolo por una salida requerida) de la ecuación generalizada de RNA, con el fin de obtener una variable de entrada como incógnita. El objetivo es encontrar valores óptimos que permitan alcanzar una mejor salida.

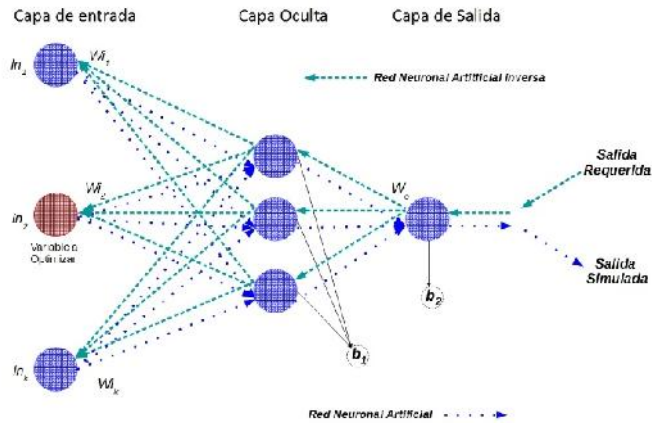


Figura 11 Esquema de una Red Neuronal Artificial inversa

A continuación, se describe a detalle cómo se lleva a cabo el planteamiento del modelo ANNi, pero como se mencionó anteriormente, para plantear el modelo es necesario empezar por establecer una ecuación general del modelo RNA. La ecuación (8) integra una función de transferencia tipo sigmoide tangencial en la capa oculta y una tipo lineal de salida con el objetivo de simular una salida deseada (y):

$$y = \sum_{j=1}^s W_{o(j)} \cdot \left[\frac{2}{1 + \exp\left(-2 \cdot \left(\sum_{k=1}^K (W_{i(j,k)} \cdot In_{(k)}) + b1_{(j)}\right)\right)} - 1 \right] + b2 \quad (8)$$

Dónde: s es el número de neuronas en la capa oculta, k es el número de variables de entrada, In son las variables de entrada a utilizar y j son los correspondientes coeficientes de pesos y bias (W_i , W_o , $b1$ y $b2$) obtenidos durante el enteramiento de la ANN.

Una vez establecido un modelo ANN consolidado con la capacidad de simular una salida con una precisión aceptable, se procede a plantear el modelo ANNi. La Ecuación (9) muestra cómo se despeja la salida simulada, al pasarla del lado

derecho de la ecuación generalizada y a su vez establecer una variable de entrada como incógnita (x)

$$f(x) = b2 - \sum_{j=1}^S W_{o(j)} - y + \sum_{j=1}^S \left[\frac{2W_{o(j)}}{1 + \exp\left(-2\left(W_{i(k,j)} \cdot x\right) + \sum_{k=1}^K \left(W_{i(k,j)} \cdot In_{(k)} + b1_{(j)}\right)\right)} \right] \quad (9)$$

Como se puede observar en la Ecuación (9) el modelo ANNi se resume en plantear una ecuación que está en función del valor de entrada que se desea optimizar (x) y el valor de salida que se desea alcanzar (y). Posteriormente, se procede a resolver la función planteada, donde se busca minimizar la función lo más cercano a cero, al momento de comparar la salida requerida con la salida obtenida al optimizar la variable de entrada.

El modelo ANNi está diseñado para ser aplicado en línea de modo que el operador identifique en tiempo real que variaciones debe realizar sobre una variable de entrada para obtener un mejor resultado. Para satisfacer este fin, es necesario utilizar un algoritmo de optimización que resuelva el modelo ANNi en el menor tiempo posible. En los primeros trabajos publicados al aplicar el modelo ANNi reportan utilizar el método Simplex (Nelder-Mead), ya que logra resolver la función en corto tiempo [17-20].

2.3.3. PLANTEAMIENTO DE LA ANNi PARA OPTIMIZAR MULTI VARIABLES.

En trabajos previos se ha demostrado que el modelo ANNi es capaz de optimizar variables de entrada. A través del tiempo el modelo ANNi se ha venido mejorando con el fin de hacerlo cada vez más versátil al aplicarlo en procesos. Entre las mejoras más destacables se encuentran utilizar distintos algoritmos de optimización

que resuelven con mayor precisión y rapidez el modelo ANNi. Este libro propone aplicar el modelo ANNi para optimizar múltiples variables a la vez, con la premisa de que, al optimizar más de una variable a la vez, el resultado requerido se obtiene de una mejor manera, ya que ahora se busca un mejor resultado a partir de diversas variables de entradas óptimas, en vez de solo forzar a una. La Ecuación (10) generaliza el planteamiento de un modelo ANNi para optimizar múltiples variables a la vez.

$$Fun(x_1, x_2, \dots, x_n) = b2_{(j)} - \sum_{j=1}^S Wo_{(j)} - y + \dots \quad (10)$$

$$\sum_{j=1}^S \left[\frac{2Wo_{(j)}}{1 + \exp\left(-2(Wi_{(j,1)} \cdot x_1 + Wi_{(j,2)} \cdot x_2 + \dots + Wi_{(j,n)} \cdot x_n + \sum_{k \neq 1, 2, \dots, n}^k Wi_{(j,k)} \cdot \ln_{(k)} + b1_{(j)})\right)} \right]$$

Con este planteamiento el modelo ANNi se mejora notablemente, ya que ahora se brinda la posibilidad de controlar un proceso de manera completa, al monitorear el comportamiento múltiple variables con respecto a un resultado deseado. Al optimizar más de una variable a la vez, el modelo ANNi se vuelve más atractivo para la industria privada, ya que, es posible reducir costos de producción, por el hecho de conocer la manera óptima de suministrar fuentes de energía o aplicar las cantidades necesarias de materia prima para obtener el resultado deseado, consiguiendo así un ahorro de insumos.

Al plantear el método ANNi para optimizar múltiples variables, la función se vuelve más compleja, por lo tanto, es necesario aplicar un método de optimización que pueda realizar la búsqueda de múltiples variables a partir de un objetivo, sin tener restricciones de partir de un punto de referencia en la búsqueda de posibles soluciones como lo es el algoritmo genético.

2.4. ALGORITMO GENÉTICO GA

Así como las Redes Neuronales Artificiales se basan en emular el comportamiento del cerebro humano, el algoritmo genético (GA) pretende emular los mecanismos de reproducción de los seres vivos. A través de muchas generaciones, las poblaciones naturales han evolucionado en función a los principios de selección natural y de la supervivencia del mejor adaptado. Los GA son métodos adaptativos que pueden ser usados para resolver búsquedas y problemas de optimización; son utilizados ampliamente en informática, ingeniería, seguridad, entre otros. La aplicación del GA en diversos campos radica en que es una herramienta computacional para localizar un objetivo a partir de una población. Difieren de otros métodos de búsqueda y optimización de varias maneras, como se muestran a continuación [21]:

- a) Los AG realizan la búsqueda en una población de posibles soluciones en lugar de uno solo.
- b) La función de fitness o aptitud es utilizada para resolver la redundancia y no tiene la necesidad de continuidad en los derivados, por lo que prácticamente cualquier función fitness puede ser seleccionada para optimizar.
- c) Los AG usan operadores aleatorios durante todo el proceso incluyendo reproducción, cruce y mutación.
- d) Los AG son ciegos, ya que no se necesita información específica sobre el problema deseado para obtener la solución final.

2.4.1. BASES BIOLÓGICAS

En 1859, Charles Darwin publicó su libro “el origen de las especies”, donde justifica el hecho de que los organismos han evolucionado para adaptarse a su entorno y lograr sobrevivir a los cambios que se presentan, como: la falta de alimento, defenderse de depredadores y mejorar sus habilidades de caza [22]. Al momento de que Charles Darwin publicó su libro se le presentó un gran reto, ya que las ideologías en ese tiempo eran muy arraigadas a la religión. Su mayor reto, fue demostrar cómo se lleva a cabo la evolución de las especies, para lo cual, reporto una serie de aves que fueron modificando el tamaño de sus picos para obtener su alimento. Darwin menciona que solo las especies más fuertes podrían lograr la supervivencia a través de la reproducción, planteando las bases de la genética humana. A partir de estudios realizados por Gregor Mendel en 1865, se recalco los términos de la genética, el cual, nos muestra que al combinarse dos cromosomas se genera un individuo con genes que proporcionan características bien definidas heredadas de los padres hacia los hijos.

En 1975, el investigador Holland publicó su libro “Adaptation in Natural and Artificial Systems”, donde se imitaba el funcionamiento de la selección natural [23]. El objetivo es codificar una población de soluciones de forma similar a cromosomas. Posteriormente, en 1989 el investigador Goldberg se basa en la genética humana y la selección de especies para desarrollar los algoritmos genéticos. Goldberg define el GA como un algoritmo de búsqueda basados en la mecánica de la selección natural y la genética humana para combinar la supervivencia del más apto y resolver un problema [24].

2.4.2. FUNCIONAMIENTO DEL GA

Para llevar a cabo el funcionamiento de un algoritmo genético es necesario realizar la codificación de cualquier solución potencial al problema a resolver. Como se muestra en la **Figura 12**, los parámetros se codifican en una cadena de valores denominada cromosomas. A partir de Holland, la codificación suele hacerse en código binario [0 y 1] y se asigna un número determinado de bits a cada parámetro. El número de bits asignado estará en base al grado de ajuste que se desea alcanzar. No es necesario que cada individuo tenga el mismo número de bits y cada uno de estos pertenecientes a un gen recibe el nombre de alelo.

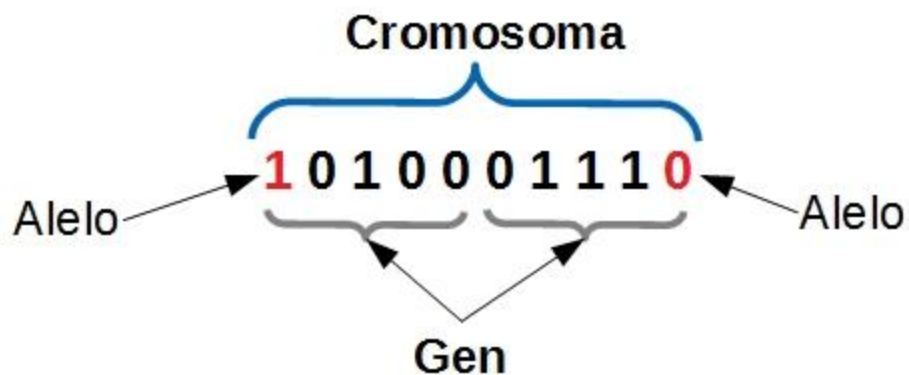


Figura 12 Codificación de un individuo genético

Una vez que se ha codificado los individuos es necesario plantear un algoritmo que permita seleccionar y evaluar los individuos para encontrar el que mejor logre satisfacer la búsqueda deseada. El algoritmo bajo el cual se rige la búsqueda de parámetros aptos para resolver un problema se resume en los siguientes pasos:

1. Generar al azar una población inicial de cromosomas
2. Evaluar con la función fitness o aptitud de cada cromosoma en la población.
3. Seleccionar los mejores cromosomas, basados en la función fitness, para la reproducción.
4. Elija al azar pares de cromosomas para apareamiento, conocido como cruce, donde existe un intercambio de genes de bits para crear nuevos pares de cromosomas.
5. Procesar los nuevos cromosomas por la mutación.
6. Repita el paso 2 al paso 5, hasta que la función fitness converja o sea menor que un valor predefinido de generaciones.

2.4.3. OPERADORES GENÉTICOS

Una vez que la población es evaluada por el ajuste o fitness se procede a generar un nuevo individuo mediante una serie de operadores genéticos. Los más usuales son: a) selección, b) cruce y c) mutación, con el fin que la nueva progenie de cromosomas logre resolver la búsqueda deseada. Cada uno de estos operadores genéticos es descrito a continuación [25,26]:

a) Selección: Al igual que en la naturaleza, para elegir la pareja de individuos más aptos para generar una solución adecuada, en AG se determina por criterios probabilísticos, donde aquellos individuos que sean más aptos se les brinda un mayor porcentaje de probabilidad de ser elegidos. Finalmente, se plantea una serie de métodos para la elección adecuada de individuos, como ruleta o torneo, donde se eligen al azar los individuos, pero con prioridad a aquellos con mayor

probabilidad de encontrar la solución adecuada (ruleta) o haciendo comparaciones directas entre los individuos con el fin de que se reproduzcan los dos mejores (torneo).

b) Cruce: consiste en que una vez que se han elegido dos individuos se lleva a cabo la reproducción o cruce de los individuos, básicamente es realizar la combinación de cromosomas de los dos individuos elegidos. En el cruce puede ser por un punto, dos puntos o uniforme. El cruce por un punto se realiza

por la combinación de dos individuos en un punto en particular. El cruce de dos puntos se elige dos puntos para llevar a cabo la combinación entre los padres. El cruce uniforme cuenta con más de dos combinaciones entre los padres, para evitar tener un cromosoma igualado a un padre en específico.

c) Mutación: Al igual que en la naturaleza, las nuevas especies han mejorado por mutaciones que modifican la estructura de los organismos, favoreciendo sus funciones. En AG, las mutaciones consisten en cambiar un gen para obtener una mejor búsqueda. La probabilidad de cambio debe ser baja, ya que si se alteran varios genes se corre el riesgo de no encontrar el resultado deseado.

CAPITULO 3

1. DESARROLLO DE LOS MODELOS DE ANN, ANNi Y GA

1.1. MODELO DE ANN.

Siguiendo el procedimiento propuesto por Hernández y otros [27] Los mejores resultados para predecir el valor del COP experimental los mostro la red que tiene tres neuronas en la capa oculta por lo que la configuración general se muestra como: **16 – 3 – 1**, 16 neuronas en la capa de entrada, 3 neuronas en la capa oculta y 1 en la capa de salida. Al realizar la comparación de las funciones de activación TANSIG y LOGSIG, la función TANSIG muestra que es capaz de predecir de mejor manera la salida deseada, la comparativa de los resultados se muestran en la

Tabla 3

Arquitectura ANN	Número de neuronas	Épocas	Raíz Cuadrada del error medio (RMSE)	Coficiente de Determinación R2	Raíz Cuadrada del error medio (RMSE)	Coficiente de Determinación R2
			TANSIG		LOGSIG	
16 - 01 - 1	1	1000	0.031	0.7748	0.0309	0.817
16 – 02 - 1	2	1000	0.0288	0.7315	0.0237	0.8186
16 – 03 – 1	3	1000	0.0045	0.9935	0.0296	0.731
16 – 04 - 1	4	1000	0.0259	0.8373	0.0227	0.8496

Tabla 3. Búsqueda de la mejor arquitectura y de la función de activación, para obtener la mejor predicción del valor del COP.

Una vez que ya se tiene la combinación de la arquitectura y la función de activación que mejor predice el valor del COP, esta es representada por la siguiente ecuación (11)

$$COP = b2_{(j)} - \sum_{j=1}^S W_{o(j)} + \sum_{j=1}^S \left(\frac{2W_{o(j)}}{1 + \exp\left(-2 \cdot \left(\sum_{k=1}^K (W_{i(j,k)} \cdot In_{(k)}) + b1_{(j)}\right)\right)} \right) \quad (11)$$

En la ecuación (11), los pesos y las bias obtenidas de las entradas y la salida se muestran en la ecuación (12). Este modelo puede ser aplicado con seguridad al modelo del HTA con reciclado de energía.

$$COP = (-0.3421) - [(0.6888) + (-0.2127) + (0.0603)] \dots + \left[\frac{2 \cdot 0.6888}{1 + \exp(x_1)} + \frac{2 \cdot (-0.2127)}{1 + \exp(x_2)} + \frac{2 \cdot 0.0603}{1 + \exp(x_3)} \right] \quad (12)$$

En donde x, es el vector de las 16 variables que serán integradas en las 3 neuronas de la capa oculta.

$$x_1 = -2 \cdot \left(\begin{array}{l} 0.0021T_{inGE-AB} + (-0.7622T_{inEV-AB}) + (-2.3217T_{outABGE}) + 0.2878T_{inABGE} \\ + 1.6444T_{outGE-AB} + (-0.5879T_{outGE-AB}) + 1.0755T_{inCO} + (-0.1564T_{outCO}) \\ + 0.0318T_{inEV} + 0.9985T_{outEV-AB} + (-0.8706X_{inAB}) + 0.4382X_{outAB} \\ + (-0.5286X_{inGE}) + 0.9315X_{outGE} + 0.7588P_{AB} + 0.5491P_{GE} + 1.1504 \end{array} \right) \quad (13)$$

$$x_2 = -2 \cdot \left(\begin{array}{l} -0.4986 \cdot T_{inGE-AB} + 0.8307 \cdot T_{inEV-AB} + 2.4742 \cdot T_{outAB-GE} \\ + (-0.3054 \cdot T_{inAB-GE}) + (-1.3404 \cdot T_{outGE-CO}) + (-0.4565 \cdot T_{outGE-AB}) \\ + 1.0482 \cdot T_{inCO} + 0.1166 \cdot T_{outCO} + 0.363 \cdot T_{inEV} + (-0.5139 \cdot T_{outEV-AB}) \\ + (-0.6915 \cdot X_{inAB}) + (-0.3243 \cdot X_{outAB}) + (-1.891 \cdot X_{inGE}) + 1.6529 \cdot X_{outGE} \\ + 0.4929 \cdot P_{AB} + 1.9905 \cdot P_{GE} + (-1.9307) \end{array} \right) \quad (14)$$

$$x_3 = -2 \cdot \left(\begin{aligned} &0.059 \cdot T_{inGE-AB} + 1.1192 \cdot T_{inEV-AB} + (-0.0079 \cdot T_{outAB-GE}) + (-0.5062 \cdot T_{inAB-GE}) \\ &+ 1.1292 \cdot T_{outGE-CO} + (-0.2404 \cdot T_{outGE-AB}) + 1.2242 \cdot T_{inCO} + 1.0001 \cdot T_{outCO} \\ &+ 1.3662 \cdot T_{inEV} + (-0.3073 \cdot T_{outEV-AB}) + 0.0163 \cdot X_{inAB} + (-0.5362 \cdot X_{outAB}) \\ &+ (-1.6384 \cdot X_{inGE}) + 0.7368 \cdot X_{outGE} + 0.6779 \cdot P_{AB} + 1.8523 \cdot P_{GE} + (-5.9985) \end{aligned} \right) \quad (15)$$

3.2. MODELO DE ANNi.

Con base a las ecuaciones 11 a 15, propuestas para predecir el COP, de un HTA con reciclado de calor; se llevó a cabo el procedimiento para revertir el modelo de ANN, esto se muestra en la **Figura 13**, se muestra que una vez que el valor del COP ha sido simulado por el modelo ANN, los coeficientes de pesos y bias del COP simulado, pueden pasar del lado derecho de la ecuación (12).

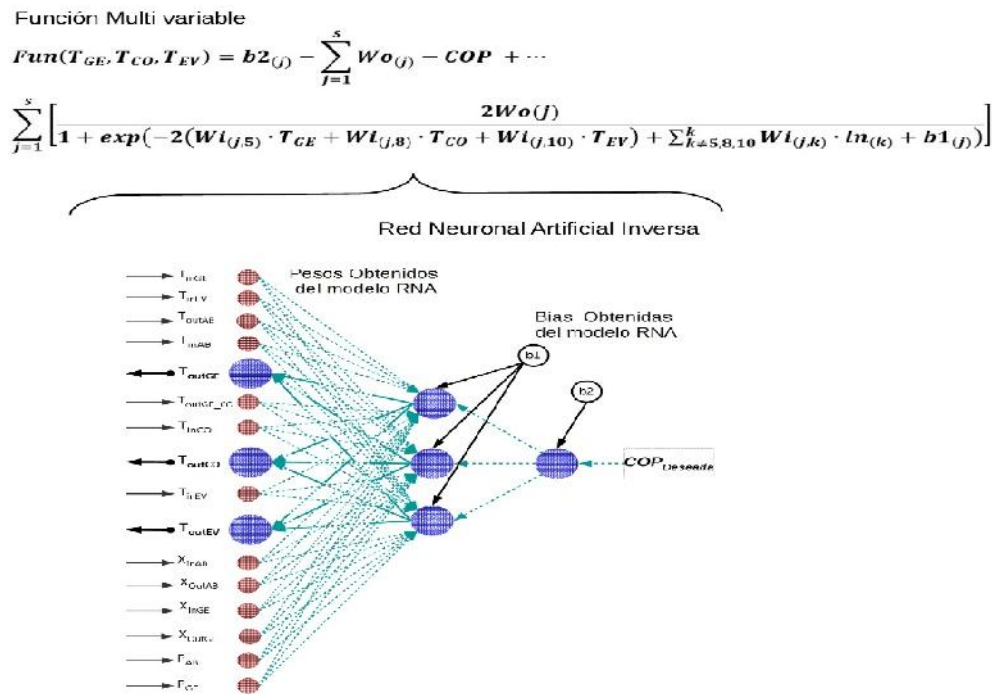


Figura 13. Esquema de la función inversa de la ANN en función de los pesos y bias generados previamente

En lugar de insertar el mismo valor simulado se inserta un valor más alto, con la diferencia de que los valores de las variables de entrada son desconocidos.

Para estar en condiciones de hacer comparaciones entre una la optimización de una variable, dos y tres al mismo tiempo, las funciones objetivo se formularon con base a las ecuaciones (16-18)

Para una variable.

$$Fun(T_{GE}) = b2_{(j)} - \dots$$

$$\sum_{j=1}^S Wo_{(j)} - COP + \sum_{j=1}^S \left[\frac{2Wo_{(j)}}{1 + \exp\left(-2(Wi_{(j,5)} \cdot T_{GE} + \sum_{k \neq 5}^k Wi_{(j,k)} \cdot \ln_{(k)} + b1_{(j)})\right)} \right] \quad (16)$$

Donde S representa el número de neuronas en la capa oculta, k indica el número de variables de entrada y j el coeficiente de pesos y bias obtenidos por el modelo ANN.

Esta ecuación se formula para encontrar una variable a un tiempo, buscando el valor óptimo primero para el TGE, después la temperatura para el TEV y por último la temperatura del TCO, la ecuación (16) ejemplifica como se encuentra la temperatura óptima para la variable del TGE, una vez que se fija un valor alto del COP. La **Figura 14**

Para dos variables

$$Fun(T_{GE}, T_{EV}) = b2_{(j)} - \dots$$

$$\sum_{j=1}^S Wo_{(j)} - COP + \sum_{j=1}^S \left[\frac{2Wo_{(j)}}{1 + \exp\left(-2(Wi_{(j,5)} \cdot T_{GE} + Wi_{(j,8)} \cdot T_{EV} + \sum_{k \neq 5,8}^k Wi_{(j,k)} \cdot \ln_{(k)} + b1_{(j)})\right)} \right] \quad (17)$$

Donde S representa el número de neuronas en la capa oculta, k indica el número de variables de entrada y j el coeficiente de pesos y bias obtenidos por el modelo ANN.

Esta ecuación se formula para encontrar dos variables a un mismo tiempo, buscando el valor óptimo primero para el TGE - TEV, después la temperatura para el TGE - TCO. El objetivo de este análisis es observar la interacción de estas dos

variables para incrementar el valor del COP y lograr un ahorro de energía, la ecuación (17) ejemplifica como se encuentra la temperatura óptima para la variable del TGE- TEV, en función del COP deseado, en la **Figura 15** muestra de manera esquemática del modelo propuesto de la inversa, con la que es posible encontrar el valor óptimo para dos variables en función del valor del COP.

Para tres variables

$$Fun(T_{GE}, T_{CO}, T_{EV}) = b2_{(j)} - \sum_{j=1}^S Wo_{(j)} - COP + ...$$

$$\sum_{j=1}^S \left[\frac{2Wo_{(j)}}{1 + \exp\left(-2(Wi_{(j,5)} \cdot T_{GE} + Wi_{(j,8)} \cdot T_{CO} + Wi_{(j,10)} \cdot T_{EV} + \sum_{k \neq 5,8,10}^k Wi_{(j,k)} \cdot \ln_{(k)} + b1_{(j)})\right)} \right] \quad (18)$$

Donde S representa el número de neuronas en la capa oculta, k indica el número de variables de entrada y j el coeficiente de pesos y bias obtenidos por el modelo ANN.

Esta ecuación se formula para encontrar tres variables a un mismo tiempo, buscando el valor óptimo primero para el TGE – TEV – TCO. El objetivo de este análisis es observar la interacción de estas tres variables para incrementar el valor del COP y lograr un ahorro de energía. la ecuación (18) se propone para encontrar los valores óptimos de TGE - TEV TCO en función del valor deseado del COP. La **Figura 16** muestra de manera esquemática del modelo propuesto de la inversa, con la que es posible encontrar el valor óptimo para dos variables en función del valor del COP.

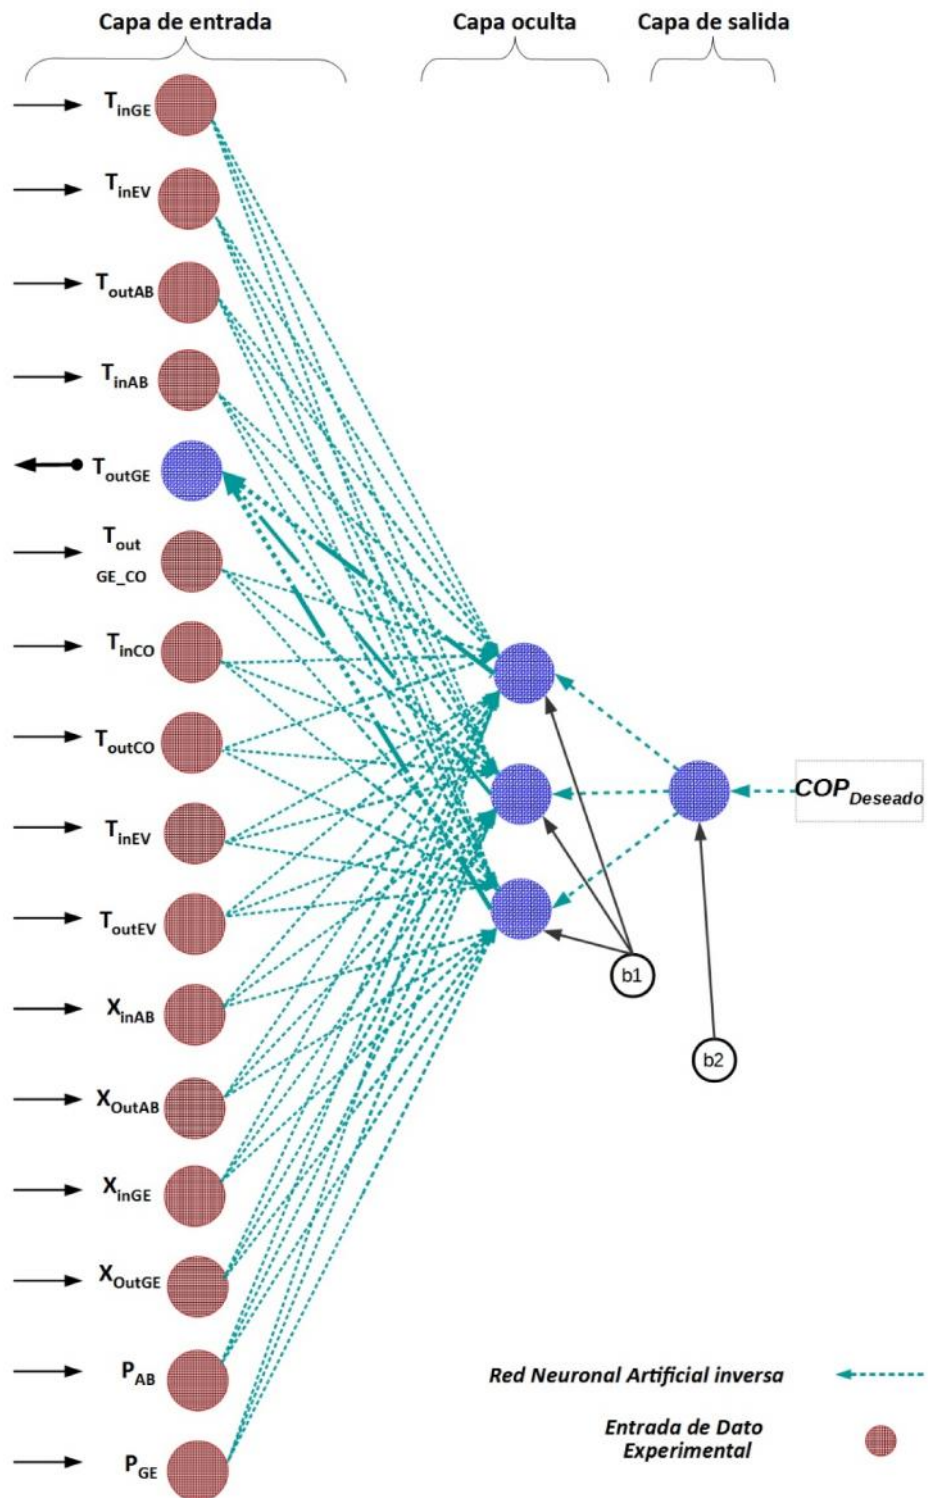


Figura 14. Diagrama esquemático del modelo ANN para optimizar una variable

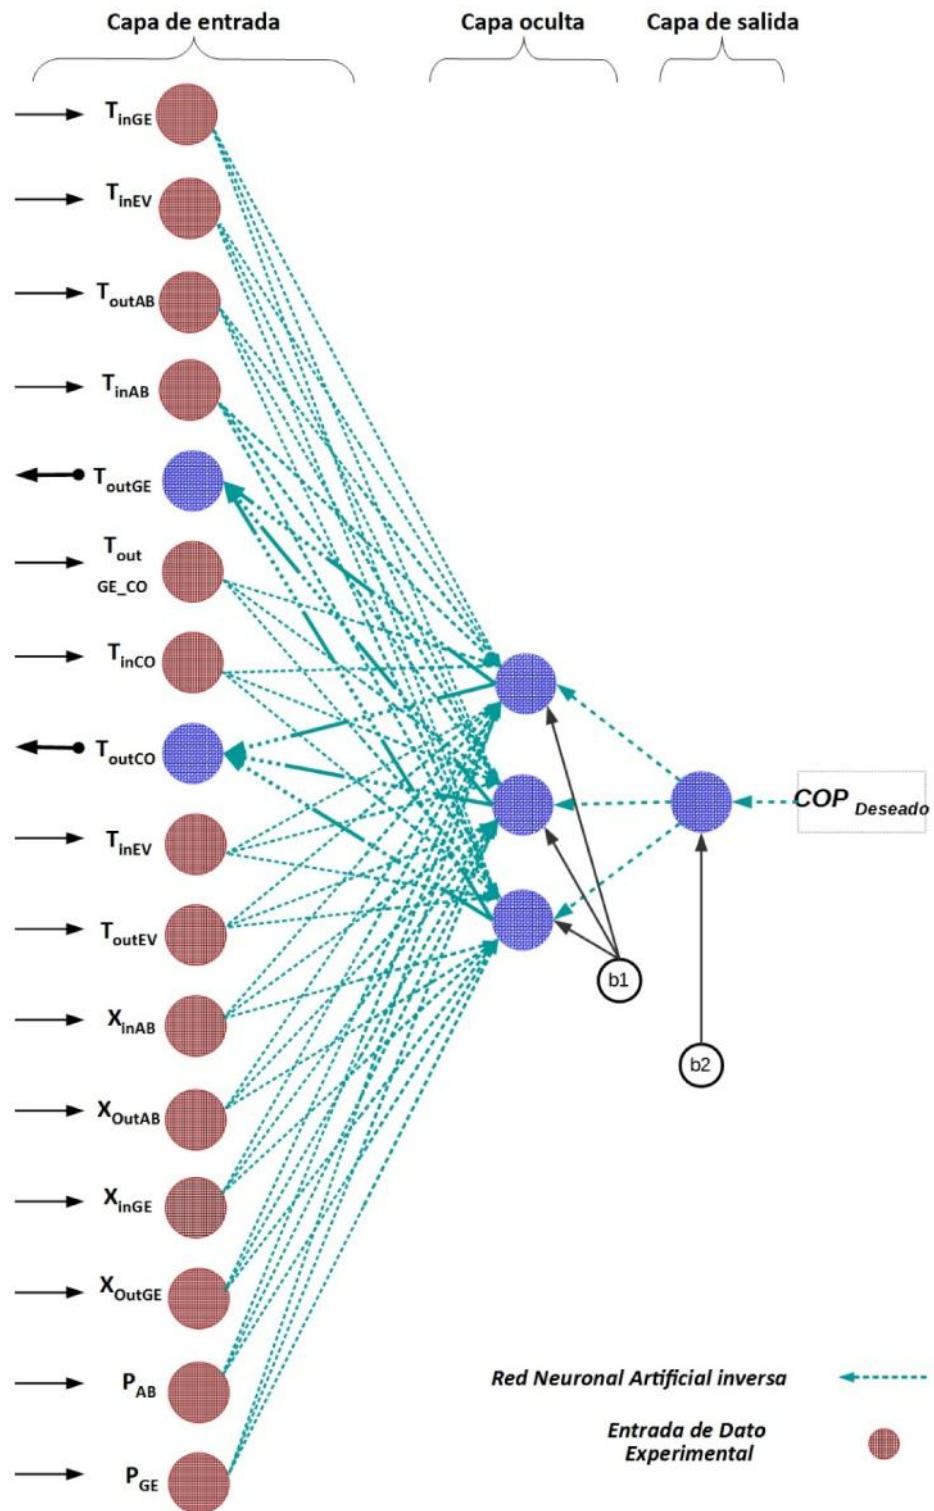


Figura 15. Diagrama esquemático del modelo ANN para optimizar dos variables.

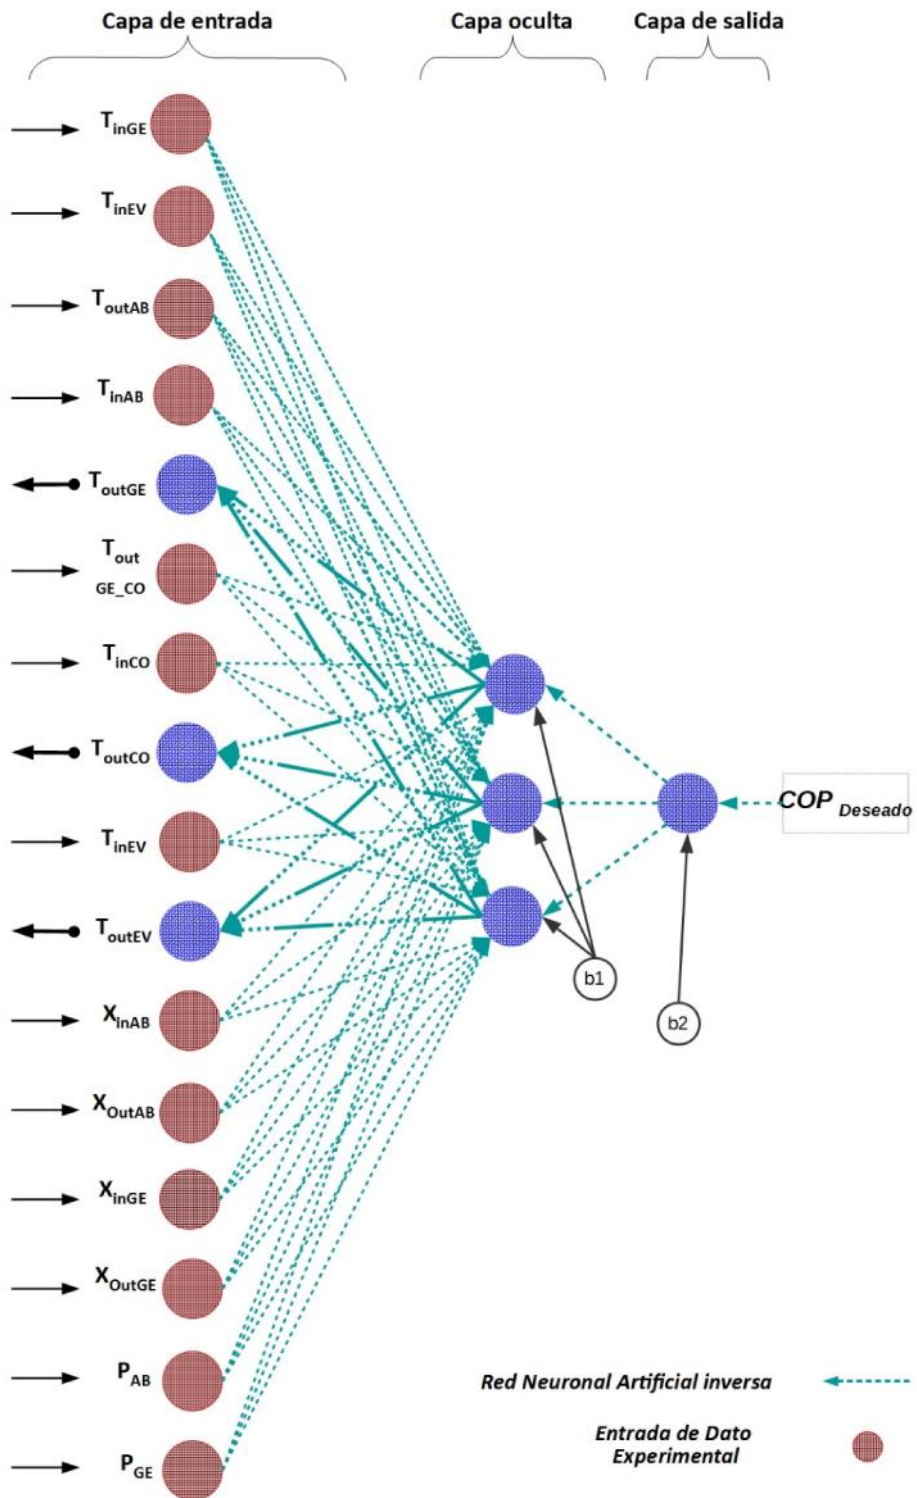


Figura 16. Diagrama esquemático del modelo ANN para optimizar tres variables.

3.3. MODELO GA COMO GENERADOR DE SOLUCIONES

La programación de GA consiste en usar sus propiedades para realizar búsquedas de posibles soluciones iniciando con una población inicial sin caer en un punto de referencia como otros métodos de optimización. La **Figura 17** muestra un diagrama de flujo de un algoritmo genético general, donde una vez inicializado el conjunto de etapas se ejecutan iterativamente hasta encontrar la solución óptima, minimizando la función multi variable acercándose lo más posible a cero, ya que el fitness que se obtiene en cada generación del GA, es comparado con el que se desea [28]. En la **Tabla 4** se muestra los parámetros de ajuste de los operadores genéticos utilizados para resolver la función multi variable propuesta por el modelo de ANNi.

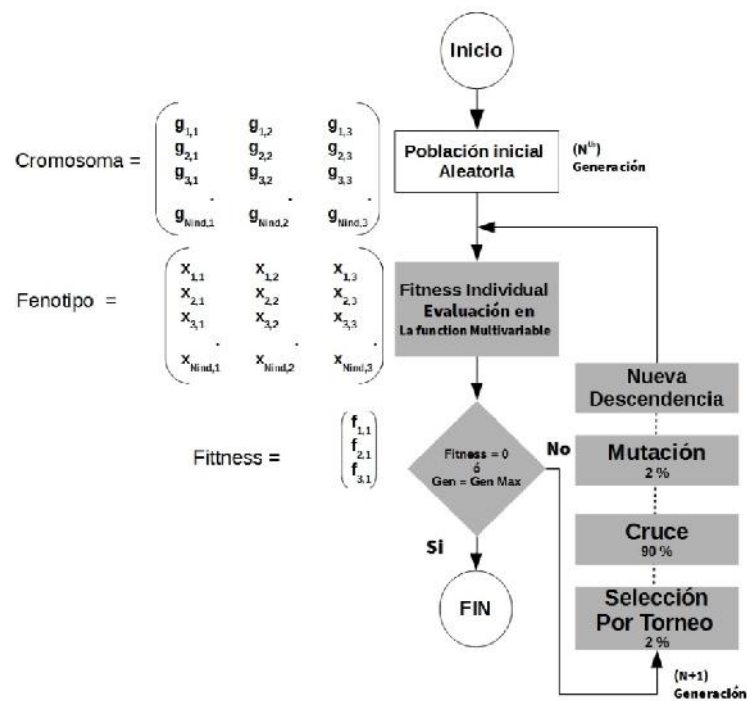


Figura 17 Diagrama de flujo general para programar un AG

Tabla 4 Ajuste de parámetros empleados en el modelo ANNi-GA.

Parámetro	Valor
Tamaño de la Población	100
Variabes	3
Máximo número de generaciones	150
Grado de Mutación	0.2
Estrategia de Cruce	Cruce solo un punto

3.4. ACOPLAMIENTO DEL MODELO DE LA RED NEURONAL INVERSA Y EL ALGORITMO GENÉTICO

Con la finalidad de validar el correcto funcionamiento del acople entre el modelo de ANNi con el modelo de GA, (ANNi - GA). Y que además sea capaz de realizarla optimización multi variable, para este propósito se eligieron tres pruebas experimentales para ser probadas en este modelo, estas pruebas corresponden a momentos diferentes en el tiempo de operación del HTA en estado estable y con diferentes condiciones a las que les corresponde un coeficiente de operación distinto COP. El detalle de las pruebas son mostradas en la **Tabla 5**

Tabla 5 Pruebas experimentales elegidas a las que se les aplico el modelo ANNi-GA.

Número de variables	Test	1	2	3
Temperaturas °C				
1	T _{in.GE-AB}	81.36	87.93	83.99
2	T _{in.EV-AB}	85.25	81.47	76.87
3	T _{out.AB-GE}	91.52	96.84	89.94
4	T _{in.AB-GE}	88.48	88.5	83.37
5	T_{out.GE-AB}	81.36	87.93	83.99
6	T _{out.GE-CO}	82	81.81	78.38
7	T _{in.CO}	42.79	50.18	42.66
8	T_{out.CO}	30.48	32.15	28.9
9	T _{in.EV}	32.26	33.44	67.39
10	T_{out.EV-AB}	85.25	81.47	76.87
Concentraciones (%)				
11	X _{in.AB}	55.25	55.25	52.39
12	X _{out.AB}	54.33	54.33	51.08
13	X _{in.GE}	54.33	54.33	51.08
14	X _{out.GE}	55.97	55.97	53.49
Presión (in.Hg, absoluto)				
15	P _{AB}	9	9	10
16	P _{GE}	21.1	21.1	20
COP_{EXP}		0.26	0.29	0.34

Una vez que se aplicó el modelo ANNi-GA a las pruebas experimentales, el modelo propuesto demostró ser capaz de predecir el valor de una variable de entrada (TGE, TEV, TCO) hasta con un grado de error de cero, esto se muestra en la **Tabla 6**. En la **Tabla 7** se muestra el error obtenido al buscar dos variables al mismo tiempo (TGE – TCO y TGE - TEV), logrando un error máximo de 6.79% cuando se predice TCO y por último en la **Tabla 8** se muestra el error obtenido cuando se buscan tres variables al mismo tiempo (TGE, TCO, TEV), en donde nuevamente al predecir el TCO el error máximo es de 13.94 %. Con esta prueba se valida que el modelo

ANNi-GA es capaz de predecir valores de las variables de entrada a partir de un COP experimental.

Tabla 6 Comparación entre los valores experimentales y los obtenidos por el modelo ANNi-GA para una variable a la vez.

Variable	Dato Experimental	ANNi -GA	MAPE (%)	COP
T _{GE}	81.86	81.36	0.6107989	0.26
T _{CO}	30.48	30.47	0.0328084	0.26
T _{EV}	85.25	85.25	0	0.26
T _{AB}	91.52			0.26

Tabla 7 Comparación entre los valores experimentales y los obtenidos por el modelo ANNi-GA para dos variables a la vez.

Variable	Datos Experimentales	ANNi-GA	MAPE (%)	COP
T _{GE}	81.86	81.28	0.7085268	0.26
T _{CO}	30.48	28.41	6.7913386	0.26
T _{EV}	85.25	85.25		
T _{AB}	91.52	91.52		

Variable	Datos Experimentales	ANNi-GA	MAPE (%)	COP
T _{GE}	81.86	81.24	0.7573907	0.26
T _{CO}	30.48	30.48		
T _{EV}	85.25	85.91	0.7741935	0.26
T _{AB}	91.52	91.52		

Tabla 8 Comparación entre los valores experimentales y los obtenidos por el modelo ANNi-GA para tres variables a la vez.

Variable	Datos	ANNi-GA	MAPE	COP
	Experimentales		(%)	
	(°C)			
T _{GE}	81.86	81.73	0.1588077	0.26
T _{CO}	30.48	34.73	13.94357	0.26
T _{EV}	85.25	84.97	0.3284457	0.26
T _{AB}	91.52	91.52		

Desde sus inicios la metodología ANNi se plantea para optimizar una variable a la vez, utilizando el algoritmo Simplex (Nelder-Mead), ya que por la complejidad de la función y las restricciones del algoritmo la búsqueda solo permite una variable a la vez. Por esta razón, se propone utilizar otros algoritmos de optimización, como el algoritmo genético, al presentar ventajas que permiten facilitar la búsqueda de variables óptimas, como las siguientes:

- a) Parten de la búsqueda en una población de posibles soluciones en lugar de uno solo.
- b) Pueden buscar múltiples variables a optimizar, en corto tiempo.
- c) Los algoritmos genéticos usan operadores aleatorios durante todo el proceso incluyendo reproducción, cruce y mutación que permite mejorar la búsqueda de óptimos.
- d) Los algoritmos genéticos son ciegos, ya que no se necesita información específica sobre el problema deseado para obtener la solución final.

La **Figura 18** presenta el acoplamiento ANNi-AG con la novedad de optimizar más de una variable de entrada, ya que actualmente todos los trabajos relacionados con la Red Neuronal Artificial inversa solo optimizan una variable a la vez. El objetivo final es que al optimizar más de una variable de entrada se controle el sistema de una mejor manera y se incremente su rendimiento más que cuando solo se optimiza

una variable a la vez, obteniendo ventajas como el ahorro de energía por el uso adecuado de las variables de entrada.

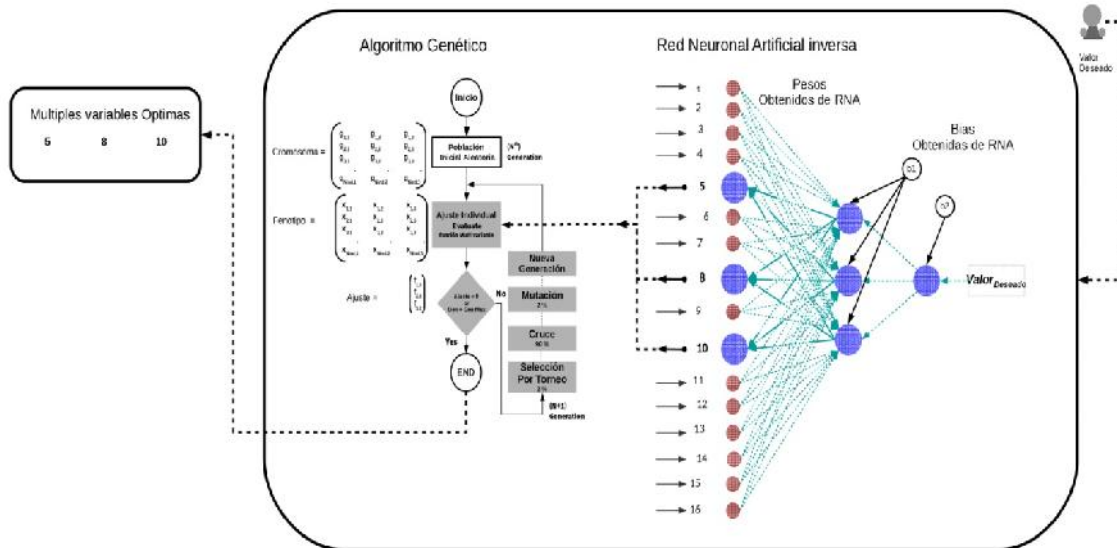


Figura 18 Acoplamiento ANNi-GA para optimizar múltiples variables de entrada

CAPITULO 4

4. DATOS EXPERIMENTALES

4.1. ANÁLISIS

Los datos experimentales usados provienen de Hernández y otros [30], en donde la energía reciclada es aplicada a un AHT, al que se le ha acoplado un sistema purificador de agua. A partir de estos datos se obtienen diferentes valores para el COP, este valor depende directamente de los parámetros de operación, tales como las temperaturas de entrada y salida de cada componente (AV, GE, EV y CO), presión (AB, GE) y la concentración de la solución de trabajo. La mezcla de LiBr-H₂O es usada como solución de trabajo y se confirma la concentración mediante el refractómetro mediante el índice de refracción.

Los datos fueron recolectados por un intervalo de 2 h a 4 h, posteriores al inicio del equipo, la colecta de los datos de las variables se realizó cuando se alcanzó el estado estable de operación, este estado se determina cuando las lecturas de temperatura de salida en cada componente muestra variaciones de ± 0.1 °C registrada por la computadora. Las condiciones de operación son obtenidas en tiempo real por un adquisidor de datos, con el cual se colectan los datos que permitieron desarrollar el modelo de Red neuronal Artificial ANN.

Los intervalos de operación usados y obtenidos de la base de datos, de las mediciones de cada uno de los parámetros del AHT se muestran en la **Tabla 2**

Tabla 2. Intervalos de las condiciones de operación experimentales usadas para calcular el valor del COP.

Número de variable	Temperatura (°C)	Intervalos de las condiciones estudiadas	
		Inferior	Superior
1	$T_{in.GE-AB}$	71.84	91.61
2	$T_{in.EV-AB}$	69.34	89.93
3	$T_{out.AB-GE}$	74.46	98.27
4	$T_{in.AB-GE}$	73.27	92.15
5	$T_{out.GE-AB}$	71.84	91.61
6	$T_{out.GE-CO}$	72.04	83.89
7	$T_{in.CO}$	39.42	65.05
8	$T_{out.CO}$	26.75	33.79
9	$T_{in.EV}$	28.52	81.34
10	$T_{out.EV-AB}$	69.34	89.93
Concentraciones (%)			
11	$X_{in.AB}$	51.66	55.36
12	$X_{out.AB}$	50.75	54.36
13	$X_{in.GE}$	50.75	54.36
14	$X_{out.GE}$	53.16	56.07
Presión (in.Hg, absoluto)			
15	P_{AB}	7	11.5
16	P_{GE}	20	21.1

5. APLICACIÓN DE LA METODOLOGÍA HÍBRIDA EN UN TRANSFORMADOR TÉRMICO POR ABSORCIÓN CON RECICLADO DE CALOR.

El objetivo de cada proceso industrial es obtener a partir de la materia prima un producto deseable. Sin embargo, para llegar a esto, la materia prima requiere de procesos intermediarios que permitan transformarla. En cada uno de estos procesos es necesario utilizar fuentes de energía para realizar la transformación y obtener la elaboración del producto final. La energía utilizada se aplica en calderas, turbinas o directamente en el proceso, una vez que la energía ha realizado su función se libera al medio ambiente. La aplicación de un método de optimización para un transformador térmico por absorción tiene su justificación en dos puntos: aprovechar la energía de desecho por los procesos industriales y realizar la optimización de múltiples variables de entrada con el fin de que el equipo incremente su rendimiento y por lo tanto se incremente la energía útil a reutilizar.

La **Figura 19** muestra un esquema general de cómo está conformado el método de optimización para un transformador térmico por absorción. El método acopla tres procesos fundamentales para llevar a cabo la optimización. El primer proceso, consiste en obtener los datos experimentales del transformador térmico por absorción y posteriormente hacer pasar por una normalización, ya que antes de pasar al siguiente proceso es necesario definir el valor que se desea mejorar, siendo el valor del coeficiente de operación del equipo (COP) el más adecuado y junto con las variables de entrada son normalizados dentro de un intervalo de [0-1]. El segundo proceso, consiste en aplicar un modelo de Redes Neuronales Artificiales para simular el comportamiento del COP a partir de las variables de entrada. Finalmente, el tercer proceso consiste en aplicar la función de la Red Neuronal Artificial inversa y el algoritmo genético para optimizar múltiples variables de entrada, entre las cuales se eligieron: la temperatura de entrada en el generador (T_{GE}), condensador (T_{CO}) y evaporador (T_{EV}), con el fin de obtener un valor de COP mejorado.




Figura 19 Esquema general de la estrategia de optimización de múltiples variables.

El primer proceso es sencillo de llevar a cabo, ya que los datos se adquieren y se registran con un adquisidor de datos y la normalización de datos se realiza aplicando la ecuación (11).

Para el segundo y tercer proceso son más complejos de llevar a cabo, por esta razón la **Figura 20** muestra con más detenimiento como se realiza el modelado del proceso. Una vez que los datos ya normalizados y el valor a simular es elegido, se introducen al modelo de Redes Neuronales Artificiales. El modelo aleatoriamente divide los datos en entrenamiento-prueba y validación. Los datos de entrenamiento-prueba sirven para llevar a cabo el aprendizaje del modelo, ya que se comparan directamente con los datos de validación, este paso se realiza iterativamente hasta que el error entre los datos de entrenamiento-prueba y los de validación se reducen al mínimo posible. Si no se logra satisfacer el criterio de error es necesario incrementar el número de neuronas en la capa oculta y realizar nuevamente el proceso de aprendizaje. Finalmente, una vez obtenido el error mínimo, se utilizan los coeficientes de pesos y bias resultantes en el tercer proceso.

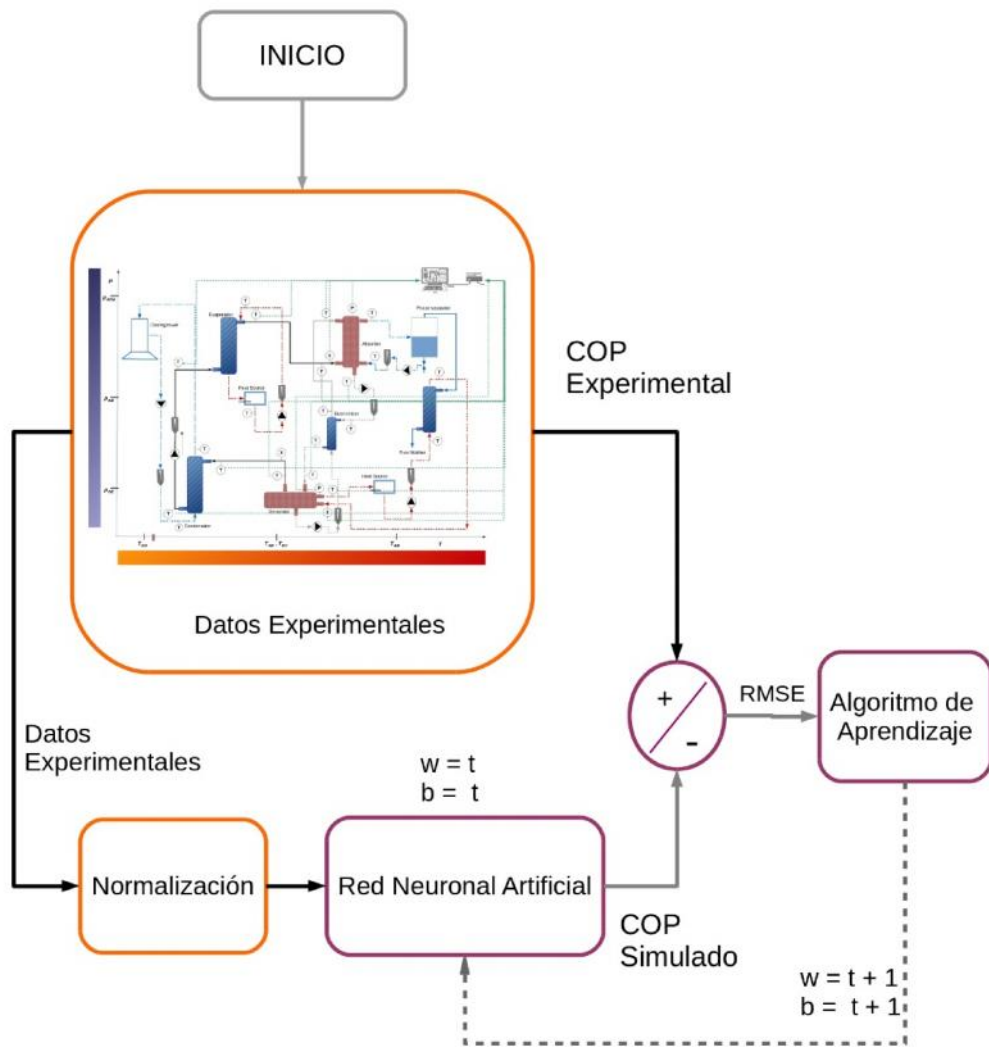


Figura 20 Diagrama general de obtención de una red neuronal artificial

La **Figura 21** muestra a detalle cómo se lleva a cabo el método de optimización. Una vez que se han obtenido los coeficientes de pesos y bias finales por el entrenamiento de la Red Neuronal Artificial se procede a utilizarlos para plantear la Red Neuronal Artificial inversa. El planteamiento inicia con definir qué valor de COP deseado se pretende alcanzar, para lograr así, despejar las variables de entrada de la ecuación general que simula el valor del COP. La ecuación (11) modela a partir

de las variables de entrada el valor del COP. Mientras, la ecuación (12) realiza el planteamiento de una función objetivo para obtener hasta 3 variables de entrada óptimas a partir de un valor de COP deseado.

$$Fun(T_{GE}, T_{CO}, T_{EV}) = b2_{(j)} - \sum_{j=1}^S Wo_{(j)} - COP + \dots \quad (11)$$

$$\sum_{j=1}^S \left[\frac{2Wo_{(j)}}{1 + \exp\left(-2(Wi_{(j,5)} \cdot T_{GE} + Wi_{(j,8)} \cdot T_{CO} + Wi_{(j,10)} \cdot T_{EV} + \sum_{k \neq 5,8,10}^k Wi_{(j,k)} \cdot In_{(k)} + b1_{(j)})\right)} \right]$$

$$COP = b2_{(j)} - \sum_{j=1}^S Wo_{(j)} + \sum_{j=1}^S \left(\frac{2Wo_{(j)}}{1 + \exp\left(-2 \cdot \left(\sum_{k=1}^K (Wi_{(j,k)} \cdot In_{(k)}) + b1_{(j)} \right)\right)} \right) \quad (12)$$

Dónde: S representa el número de neuronas en la capa oculta, In indica las variables de entrada, Wi pesos de entrada, Wo pesos de salida, $b1$ bia de entrada, $b2$ bia de salida y k, j indican el número de variables de entrada y el número de coeficientes de pesos y bias respectivamente.

La ecuación (19) se plantea como una función objetivo, la cual se resuelve minimizando el valor del COP deseado con respecto al COP obtenido al buscar las variables de entrada óptimas. Para realizar la búsqueda es necesario utilizar un algoritmo inteligente que permita encontrar las variables óptimas en el menor tiempo posible y con la mayor precisión. El algoritmo genético se programó para resolver la función objetivo a través de sus operadores genéticos y estableciendo un valor fitness que permita alcanzar el COP deseado.

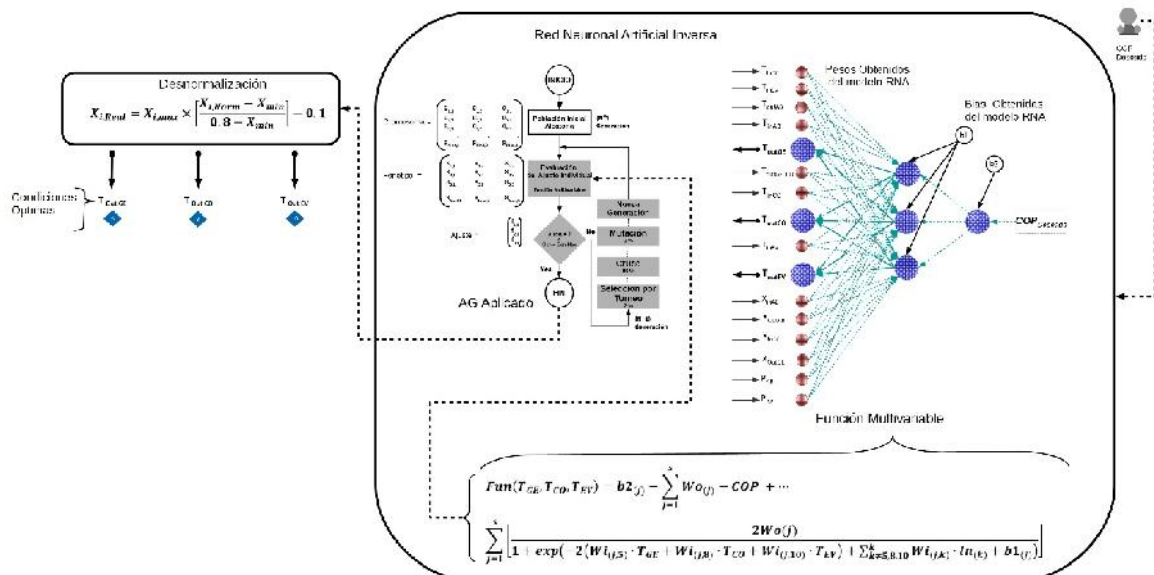


Figura 21 Acoplamiento del algoritmo de búsqueda a la estrategia de optimización

Finalmente, el acoplamiento de estos tres procesos permite optimizar un transformador térmico por absorción, encontrando condiciones óptimas de operación y brindando un control sobre el equipo. La importancia de este método recae en que se realiza una optimización de múltiples variables en este caso hasta 3 variables con la certeza de que los resultados obtenidos sean alcanzados durante la operación del equipo, ya que primero se simula el proceso con datos reales y después se optimiza, lo cual es difícil de realizar por otros métodos que simulan en condiciones ideales y se alejan de las condiciones reales del equipo.

6. RESULTADOS

6.1. OPTIMIZACIÓN DE UNA VARIABLE USANDO ANNi-GA.

Una vez que se ha validado la capacidad del modelo ANNi-GA, para encontrar los valores de las variables de entrada, esta se utilizó para buscar valores óptimos e

incrementar el valor del COP. El procedimiento para optimizar una variable a la vez, primer paso, se mantuvieron sin cambio 16 variables excepto la variable TGE, para obtener la temperatura óptima en la que el valor del COP se incrementa, subsecuentemente y de la misma manera se mantuvieron sin cambio 16 variables y excepto TEV y finalmente se mantuvieron fijas 16 variables excepto el TCO, en la **Tabla 9** se muestra la aplicación del modelo ANNi-Ga para tres pruebas experimentales elegidas previamente.

Tabla 9 Aplicación del modelo ANNi-GA para incrementar el valor Del COP optimizando una variable a la vez.

Variable	Dato	Optimización ANNi-GA			
	Experimental	T _{GE}	T _{CO} (° C)	T _{EV}	Temperatura Suministrada (° C)
Test 1					
T _{GE}	81.36	88.5	81.36	81.36	7.14
T _{CO}	30.48	30.48	20	30.48	
T _{EV}	85.25	85.25	85.25	87.6	2.35
COP	0.26	0.4	0.3	0.28	
Test 2					
T _{GE}	87.93	90.1	87.93	87.93	2.17
T _{CO}	32.15	32.15	20	32.15	
T _{EV}	81.47	81.47	81.47	87.6	6.13
COP	0.29	0.33	0.3	0.33	
Test 3					
T _{GE}	83.99	88	83.99	83.99	4.01
T _{CO}	28.9	28.9	26	28.9	
T _{EV}	76.87	76.87	76.87	85	8.13
COP	0.34	0.4	0.35	0.4	

6.2. OPTIMIZACIÓN DE DOS VARIABLES USANDO ANNi-GA.

El modelo ANNi-GA, fue usado para optimizar dos variables al mismo tiempo en tres pruebas experimentales, 15 variables se mantuvieron sin cambio excepto las variables TGE y TEV, como fue ya demostrado, previamente la variable TCO no logra incrementar el valor del COP. La **Figura 22** muestra como el modelo ANNi-GA es capaz de optimizar dos variables a la vez mediante la función multi variable, incrementando el valor del COP. Para a) la aplicación del modelo ANNi-GA en la primer prueba experimental se observa que al optimizar dos variables es posible alcanzar un COP de 0.26 a 0.43, el límite de la prueba se fijó a 90 °C, ya que esta temperatura es considera el límite para el calor de recicle que puede alimentar al HTA. Para b) el modelo ANNi-GA es aplicado en la segunda prueba experimental, en donde se observa que la optimización de dos variables logra incrementar el COP de 0.29 a 0.33. Para c) el modelo de ANNi-GA se aplica a la tercera prueba experimental, en donde se observa que la optimización de dos variables incrementa el COP de 0.34 a 0.8.

El uso del modelo ANNi-GA en las tres pruebas experimentales: cuando se eleva la temperatura del generador; el COP se incrementa y puede darse un ahorro de energía en el evaporador, alcanzando un ahorro de 3 °C, solo para el correcto suministro de energía en ambos componentes.

Como el COP se incrementa por encima del valor alcanzado de manera experimental, este alcanza un punto en el que es necesario incrementar la temperatura en ambos componentes (GE EV), teniendo cuidado de no exceder los 90 °C para la energía suministrada, esto es posible incrementar más el COP, ya que de esta manera la temperatura suministrada no sería de recicle.


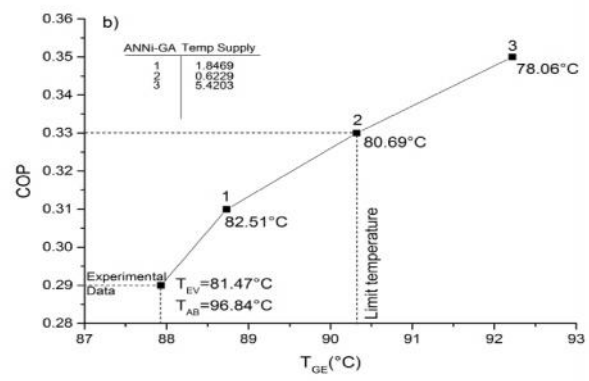



Figura 22 La optimización para dos variables usando el modelo de ANNi-GA, aplicado a tres pruebas experimentales con valores de COPEXP a) 0.26, b) 0.29 y c) 0.34

6.3. OPTIMIZACIÓN DE TRES VARIABLES USANDO ANNi-GA.

El modelo ANNi-Ga se usó para optimizar tres variables a la vez, en las tres pruebas experimentales; las 14 se mantuvieron sin cambio, con excepción de TGE, TEV y TCO, en la **Figura 23** se muestra que el modelo de ANNi-GA, es capaz de efectuar la optimización a través de la función objetivo multivariable, optimizando tres variables a la vez y con esto se logra incrementar el valor del COP. Para a) la aplicación del modelo ANNi-GA, en la primera prueba experimental, en donde a través de la optimización de tres variables es posible alcanzar un COP de 0.26 a 0.43. Para b) el modelo ANNi-GA aplicado en la segunda prueba experimental, en donde se observa que la optimización de tres variables logra incrementar el COP de 0.29 a 0.33. Para c) el modelo ANNi-GA aplicado a la tercera prueba experimental, en donde podemos observar que mediante la optimización de tres variables logra incrementar el COP de 0.34 a 0.38.

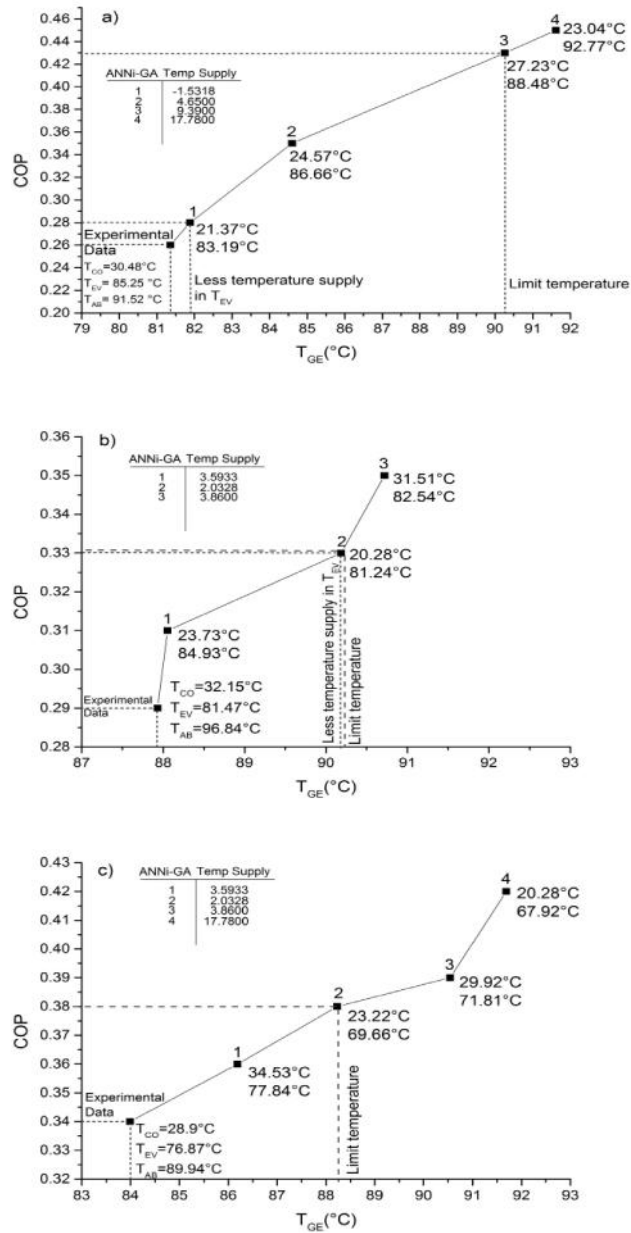


Figura 23. Optimización de tres variables usando el modelo ANNi-GA, aplicado a tres pruebas experimentales con valores de COPEXP, a) 0.26, b) 0.29 c) 0.34.

El incremento del valor del COP, es resultado en la mayoría de los casos cuando se incrementa la temperatura tanto en el generador y el evaporador y la disminución de

la temperatura en el condensador. Al llevar a cabo la optimización de tres variables al mismo tiempo, se obtienen los mismos resultados que cuando se optimiza solo dos variables, debido al hecho a que la temperatura en el condensador es una variable que no contribuye por si misma a incrementar el valor del COP. Sin embargo, el equipo experimental es mejor controlado, ya que solo estas tres variables impactan directamente al sistema. Para el generador y el evaporador, la energía suministrada es proveída por el calor de recicle, partiendo del absorbedor para reciclar energía, En el caso del condensador, el calor se retira por contacto con el medio ambiente. Los resultados obtenidos al optimizar una, dos y tres de las variables de entrada, al mismo tiempo, ubican a la temperatura del generado como una variable clave para el incremento del desempeño de equipo. Estos resultados son soportados por el hecho de que al equipo se le acopla un sistema purificador de agua para reciclar energía en el generador y el evaporador, el desempeño del equipo seria incrementado [30]. El generador es el componente que más se beneficia por el uso de reciclado de energía, permite realizar una mejor separación de la solución refrigerante del absorbente.

7. CONCLUSIONES

Para este trabajo se propone una función objetivo multi variable, para optimizar un transformador térmico por absorción con calor de recicle. Se propone un marco de trabajo consistente en desarrollar tres modelos, el primero es el modelo ANN, el segundo la inversa de esa red ANNi, el tercero un generador de soluciones haciendo uso de GA. El modelo propuesto para la red ANN, se desarrolla para predecir el valor de coeficiente de eficiencia (COP) del transformador térmico, para este sistema se considera como entradas a la ANN, las temperaturas de entrada y salida de los principales componentes, también se consideran las presiones y concentraciones de la solución de trabajo, la arquitectura de red que mejores predicciones logro obtener fue haciendo uso de tres neuronas en la capa oculta y aplicando la función de activación TANSIG, con un coeficiente de determinación R2 de 0.9935 y un MAPE de 1.04% entre los datos experimentales y los datos simulados los cuales muestran una correspondencia buena entre ambos grupos de datos.

El modelo de la ANNi, se desarrolla a partir de los pesos y bias que la ANN generada, creándose la función objetivo que permite optimizar las variables de entrada, como las temperaturas del generador, evaporador y el condensador,

La función objetivo se desarrolla para más de una variable a la vez. El GA se utiliza para resolver esta función multi variable con la finalidad de incrementar el valor del COP y optimizar las variables de entrada del HTA. El acoplamiento de los modelos ANNi-GA demuestra que esto es posible encontrar el valor experimental con un error de cero. Sin embargo, para encontrar dos o tres variables al mismo tiempo, la temperatura del condensador muestra un error máximo de 13.94 % en la predicción. Cuando se realiza la optimización de una variable a la vez, el comportamiento de las tres variables se compara, en donde la temperatura en el generador tiene gran impacto sobre el COP, desde el momento en el que el valor de esta variable se incrementa, el COP se incrementa de un 0.25 a 0.40, para el caso del evaporador

es necesario suministrar más energía comparado con el generador para incrementar el valor del COP, en el caso del condensador la temperatura debe disminuir para que el valor del COP se incremente, esta variable es la que menor preponderancia tiene en el comportamiento del sistema. Ya que por sí solo no logra incrementar el valor del COP. Al llevar a cabo la optimización multi variable de dos es posible incrementar el valor del COP de 0.34 a 0.38 y de esta manera obtener un ahorro de energía de 3 ° C, suministrándose correctamente entre el generador y el evaporador. Cuando la búsqueda por alcanzar un nivel de COP alto, sin que se exceda el límite de los 90 ° C en el suministro de calor de desecho, la interacción entre las tres variables se resume al incrementar la temperatura tanto en el generador como en el evaporador y reduciendo la temperatura en el condensador, para conseguir un valor de COP de 0.43. Al incrementarse el COP a causa del incremento de la temperatura en el generador y el evaporador se asocia directamente con el reciclado de energía, provisto durante el proceso de purificación de agua, aprovechando el calor latente, el generador puede separar de mejor manera el fluido absorbente que fluye del refrigerante y el evaporador puede enviar el fluido refrigerante a un nivel térmico más alto al absorbedor produciendo una mejor reacción exotérmica.

Finalmente el modelo ANNi-GA, muestra que es capaz de abrir la vía para futuras aplicaciones, donde sea necesario controlar múltiples variables para mejorar el desempeño del sistema.

8. REFERENCIAS

- [1] Octave Levenspiel. (1997). *Fundamentos de Termodinámica*. México: Pearson-Prentice Hall.
- [7] Encyclopedia britannica <https://www.britannica.com/biography/Sadi-Carnot-French-scientist>.
- [3] Haykin, Simon *Neural networks and learning machines* / Simon Haykin. 3rd ed. p. cm. Rev. ed of: *Neural networks*. 2nd ed., 1999. ISBN-13: 978-0-13-147139-9.
- [4] Yegnanarayana, B. (2009). *Artificial Neural Networks*. India: PHI Learning Pvt. Ltd.
- [5] Sablani, S.S., Datta, A.K., Rahman, M.S. y Mujumdar, A.S. (2006). *Handbook of Food and Bioprocess Modeling Techniques*. New York: CRC/Taylor & Francis.
- [6] McCulloch, W. S. y Pitts, W. (1943). A logical calculus of the ideas immanent in neurons activity. *The bulletin of Mathematical Biophysics*, 5(4), 115-133.
- [7] Redolar, R.D. (2008). *Cerebro y adicción*. España: Editorial UOC.
- [8] Herculano-Houzel, S. (2009). The Human Brain in Numbers: A Linearly Scaled-up Primate Brain. *Frontiers in Human Neuroscience*, 3, 31.
- [9] Williams, R.J.P. (2003). The biological chemistry of the brain and its possible evolution. *Inorganica Chimica Acta*, 356, 27-40.
- [10] Andreev, A. V., Makarov, V. V., Runnova, A. E., Pisarchik, A. N., y Hramov, A. E. (2018). Coherence resonance in stimulated neuronal network. *Chaos, Solitons & Fractals*, 106, 80-85.
- [11] Da Silva, I.N., Hernane Spatti, D., Andrade Flauzino, R., Liboni, L.H.B., y dos Reis Alves, S. F. (2017). *Artificial Neural Networks: A Practical Course*. Suiza: Springer International Publishing.
- [12] Flores, L.R., y Fernández, F.J.M. (2008). *Las redes neuronales artificiales Fundamentos teóricos y aplicaciones prácticas*. España: Editorial netbiblo.
- [13] Bassam, A., Conde-Gutierrez, R.A., Castillo, J., Laredo, G., y Hernandez, J.A. (2014). Direct neural network modeling for separation of linear and branched paraffins by adsorption process for gasoline octane number improvement. *Fuel*, 124, 158-167.
- [14] Verma, S.P. (2005). *Estadística básica para el manejo de datos experimentales: Aplicación en la Geoquímica (Geoquimiometría)*. México. Universidad Nacional Autónoma de México.

- [15] Mohanraj, M., Jayaraj, S., y Muraleedharan, C. (2012). Applications of artificial neural networks for refrigeration, air-conditioning and heat pump systems-A review. *Renewable and Sustainable Energy Reviews*, 16(2), 1340-1358.
- [16] Hernandez, J.A. (2009). Optimum operating conditions for heat and mass transfer in foodstuffs drying by means of neural network inverse. *Food Control*, 20(4), 435–438.
- [17] Hernandez, J.A. (2009). Optimum operating conditions for heat and mass transfer in foodstuffs drying by means of neural network inverse. *Food Control*, 20(4), 435–438.
- [18] Hamzaoui, Y. E., Hernández, J. A., Silva-Martínez, S., Bassam, A., Álvarez, A., y Lizama-Bahena, C. (2011). Óptimal performance of COD removal during aqueous treatment of alazine and gesaprim commercial herbicides by direct and inverse neural network. *Desalination*, 277(1-3), 325-337.
- [19] Labus, J., Hernández, J. A., Bruno, J. C., y Coronas, A. (2012). Inverse neural network based control strategy for absorption chillers. *Renewable Energy*, 39(1), 471-482.
- [20] Laidi, M., y Hanini, S. (2013). Óptimal solar COP prediction of a solar-assisted adsorption refrigeration system working with activated carbon/methanol as working pairs using direct and inverse artificial neural network. *International Journal of Refrigeration*, 36(1), 247-257.
- [21] Liu, F. B. (2008). A modified genetic algorithm for solving the inverse heat transfer problem of estimating plan heat source. *International Journal of Heat and Mass Transfer*, 51(15-16), 3745-3752.
- [22] Darwin, C. (1859). *On the Origin of Species by Means of Natural Selection*. London. John Murray.
- [23] Holland, J. H. (1975). *Adaptation in Natural and Artificial Systems*. University of Michigan Press, Ann Arbor. Republished by the MIT press, 1992.
- [24] Goldberg, D. E. (1989). *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison-Wesley Longman Publishing Co., Inc., Boston, MA, USA.
- [25] McCall, J. (2005). Genetic algorithms for modelling and optimisation. *Journal of Computational and Applied Mathematics*, 184(1), 205-222.
- [26] Gestal, M., Rivero, D., Rabuñal, J. R., Dorado, J., y Pazos, A. (2010). Introducción a los algoritmos genéticos y la programación genética. A Coruña, 2010, 30-68.

[27] Hernández, J. A. (2009). Optimum operating conditions for heat and mass transfer in foodstuffs drying by means of neural network inverse. *Food Control*, 20(4), 435–438.

[28] Holland, J. H. (1975). *Adaptation in natural and artificial systems*. Ann Arbor, MI: University of Michigan Press.

[30] Hernández, J. A., Bassam, A., Siqueiros, J., & Juárez-Romero, D. (2009). Optimum operating conditions for a water purification process integrated to a heat transformer with energy recycling using neural network inverse. *Renewable Energy*, 34(4), 2009, 1084-1091.