



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

***“LA MULTIVARIABILIDAD DE LA INVERSA DE LA RED NEURONAL ARTIFICIAL APLICADA
A PROCESOS”***

TESIS PARA OBTENER EL GRADO DE:

DOCTOR EN INGENIERÍA Y CIENCIAS APLICADAS

PRESENTA:

MICA. ULISES CRUZ JACOBO

ASESORES:

DR. JOSÉ ALFREDO HERNÁNDEZ PEREZ

DR. ROBERTO AGUSTÍN CONDE GUTIÉRREZ

SINODALES:

DRA. ARIANNA PARRALES BAHENA

DR. ARMANDO HUICOCHEA RODRÍGUEZ

DR. ALBERTO ÁLVARES GALLEGOS

DR. JESUS EMMANUEL SOLIS PÉREZ

DR. JOSÉ ALFREDO RODRÍGUEZ RAMÍREZ

CUERNAVACA MOR.

AGOSTO 2022

RESUMEN

El objetivo primordial de esta Tesis Doctoral es proponer una metodología computación que permita realizar la optimización de diferentes sistemas experimentales generando modelos de procesos, en aplicaciones complejas del área de ingeniería, para las cuales muy costoso o tomaría mucho tiempo realizar los cálculos matemáticos para encontrar la relación directa que existe entre las variables de entrada y las variables de salida mediante modelos matemáticos sencillos o aproximaciones estadísticas.

Aunado a la creación del modelo del sistema experimental estudiado, resulta ser de gran interés el hecho de aplicar métodos metaheurísticos con los que se han de resolver las funciones objetivo con las que se realizará la optimización buscando tener además un costo computacional mínimos. Estos metaheurísticos pueden obtener valores óptimos para múltiples variables incógnitas al mismo tiempo.

En la actualidad para muchos de los problemas de clasificación, regresión, clasificación y optimización, se hace uso de metodologías computacionales nuevas, basadas en inteligencia artificial. La inteligencia artificial es parte de las ciencias computacionales que busca hacer automática la respuesta de un sistema a los estímulos que recibe y aportar una salida válida de manera física. Esta clase de respuesta se produce a una fase de entrenamiento en la que de forma literal se realiza un proceso de aprendizaje, en este entrenamiento se presentan muestras o registros históricos válidos, con sus correspondientes salidas, de esta forma se logra llevar a cabo este proceso de aprendizaje y a partir de esto propone los valores de salida correspondientes a nuevos estímulos que no fueron utilizados en la fase de entrenamiento previamente.

Este tipo de entrenamiento se llama aprendizaje supervisado. Aunque también se puede dar el caso de que el modelo se genere a partir de la asociación de las variables de entrada con características similares entre sí para obtener una clasificación de las muestras de entrada sin necesidad de un patrón de salida. Este modelo de aprendizaje se llama no supervisado. Una de las herramientas de la inteligencia artificial para la clasificación y simulación son las redes neuronales artificiales ANN. Estas ANN son modelos que han demostrado sus ventajas en el ámbito del modelado y de la simulación o predicción frente a otros métodos clásicos.

No podemos dejar de mencionar el preprocesamiento de las variables para optimizar la respuesta de un sistema de predicción basado en redes neuronales. Tan importante es la adecuación de las variables de entrada como el correcto diseño del sistema predictivo. Por ello, se ha dedicado especial atención al análisis de la selección de variables de entrada de un sistema y su transformación (escalado, proyección, etc.) para optimizar su respuesta. En concreto, se ha hecho uso de un criterio que se utiliza cada vez más para decidir qué variables son verdaderamente importantes para una predicción. Dicho criterio se denomina Test Delta, y es un estimador no paramétrico que se basa en la aproximación de la varianza

del ruido a la salida de una función. La combinación de variables de entrada que suponga la minimización de dicho criterio conseguirá un óptimo comportamiento predictivo de la red neuronal bajo estudio. Este método se evaluará sobre conjuntos de datos reales para comprobar su utilidad práctica.

ABSTRACT

The primary objective of this Doctoral Thesis is to propose a computational methodology that allows the optimization of different experimental systems by generating process models, in complex applications in the engineering area, for which it is very expensive or would take a long time to carry out the mathematical calculations to find the direct relationship that exists between input variables and output variables through simple mathematical models or statistical approximations.

In addition to the creation of the model of the studied experimental system, it turns out to be of great interest the fact of applying metaheuristic methods with which the objective functions must be solved with which the optimization will be enhanced, also seeking to have a minimum computational cost. These metaheuristics can obtain optimal values for multiple unknown variables at the same time.

Nowadays, new computational methodologies are used for many of the classification, regression, classification, and optimization problems social intelligence is part of computational sciences that seeks to make the response of a system automatic to the stimuli it receives and provide a physically valid output. This kind of response occurs at a training phase in which a learning process is carried out, in this training samples or valid historical records are presented, with their corresponding outputs, in this way it is possible to carry out this process. of learning and from this it proposes the output values corresponding to new stimuli that were not previously used in the training phase.

This type of training is called supervised learning. Although it can also be the case that the model is generated from the association of input variables with similar characteristics to each other to obtain a classification of the input samples without the need for an output pattern. This model of learning is called unsupervised. One of the artificial intelligence tools for classification and simulation is the ANN artificial neural networks. These ANNs are models that have demonstrated their advantages in the field of modeling and simulation, or prediction compared to other classical methods.

We cannot fail to mention the preprocessing of the variables to optimize the response of a prediction system based on neural networks. The adequacy of the input variables is just as important as the correct design of the predictive system. For this reason, special attention has been devoted to the analysis of the selection of input variables of a system and its transformation (scaling, projection, etc.) to optimize its response. Use has been made of a criterion used more to decide which variables are truly important for a prediction. This criterion is called Test Delta, and it is a non-parametric estimator based on the approximation of the noise variance at the output of a function. The combination of input variables that implies the minimization of said criterion will achieve an optimal predictive behavior of the neural network under study. This method will be evaluated on real data sets to check its practical utility.

AGRADECIMIENTOS

Esta tesis no se hubiera podido realizar sin el apoyo y paciencia de algunas personas a las que quiero mostrar mi profundo agradecimiento por su papel fundamental en el desarrollo de esta.

En un principio quiero agradecer Doctor José Alfredo Hernández Pérez quien me ha recibido en su equipo de trabajo en el Centro de Investigación en Ingeniería y Ciencias Aplicadas de la Universidad Autónoma del Estado de Morelos con el Dr. Aprendí mucho el me mostró soluciones posibles a problemas en donde no se veía a simple vista que tuviera solución y siempre planteó inquietudes y vías de trabajo fomentando, la iniciativa, la creatividad y el interés por el trabajo de equipo. De igual forma doy las gracias al Dr. Roberto Conde Gutiérrez por su inestimable trabajo como codirector de tesis quien siempre se ofreció a ayudarme y explicarme además de mantenerse al pendiente del desarrollo de este.

Agradezco también, a otros compañeros y amigos becarios con los que compartí muchas horas de clase y de desarrollo de proyectos, compañeros y amigos.

Quiero expresar mi agradecimiento al Concejo Nacional de Ciencia y Tecnología por la beca Nacional de Doctorado otorgada para la realización de este trabajo de investigación.

Agradecimiento, muy especialmente, a mi familia completa quienes me han apoyado en la conclusión de esta tesis y de este proyecto de varios años en los que hemos compartido los días llenos de trabajo y las noches llenas de insomnio; gracias por su apoyo

A todos ellos, con mucha admiración y cariño ¡Gracias!

DEDICATORIAS

Dedico este trabajo a mis padres a Carlos y a Alice, a mis hijos Ximena, Diego Regina y Carlos, a mi hermana Araceli y a mi esposa que me ha acompañado en este viaje de investigación Raque te amo vida.

INDICE GENERAL

RESUMEN	2
ABSTRACT	4
AGRADECIMIENTOS	6
DEDICATORIAS	7
INDICE DE TABLAS	¡Error! Marcador no definido.
INDICE DE FIGURAS	11
NOMENCLATURA	12
CAPITULO I	14
1.1.- Introducción	14
1.2.- Optimización con restricciones y sin restricciones	16
1.3.- Optimización global y local	16
1.4.- Optimización estocástica y determinista	16
1.5.- Algoritmos de optimización	17
1.6.- Planteamiento del problema	19
1.7.- Alcance del trabajo	19
1.7.1.- Objetivo general	19
1.7.2.- Objetivos específicos	20
1.8.- Energías renovables	21
1.9.- Red Neuronal Artificial	22
1.9.1.- Entrenamiento	23
1.9.2.- Red Neuronal Artificial inversa	23
1.10.- Algoritmos Genéticos	25
1.11.- Enjambre de Partículas	25
1.12.- Recosido Simulado	26
1.13.- Búsqueda Ckukoo	27
CAPITULO II Estado del arte	29
CAPITULO III Descripción de las diferentes opciones experimentales de optimización en energía renovable y degradación de contaminantes	32
3.1.- Transformador Térmico	32
3.2.- Colector solar de canal parabólico	34
3.3.- Reactor de degradación por sonofotocatálisis	37

CAPITULO IV Descripción de la metodología de optimización multivariable (ANNi -)	40
4.1.- Desarrollo de la Metodología de Optimización Multivariable	40
4.2.- Transformador térmico por absorción incremento del rendimiento	42
4.2.1.- Desarrollo	42
4.2.2.- Resultados parciales	43
4.3.- Colector solar de canal parabólico, incremento del rendimiento	44
4.3.1.- Desarrollo	44
4.3.2.- Resultados parciales	46
4.4.- Reactor de degradación por sonofotocatalisis, disminución de la necesidad de oxígeno	47
4.4.1.- Desarrollo	47
4.4.2.- Resultados parciales	48
CAPITULO V	50
5.1.- Resultados y Conclusiones Generales	50
PERSPECTIVAS FUTURAS	52
BIBLIOGRAFÍA	53

INDICE DE FIGURAS

Figura 1 Modelo de entrenamiento de una ANN.....	22
Figura 2 Red neuronal artificial inversa.....	24
Figura 3 Diagrama de Flujo Algoritmos Genéticos.....	25
Figura 4 Diagrama de Flujo de PSO	26
Figura 5 Diagrama de flujo de recosido simulado.....	27
Figura 6 Diagrama de flujo de la Busqueda Cukoo	27
Figura 7 Diagrama del trasformador térmico	32
Figura 8 Diagrama experimental del Colector Solar Parabolico	36
Figura 9 Diagrama experimental del Reactor Químico de degradación	37
Figura 10 Entrenamiento Reactor Químico.....	41
Figura 11 Diagrama del reactor sonofotocatalitico.....	48

NOMENCLATURA

ANN	Red Neuronal Artificial	IW or Wih	Matriz de pesos obtenidos en la capa oculta
ANNi Artificial	Inversa de Red Neuronal Artificial	LW or Who	Matriz obtenida en la capa oculta.
ANNim	Inversa Multivariable Red Neuronal Artificial	L	Longitud [m]
GA	Algoritmos Genéticos	m'	Flujo másico ($m' = \rho Fw$) [kg/s]
LM	Algoritmo de entrenamiento Levenberg-Marquardt	Nh	Numero de neuronas en la capa de entrada.
LOGSIG	Función de transferencia logarítmica sigmoide	Ni	Numero de neuronas en la capa de salida.
MAPE	Porcentaje del Error Medio Absoluto	$Q' u$	Calor Útil [W]
PSO	Algoritmo de Optimización Enjambre de partículas	$Q' c$	Calor concentrado (Aa Gb) [W]
PTC	Parabolic trough collector	R2	Coefficiente de determinación
PURELIN	Función de transferencia Lineal	R	Coefficiente de correlación
RMSE	Error cuadrático medio de la raíz	T	Temperatura [°C]
TANSIG	Función de transferencia Lineal	Vv	Velocidad del Viento[m/s]
Aa	Área de Apertura [m ²]	F	Función de Activación
aJ	Salida de la capa oculta	f	Longitud Focal[m]
b1(s)	bias obtenidas en las neuronas de la capa oculta.	Fw	Flujo Volumétrico [l/min]
b2(l)	bias obtenidas en las neuronas de la capa de salida	Gb	Radiación Solar [W/m ²]
C	Concentración ($C = Aa / Ar$)	BPNN	Red Neuronal tipo Back-Propagation

CAPITULO I

1.1.- Introducción

La optimización es una herramienta importante en la ciencia utilizada en el análisis de sistemas físicos experimentales. Para usar esta herramienta primero debemos identificar cual es el objetivo, es decir tener una medida cuantitativa del desempeño del sistema que se está estudiando. Este objetivo puede ser la ganancia, el tiempo, la energía potencial o cualquier cantidad o combinación de cantidades que pueda representarse con un solo número.

El objetivo depende características propias del sistema llamadas variables o incógnitas. Nuestra meta es encontrar los valores de estas variables con las que se lleva a cabo la optimización de la función objetivo. Con cierta frecuencia, las variables están restringidas de alguna manera. Por ejemplo, cantidades como la densidad de electrones en una molécula y la tasa de interés de un préstamo no pueden ser negativas.

El proceso de identificar el objetivo, las variables y las restricciones de un problema dado, se conoce como modelado. Este es quizás la fase más importante dentro del proceso de optimización, esta fase consiste en la construcción del modelo apropiado. Si el modelo es demasiado simple, este no proporcionará información útil sobre el sistema físico. Por el contrario, un modelo de una complejidad alta puede ser excesivamente difícil de resolver.

Una vez que se el modelo ha sido obtenido, se puede usar un algoritmo de optimización para encontrar su solución. No existe un algoritmo de optimización único o universal, sin embargo, lo que, si existe en una larga colección de algoritmos, cada uno de los cuales se adapta particularmente a un tipo de problema específico de optimización. La importancia de elegir el algoritmo apropiado para una aplicación específica, ya que, a partir de esta elección, el problema puede resolverse en un tiempo óptimo, además debe tenerse en cuenta la precisión de la solución alcanzada.

Una vez que se ha aplicado el algoritmo de optimización al modelo, debemos confirmar si el algoritmo tiene la capacidad de encontrar una solución óptima mediante la realización de pruebas estadísticas. En la mayoría de los casos de estudio se tienen restricciones de optimización, estas restricciones deben ser verificadas contra el conjunto de variables simuladas, buscando que sea la solución del problema. Si estas condiciones de optimización no son alcanzadas, estas mismas brindan información útil sobre el cómo puede mejorarse la simulación o estimación actual de la solución obtenida. El modelo obtenido es susceptible de ser mejorado al aplicar técnicas como el análisis de sensibilidad de las variables, en el que se identifica el grado de influencia que presentan las variables sobre la solución simulada o estimada en función a los cambios efectuados entre el modelo y los datos. Por otro lado, la interpretación de la solución simulada o estimada, en términos de su efectiva aplicación también puede sugerir algunas formas alternativas en las que el modelo puede mejorarse o corregirse. De esta manera al realizar cambios en el modelo, o ajustes en el algoritmo de optimización, se reinicia el proceso solución este proceso se repite hasta

cumplir con las condiciones previamente establecidas o alcanzar el valor óptimo de la simulación o estimación.

La optimización expresada de forma matemática la podemos ver si queremos minimizar o maximizar una función objetivo, a esta función aplican las restricciones, para esto podemos seguir la notación mostrada a continuación

x Representa vector de variables, desconocidas

f Representa la función objetivo

c_i Representa las restricciones de la ecuación.

Con base a esta notación un ejemplo de una función objetivo sería como la descrita en:

$$\max_{x \in \mathbb{R}^n} f(x) \quad \text{Esta ecuación está sujeta a las siguientes restricciones} \quad \begin{cases} C_i = 0 \\ C_i \neq 0, \end{cases} \quad (1)$$

Tipos de variables, en la optimización

Para diversos problemas de optimización, la naturaleza de las variables hace una diferencia al momento de llevar a cabo la optimización. Es decir, una variable x_i puede representar la cantidad de equipos de cómputo del modelo i que deben ser ensambladas durante los próximos 6 años, o podría indicar si una fábrica en particular debe ubicarse o no en una ciudad en particular. Para la formulación matemática de un problema como este, el cual incluye restricciones, que tienen la forma $x_i \in Z$, donde Z representa el conjunto de números enteros, o el de las restricciones binarias, que tienen la forma $x_i \in \{0, 1\}$, Para los problemas de este tipo se denominan problemas de programación entera.

Dentro de los problemas de programación entera contempla dos tipos de problemas de optimización. Los problemas de optimización continua normalmente son más fáciles de resolver porque la suavidad de las funciones hace posible usar información objetiva y de restricciones en un punto x particular para deducir información sobre el comportamiento de la función en todos los puntos cercanos a x . En problemas discretos, por el contrario, el comportamiento del objetivo y las restricciones pueden cambiar significativamente a medida que nos movemos de un punto factible a otro, incluso si los dos puntos están "cerca" en alguna medida.

1.2.- Optimización con restricciones y sin restricciones

De manera general los problemas que se ajustan a la forma de la ecuación (1), pueden ser categorizadas en función a la naturaleza de la función objetivo y a sus restricciones como lineal, no lineal o convexa, por el número de variables en grandes o pequeñas, y por la suavidad de las funciones en diferenciables o no diferenciables. Y de forma importante las funciones que tienen restricciones sobre las variables y los que no.

Los problemas de optimización sin restricciones, para los cuales tenemos $E = I = \emptyset$, aparecen de forma directa en múltiples aplicaciones físicas. Los problemas sin restricciones son prácticamente reformulaciones sobre los problemas de optimización con restricciones, en donde las restricciones son reemplazadas por términos de penalización incorporados a la función objetivo con lo que se busca limitar el área de soluciones posibles para la función objetivo.

Aquí I y E son conjuntos de índices para restricciones de igualdad y desigualdad, respectivamente. Como un ejemplo simple, considere el problema

Por otro lado, los problemas de optimización con restricciones aparecen en modelos sobre los que las restricciones tienen un rol particular, tal como se hace al imponer límites o restricciones en un problema de diseño arquitectónico o en el diseño de un aero - generador. Estos límites o restricciones pueden ser tan sencillo como $1000 \text{ rpm} \leq x_i \leq 9000 \text{ rpm}$, restricciones lineales más generales como $x_i \leq 90^\circ\text{C}$ o desigualdades no lineales que representan relaciones complejas entre las variables.

Tomando como base lo anterior cuando una función objetivo y sus restricciones son funciones lineales de x , este problema se clasifica como un problema de programación lineal. Para este tipo de problemas son los más ampliamente expresados y resueltos de todos los problemas de optimización, en diferentes áreas de aplicación particulares como las económicas administrativas. En contra parte los problemas de programación no lineal, en los que al menos algunas de las restricciones o el objetivo son funciones no lineales, tienden a surgir de forma natural en las ciencias físicas y la ingeniería.

1.3.- Optimización global y local

Muchos de los algoritmos diseñados para solucionar problemas de optimización no lineal buscan solo una solución local, un punto en el que la solución de la función objetivo es más pequeña que en todos los demás puntos cercanos posibles. Por lo tanto, no siempre se encuentran una solución global, este es el punto con el valor de la función objetivo más bajo entre todos sus puntos posibles. Se necesitan soluciones globales en algunas aplicaciones, pero para muchos problemas son difíciles de reconocer y aún más difíciles de localizar.

1.4.- Optimización estocástica y determinista

En algunos de los problemas de optimización, en la fase de generación del modelo se tienen algunas limitantes debido a que la generación de modelo depende de cantidades

desconocidas en esa fase. Esta característica es compartida por muchos modelos de planificación económica y financiera, ya que pueden depender, entre otras cosas de los porcentajes de los futuros, por la demanda a futuro de un servicio de o los costos en el futuro de las materias primas en la producción.

Con la finalidad de solucionar esta limitante generalmente se establece un valor inicial con el que se podrá generar el modelo del problema estudiado, Sin embargo, los modeladores pueden obtener soluciones más útiles al incorporar conocimientos adicionales sobre estas cantidades en el modelo En lugar de simplemente usar un valor inicial para las cantidades desconocidas.

De esta manera, se pueden conocer varios escenarios para la o las variables desconocidas, en conjunto con las estimaciones de las probabilidades para cada escenario. Los algoritmos de optimización estocástica utilizan estas cuantificaciones de la incertidumbre para producir las soluciones que optimicen el rendimiento esperado del modelo.

Los paradigmas utilizados para tratar con datos inciertos en el modelo incluyen la optimización con restricciones de probabilidad, en la que nos aseguramos de que las variables x satisfagan las restricciones dadas para alguna probabilidad específica, y la optimización robusta, en la que se imponen ciertas restricciones. requerido para mantener todos los valores posibles de los datos inciertos.

1.5.- Algoritmos de optimización

Los algoritmos de optimización son iterativos o recursivos lo que quiere decir que dan cierto número de ciclos antes de llegar a la solución. Estos dan inicio asumiendo un valor inicial de la variable dependiente x con lo que se genera una secuencia de valores que mejoran con cada ciclo o interacción hasta que terminan, con suerte en una solución.

Cada algoritmo se distingue por utilizar una estrategia específica con la que pasa de una iteración a la siguiente. En general algunas de estas estrategias pueden usar los valores de la función objetivo f , o las restricciones c_i o en su caso las primera y segunda derivada de la función. Algunos algoritmos acumulan información recopilada en iteraciones anteriores, mientras que otros usan solo información local obtenida en el punto actual. De lo antes mencionado podemos definir que los buenos algoritmos deben poseer las siguientes propiedades:

- Robustez. Debe tener un desempeño bueno al aplicarse en una gran variedad de problemas de la misma clase.
- Eficiencia. El tiempo de computadora al que llamaremos costo computacional no debe ser excesivo.
- Precisión. Debe poder obtener una solución con una precisión alta.

Estas características no siempre se cumplen al mismo tiempo, por lo que pueden caer en conflicto. Es decir, un método que convergente de forma rápida para un gran problema no lineal sin restricciones puede requerir demasiado almacenamiento en la computadora. Por el

contrario, un método más robusto puede ser el más lento para converger a una solución posible.

1.6.- Planteamiento del problema

La complejidad de muchos de los procesos industriales en los que se aplica la ingeniería, así como sus diversas aplicaciones en diferentes campos de la ciencia y en particular en el campo de la optimización de sistemas no lineales, es necesario el uso de modelado funciones que permitan aproximar a sus respectivas soluciones, estas por ser demasiado difíciles de evaluar mediante métodos matemáticos clásicos, específicamente cuando se tienen múltiples variables.

Para estos casos es posible la creación del modelo, por medio de alguna de las múltiples herramientas de aprendizaje máquina, un ejemplo son las redes neuronales, estos facilitan, el proceso de solución de la función multivariable. En la actualidad la aplicación de redes neuronales es muy extendida.

El objetivo principal de esta tesis es demostrar que las redes neuronales pueden ser utilizadas como herramientas de predicción confiables y sobre todo como una herramienta de optimización, por ejemplo, en problemas de ingeniería térmica, química y ambiental.

Generalmente en los trabajos de optimización, el fenómeno a estudiar cuenta con una gran cantidad de variables. Esta gran cantidad de variables plantea una situación en la que se debe tomarse como multidimensionalidad esto dificulta el modelado y la optimización, de la misma forma el hardware utilizado, planteando un costo computacional y temporal alto.

La primera evaluación con la metodología de ANNi – metaheurística es la optimización multivariable de un transformador térmico por adsorción. La optimización de un transformador térmico es de interés ya que este dispositivo utiliza una reacción exotérmica para incrementar la temperatura de salida utilizando una temperatura de entrada baja. La segunda evaluación se realiza a un colector solar de canal parabólico de tubo concéntrico, con una baja temperatura de entrada a un flujo específico. Por último, se aplica a un reactor químico de degradación de contaminantes, específicamente herbicidas disueltos en una solución acuosa, en este reactor se aplica ultrasonido y radiación UV entre otras variables. En estos sistemas se quiere optimizar múltiples variables a un mismo tiempo con la intención de mejorar la eficiencia caracterizada en la fase experimental. Con la optimización de estos casos, se busca establecer que la técnica desarrollada es de una amplia la aplicación en diversos campos de estudio.

1.7.- Alcance del trabajo

1.7.1.- Objetivo general

1. Analizar el comportamiento del método de optimización multivariable a una red neuronal artificial inversa, aplicando un algoritmo metaheurístico, para obtener los valores óptimos de las variables.

1.7.2.- Objetivos específicos

1. Mostrar el estado del arte que se muestra en la bibliografía en referencia a las redes neuronales como una herramienta eficiente de predicción, así como sus ventajas en comparación a otros métodos.
2. Estudiar la repercusión en la optimización, mediante múltiples variables predictores en diferentes sistemas físicos experimentales.
3. Esta aplicación de red neuronal se desarrolló con la finalidad de obtener los valores óptimos de múltiples variables con alguno de las siguientes metas:
 - a. Aumentar el índice de eficiencia en un transformador térmico (COP)
 - b. Incrementar la eficiencia térmica de un colector solar parabólico
 - c. Disminuir la necesidad química de oxígeno (COD), y el tiempo de degradación de contaminantes (herbicidas), en la operación de un reactor químico en medio acuoso.

Discutir sobre las ventajas de optimizar experimentos de diferentes naturalezas optimizando una función multivariable aplicando algún algoritmo metaheurístico con múltiples variables.

1.8.- Energías renovables

El crecimiento de la economía a nivel global con base al desarrollo tecnológico tiene relacionado directamente el incremento en la necesidad de energía con la que se sostiene el nivel de crecimiento actual y futuro. Históricamente la fuente de energía que ha proveído a la industria han sido las energías de orígenes fósiles, por lo que a partir de la industrialización de la industria en el siglo XIX con la creación de máquinas cuyo funcionamiento se basa en la generación energía mecánica a partir de la transformación de energía química. A partir de este momento, el incremento en la generación de contaminación se ha ido acumulando a lo largo de los años llegando a producir en este punto un cambio en la temperatura promedio a nivel global de la atmosfera y en consecuencia de los océanos, este calentamiento presenta un reto a gobiernos, especialistas y científicos en campos como la tecnología ambiental y la ingeniería industrial, así como también en el análisis y optimización. El reto presenta una contradicción entre mantener el nivel de crecimiento en la industria y disminuir el ritmo en la generación de desechos contaminantes y que impactan en el equilibrio del medio ambiente.

Con la finalidad de alcanzar una solución de equilibrio, debe hacer un uso más fuerte de las fuentes de energía renovable, tales como la energía solar, energía eólica, energía hidroeléctrica, energía de biomasa y geotermia. De forma general las ventajas de estas fuentes de energía son: son renovables, no contaminantes al medio ambiente, se tiene generalmente en abundancia como la solar, en teoría se puede llegar a una eficiencia del 100% como en la energía eólica, sin embargo, lograr esa eficiencia teórica requiere de un trabajo de optimización de los sistemas físicos.

1.9.- Red Neuronal Artificial

El funcionamiento de una red neuronal artificial (RNA), se basa crear modelos matemáticos con lo que busca emular el funcionamiento del sistema nervioso central del ser humano, más específicamente el cerebro y las neuronas que lo forman. Este modelado, realiza una simplificación del sistema físico analizado, partir del modelo obtenido logra simular un valor de salida, esta salida se logra a partir del aprendizaje del comportamiento sistema físico.

Las redes neuronales artificiales tienen las siguientes características, procesamiento paralelo, distribuido y adaptativo. Sin embargo, la mayor capacidad de las RNA se enfoca en el procesamiento paralelo realizado por las neuronas artificiales. El elemento básico de las redes neuronales es la neurona, ya que es un elemento de procesamiento simple y constituye además el elemento principal. Las neuronas artificiales se estructuran en capas, estas capas forman una red neuronal artificial.

Esta estructura crea una tolerancia a fallos, debido a que la información de toda la red se distribuye en las sinapsis entre neuronas. Por consiguiente, las RNA cuentan con la capacidad modificar su funcionamiento al medio modificando las conexiones sinápticas de las neuronas. Con esto pueden aprender de la experiencia y generalizar conceptos.

Encontramos de acuerdo con su posición tres funciones de las neuronas artificiales:

1. Se encuentran en la capa de entrada y reciben los datos del exterior de la red
2. Se encuentran en la capa oculta o intermedia de la red y reciben información desde otras neuronas en esta capa se realiza la representación de la información almacenada.
3. Se encuentran en la capa de salida recibiendo los datos procesados y devuelven la información.

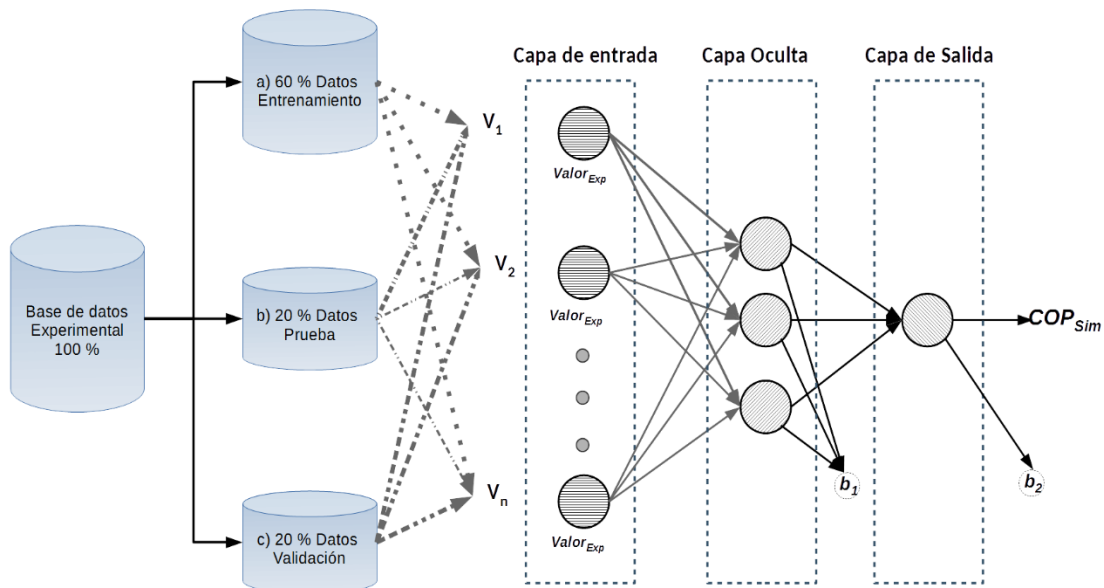


Figura 1 Modelo de entrenamiento de una RNA

Entonces podemos realizar una nomenclatura de la siguiente manera al grupo de entradas, $x_j(t)$, a los pesos de conexión entre capas (sinápticos), w_{ij} , el método de propagación de la señal entre las capas, $\sigma_i(w_{ij}, x_j(t))$, al método o función de activación de la neurona, $f_i(a_i(t-1), h_i(t))$ y por último la función de activación en la capa de salida, $F_i(a_i(t))$.

Por lo antes descrito podemos definir la salida para una neurona en un tiempo (t).

$$y(t) = F(f[a(t-1), (w, x(t))])$$

1.9.1.- Entrenamiento

El proceso de aprendizaje o entrenamiento se realiza a partir de un conjunto de datos experimentales generalmente históricos, a partir de los cuales aprende el comportamiento del sistema físico mediante el ajuste de los parámetros llamados pesos y bias, estos parámetros permitirán transpolar los datos experimentales de entrada a una salida, generalmente uno o más datos. Este proceso de entrenamiento o aprendizaje busca disminuir el error entre el dato experimental y el dato simulado:

Este entrenamiento se puede dar en formas diferentes tales como:

Aprendizaje supervisado, La fase de entrenamiento se realiza con un conjunto de patrones de entrada, junto con la salida esperada. Los pesos se van modificando de manera proporcional al error que se produce entre la salida real de la red y la salida esperada.

Aprendizaje no supervisado, Se presenta a la red un conjunto de patrones de entrada. No existen datos sobre los valores de la salida esperada. El proceso de entrenamiento en este caso debe ajustar sus pesos en base a la correlación existente entre los datos de entrada.

Aprendizaje por refuerzo, Este tipo de aprendizaje se ubica entre medio de los dos anteriores. Se le presenta a la red un conjunto de patrones de entrada y se le indica a la red si la salida obtenida es o no correcta. Sin embargo, no se le proporciona el valor de la salida esperada. Este tipo de aprendizaje es muy útil en aquellos casos en que se desconoce cuál es la salida exacta que debe proporcionar la red.

1.9.2.- Red Neuronal Artificial inversa

En la Fig. 2 se muestra una red neuronal general que está constituida por tangente hiperbólica (\tanh) o función sigmoidea (tansig) en la capa oculta y funciones de transferencia lineales en la capa de salida.

Es muy importante remarcar que en el caso de que sólo una neurona se ha considerado en la capa oculta de un modelo ANN; es posible obtener la respuesta inversa con una solución analítica a dos casos:

En la Fig. 2 se muestra una red neuronal general que está constituida por tangente hiperbólica (tanh) o función sigmoidea (tansig) en la capa oculta y funciones de transferencia lineales en la capa de salida. Entonces, la salida está dada por,

Si se utiliza la definición de las funciones purelin y tansig, y viene dada por, $\{k \frac{1}{4} 2\}$

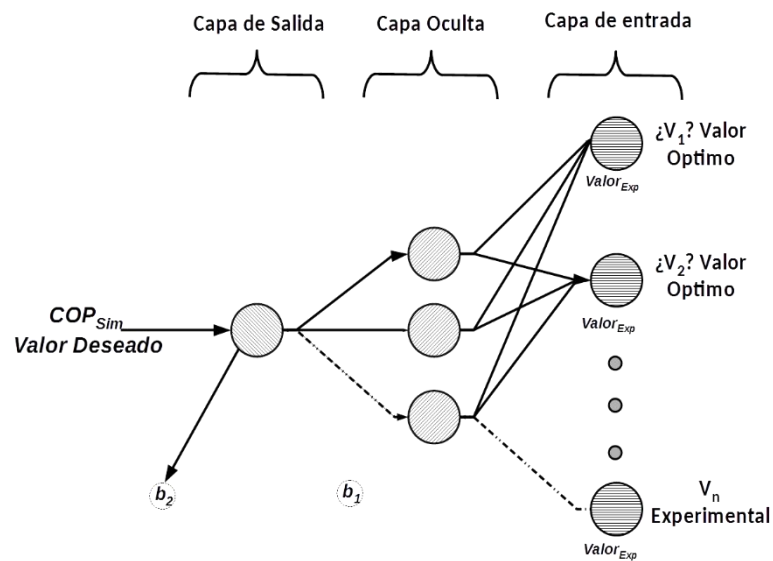


Figura 2 Red neuronal artificial inversa

1.10.- Algoritmos Genéticos

Algoritmos genéticos, se inspiran en la evolución de las especies y son un conjunto de algoritmos computacionales. Estos codifican una posible solución para un problema específico en una estructura de datos de forma individual, esta solución se asemeja a un cromosoma biológico en el que se aplican los métodos genómicos, como el cruce, la mutación y la selección entre las generaciones, este ciclo generacional tiene la característica de conservar la información de la generación inicial como una posible solución en las generaciones sucesivas. El diagrama de flujo se muestra en la figura 3

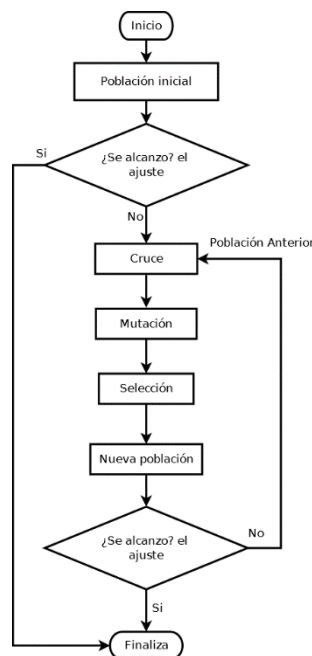


Figura 3 Diagrama de Flujo Algoritmos Genéticos

1.11.- Enjambre de Partículas

Optimización por enjambre de partículas (Particle Swarm Optimization, PSO) es un algoritmo de inteligencia de enjambre basado en la población propuesto por Kennedy y Eberhart en 1995. Este algoritmo, se basa en simular el comportamiento social de algunos organismos biológicos tales como bandadas de aves y cardúmenes de peces utilizando movimientos físicos de los individuos en un enjambre. Los individuos evolucionan por cooperación y competencia entre ellos con la finalidad de encontrar una solución al problema de optimización. Para esto cada partícula ajusta su trayectoria de vuelo en función

a su experiencia individual y de la experiencia de vuelo de la población en general. El algoritmo de PSO se muestra en la figura 4.

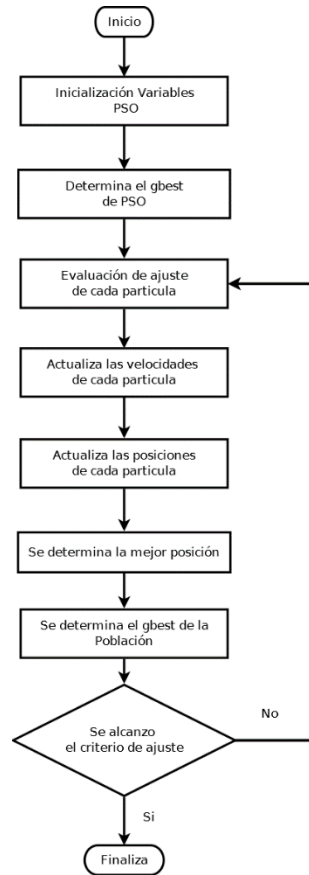


Figura 4 Diagrama de Flujo de PSO

1.12.- Recosido Simulado

El recocido simulado, es una heurística para la optimización global aproximada en el espacio de búsqueda. Fue introducido en 1982 para permitir la aproximación al óptimo global de una función objetivo.

Aquí, la función objetivo es estática y se puede maximizar o minimizar fácilmente usando este algoritmo. La formulación de SA permite en circunstancias específicas, movimientos que empeoran la solución, lo cual depende de una probabilidad calculada. Además, considera varios estados vecinos del estado actual y decide probabilísticamente entre mover el sistema al estado vecino o permanecer en el estado actual. Este paso se repite hasta que el sistema alcanza un estado que resuelve el problema, o hasta que se ha terminado un

presupuesto de cómputo dado. El pseudocódigo para el modelo ANNi (ANNi-SA) se resume en la figura 5.

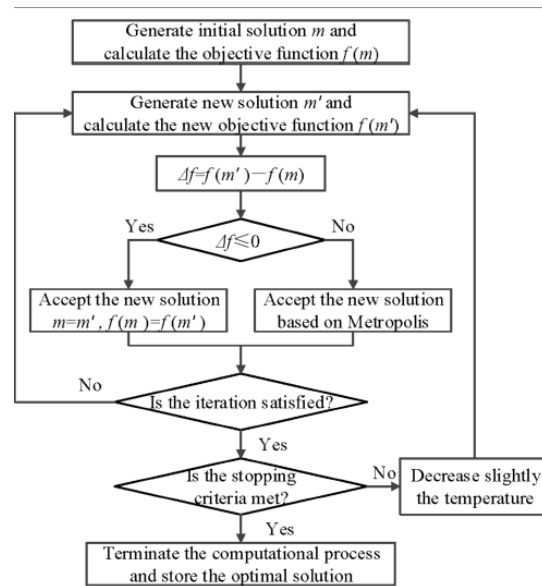


Figura 5 Diagrama de flujo de recocido simulado

1.13.- Búsqueda Cukoo

Búsqueda Cuckoo es un algoritmo metaheurístico inspirado en la naturaleza desarrollado por Xin-She Yang en 2009. Se basó en el parasitismo de algunas especies de cucos mediante vuelos de Lévy en lugar de paseos aleatorios.

La característica principal de este algoritmo es que la similitud entre los huevos produce mejores soluciones, es decir, la mutación realizada por los vuelos de Lévy y las soluciones basadas en la similitud proporciona una forma sutil de cruce. El algoritmo de CS aplicado al modelo ANNi (ANNi-CS) se resume en la figura 6.

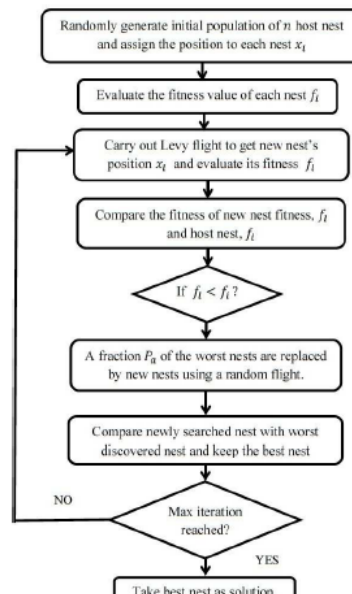


Figura 6 Diagrama de flujo de la Búsqueda Cukoo

CAPITULO II Estado del arte

En la administración y gestión de las tecnologías que tienen como base, las fuentes de energía renovables pueden aplicarse metodologías de optimización que permitan dar un alto grado de confianza en el suministro de energía. Actualmente, existen diversos trabajos basados en soft computing y machine learning como herramientas de optimización de funciones objetivo multivariables y con restricciones de los sistemas físicos. A partir de una revisión en la literatura, se encuentra que existen pocos trabajos de investigación cuyo enfoque sea realizar la aplicación de algoritmos de optimización.

En este trabajo, se han aplicado algoritmos inteligentes ampliamente utilizados que se han utilizado para abordar la optimización de tres diferentes sistemas físicos. Entre estos algoritmos se encuentran, algoritmos genéticos (AG), algoritmo de optimización de enjambre de partículas (PSO), Búsqueda Cuckoo (BC), Recosido Simulado (RS).

Entre los trabajos relacionados con (AG), encontramos la optimización de un sistema fotovoltaico en el cual intervienen las siguientes variables con las que se determina el tamaño óptimo de construcción, estas variables son: energía solar fotovoltaica (FV), tipo de baterías (TB), tipo de microturbina (TMT), cantidad de paneles instalados (NPV), número de baterías (NB), número de microturbinas (NMT) y el ángulo de inclinación (beta), la función objetivo es minimizar el costo de generación por 1 kWh. De estas variables los investigadores encontraron que al encontrar los valores óptimos de los ángulos de inclinación y azimut con los siguientes valores 38° y 16° respectivamente.

El algoritmo de optimización por enjambre de partículas (PSO) se aplicó en la generación de energía en un sistema de aerogeneradores optimizando las variables costo nivelado de energía (LCE €/kW), CRF: Factor de Recuperación de Capital (CRF %), ICC: Coste de Capital Instalado (ICC €/kW), AOE: Gastos Operativos Anuales (€/kW/año), Producción neta anual de energía (AEP kW) de con el objetivo de minimizar el costo de generación por kW. Como resultado de aplicar el algoritmo de optimización (PSO), fue que el LCE mínimo se encuentra en 0,0030277 €/kW y la potencia generada por el aerogenerador es de 1,0185 kW.

El recosido simulado (RS) para optimizar una planta de energía geotérmica binaria (GPP), logrando aumentar la tasa de energía del vaporizador en un 8%, a 2.456 MW. Los parámetros iniciales son los siguientes; temperatura inicial (T_{start}). Temperatura final (T_{final}) factor alfa 0.95, distancia del vecindario 0.05, a partir de estos parámetros Logrando aumentar la eficiencia del sistema en 14,48 %, el algoritmo SA, a excepción del número de iteración 300, alcanzó una eficiencia máxima de aproximadamente 33 % en las primeras tres iteraciones.

La búsqueda Cuckoo se ha aplicado es la predicción de radiación solar mediante la construcción de un modelo para determinar los coeficientes para pronosticar la radiación solar. Los parámetros iniciales fueron, número de nidos 30, el factor de probabilidad de es de 2, número máximo de iteraciones 500 y un error esperado de 0.0001. El modelo de CS obtiene el menor MRE, mostrando los mejores resultados de pronóstico en cuatro días.

Por otro las ANN han sido utilizadas en diversos trabajos de investigación en el modelado y la predicción dentro del campo de sistemas de energía renovable. Algunos ejemplos son los que se presentan aquí.

Una ANN ha sido entrenada para modelar la puesta en marcha de un generador de vapor solar. Para este caso en particular importante el diseño que tenga la capacidad de hacer tales predicciones ya que la energía usada en el arranque por la mañana tiene un efecto profundo en el rendimiento del sistema. Este problema es muy difícil de manejar con métodos analíticos ya que el sistema trabaja en condiciones transitorias. A partir de este punto las ANN podrían predecir el perfil de las temperaturas generadas, con una precisión del 3,9 %, lo que se considera adecuado para fines de diseño. El entrenamiento de la red con valores de rendimiento para una serie de tamaños de colectores que van desde 3,5 a 2160 m² pudo hacer predicciones tanto dentro como fuera del rango de entrenamiento. Una red neuronal pudo predecir la producción de vapor promedio mensual promedio del sistema con una diferencia máxima limitada a menos del 5.1% en comparación con los valores simulados, lo que se considera aceptable. La coincidencia de los valores previstos y reales en cada caso es excelente.

Las ANN, también se han aplicado en la estimación y pronóstico del consumo óptimo de diversas energías renovables. En el estudio se realiza el entrenamiento de una ANN con datos de 11 años correspondientes del área de Iran obteniendo una precisión en la simulación de 99.9 %, Las variables que se toman para el entrenamiento son X_1 (dióxido de carbono), X_2 (monóxido de carbono), X_3 (óxido de nitrógeno), X_4 (precio de la gasolina), X_5 (precio del petróleo), X_6 (PIB), Y_{t-1} (variable retrasada) con lo que se simula la cantidad del consumo de energía renovable Y_t , Los investigadores utilizan cuatro métodos básicos de estimación del error de simulación, el error absoluto medio (MAE), error cuadrático medio (MSE), error cuadrático medio (RMSE) y error porcentual absoluto medio (MAPE). Obteniendo el mejor resultado con un MAPE de 0.0034%.

De igual forma se han aplicado en la predicción de dos diferentes fuentes de energía renovable, de manera altamente efectiva, en lugares diferentes. Usando una base de datos viento. Esta base cuenta con la información de dirección del viento, velocidad del viento, temperatura del aire, presión del aire en la superficie y densidad del aire, estas consideradas variables de entrada, y la variable a simular, la potencia. También cuentan con datos de un sistema solar fotovoltaico. El ángulo de inclinación, la temperatura de la superficie y la temperatura ambiente se toman como variables de entrada, mientras que la potencia de salida de la planta se consideró como variable de a simular. Los autores también aplican metaheurísticas con la finalidad de resolver las funciones objetivo de ambas bases de datos entre los que destacan, optimización avanzada de enjambres de partículas (APSO) y

algoritmo metaheurístico de ajuste fino (FTMA) obteniendo los mejores resultados para el sistema fotovoltaico, FTMA obtuvo un MSE 0.0207, MAE 0.1034, y para el aerogenerador, FTMA se obtuvo 0.9863, MAE 0.1005.

La aplicación de esta metodología en la optimización multivariable con la finalidad de disminuir el uso de energía en diversos procesos industriales como por ejemplo en un transformador térmico en donde se busca maximizar el índice de coeficiente de eficiencia, este índice se encuentra en función de la energía suministrada y la energía resultante para esto los investigadores usaron una base de datos con 8500 registros de la operación de un transformador térmico con reciclado de calor tomando en consideración, 16 variables de entrada en el entrenamiento, 10 de esas son temperaturas de entrada y salida, 4 son concentraciones, por ultimo 2 variables de presión interna al sistema, todas estas se encuentran en los diferentes dispositivos que componen el transformador térmico. Los investigadores logran maximizar el COP mediante la optimización de tres variables, la temperatura del Condensador (T_{CO}) la temperatura del generador (T_{GE}) y la temperatura del evaporador (T_{EV}), logrando incrementar el COP de 0.34 a 0.38, esta optimización se realiza con la aplicación de la metaheurística de algoritmos genéticos.

CAPITULO III Descripción de las diferentes opciones experimentales de optimización en energía renovable y degradación de contaminantes

3.1.- Transformador Térmico

El transformador térmico por absorción se compone de cuatro dispositivos básicos un generador, un condensador, un evaporador y un absorbedor que trabajan mediante el flujo de una solución de trabajo cuya composición puede variar, pero generalmente es de BrLi – H₂O. El objetivo principal del transformador térmico es reciclar calor considerado de desecho y que se puede encontrar entre los 60 y 90 °C, e incrementar su utilidad hasta los 100 – 140 °C, esta relación entre el calor de desecho y el calor resultante se conoce como el coeficiente de operación COP y la podemos representar mediante la ecuación $COP = Q_{AB}/Q_{GE} + Q_{EV}$, en la figura 7 se muestra de manera gráfica la operación de un transformador térmico.




Figura 7 Diagrama del transformador térmico

El ciclo de operación del transformador térmico inicia en el generador separando la solución de trabajo en concentrado y fluido refrigerante este llega al condensador en fase de vapor, condensándose ya en su fase líquida pasa al absorbedor en donde se lleva a cabo la reacción exotérmica generando una gran cantidad de energía en forma de calor. Como podemos ver el diseño de este dispositivo lleva un alto número de variables, en total 16 son las variables que intervienen en la operación, sus intervalos de operación son mostrados en la tabla 1

Tabla 1 Variables y límites de operación del Transformador Térmico

# Variable	Temperaturas	Intervalo de Operación	
		Inferior	Superior
1	T _{entrada.GE-AB}	71.84	91.61
2	T _{entrada.EV-AB}	69.34	89.93
3	T _{salida.AB-GE}	74.46	98.27
4	T _{entrada.AB-GE}	73.27	92.15
5	T _{salida.GE-AB}	71.84	91.61
6	T _{salida.GE-CO}	72.04	83.89
7	T _{entrada.CO}	39.42	65.05
8	T _{salida.CO}	26.75	33.79
9	T _{entrada.EV}	28.52	81.34
10	T _{salida.EV -AB}	69.34	89.93
Concentraciones (%)			
11	X _{entrada.AB}	51.66	55.36
12	X _{salida.AB}	50.75	54.36
13	X _{entrada.GE}	50.75	54.36
14	X _{salida.GE}	53.16	56.07
Presión (in.Hg)			
15	P _{AB}	7	11.5
16	P _{GE}	20	21.1

A partir de la operación del transformador térmico, son obtenidos los datos de las 16 variables con las que posteriormente será entrenada la red neuronal artificial. Esta base de datos está compuesta por un total de 4702 registros del comportamiento experimental del sistema físico.

3.2.- Colector solar de canal parabólico

El colector solar tiene la capacidad de absorber la energía radiante del sol y transformarla en un flujo de trabajo con energía química, este flujo de trabajo puede ser usado en diversas aplicaciones. Existen diferentes tipos de colectores solares entre estos se encuentran los colectores solares de cilindro parabólico PTC, este tipo de colector tiene la característica de alcanzar un intervalo de 350 a 140° C, por lo que puede ser utilizado como un generador de vapor en plantas de energía y en los procesos de desalinización.

El concepto inicial de un concentrador solar consistía en emplear una superficie semiesférica llena de múltiples espacios con espejos de tamaño pequeño. En esta configuración el punto focal de se ubicaría a la mitad de la sección esférica, exactamente sobre el vértice de la esfera. De esta forma la radiación solar se refleja hacia el punto focal, como en el caso de una parábola, un primer acercamiento fue realizado en 1870, con un PTC diseñado y construido por John Ericsson, este colector contaba con un área de apertura de 3,25 m para producir vapor e impulsar un motor de 373 W de potencia. Siguiendo esta idea una planta de energía generalmente requiere combustibles fósiles con la consecuente emisión de dióxido de carbono. Por esta razón es que maximizar la eficiencia de un PTC permite la disminución en el consumo de fósiles y la disminución de la contaminación.

La geometría del PTC al que se refiere este estudio se trata de un grupo de colectores instalados y operados en el instituto de energías renovables de la UNAM, con la siguiente geometría, cuanta con un tubo absorbedor de 2,54 cm (1 pulgada), hecho de material de cobre comercial. Venegas-Reyes reportó los detalles de diseño, construcción, eficiencia óptica y factor de intercepción para el PTC 45°, y Jaramillo publicó los correspondientes para el PTC de 90°. Con la finalidad de maximizar la incidencia de energía irradiada por el sol, el PTC se posiciono en el eje horizontal Este-Oeste con un ajuste en el plano Norte-Sur para minimizar el ángulo de incidencia. El sistema experimental completo se armó con 5 PTCs para proporcionar agua precalentada para la caracterización de los PTC y actuar como almacenamiento de calor al mismo tiempo. El sistema cuenta con un acumulador térmico de 120 l, sistema eléctrico de calentamiento de agua (con control automático de temperatura), y circuito hidráulico. Puede proporcionar agua caliente en un rango de temperatura desde ambiente hasta $90 \pm 1,0$ C. Inicialmente en el inicio del ciclo de operación, el agua fue calentada por resistencias eléctricas de 3 y 6 kW en el tanque de almacenamiento. La temperatura se regula por un sistema de control, cuya medición es un termopar ubicado en el tanque. A continuación, el fluido de trabajo ya precalentado alimenta al tubo receptor del PTC, mediante una bomba centrífuga de 1/2 hp, manteniendo un flujo constante regulado por válvulas. El caudal se controla mediante una válvula de aguja y se supervisa con el flujómetro de la serie que cuenta con una precisión de $\pm 0,1$ %. De igual manera se realizan mediciones de la temperatura y la presión a la salida del tanque de almacenamiento. El agua se recircula al tanque de almacenamiento para aumentar la tasa de calentamiento y obtener una temperatura más uniforme. Una vez alcanzada la temperatura deseada en el depósito térmico, se permite la entrada de agua a temperatura

ambiente en el depósito. El sistema está equipado con termopares tipo T que tienen una precisión de $\pm 0,5$, con un intervalo de operación de 0 a 120 °C calibrados para medir las temperaturas a la entrada y salida del PTC, de la misma forma la temperatura ambiente. También se instala un anemómetro para medir la velocidad y la dirección del viento, cuenta con una precisión de $\pm 0,5$ m/s. Y con la finalidad de medir la radiación solar se utilizó un pirheliómetro con una precisión de $\pm 2\%$. Las mediciones de temperatura, flujo y los demás parámetros mencionados anteriormente, incluida la fecha y la hora, se registraron utilizando una tarjeta de adquisición de datos Agilent Technologies 34970A (6½ dígitos) con tarjeta multiplexora HP34901A y un CPU. Se realizaron una serie de pruebas experimentales para seis caudales diferentes que van de 1 LPM hasta 6 LPM (litros por minuto) y diferentes temperaturas de entrada 27, 30, 50, 68, 70, 80 y 86 °C en mayo, diciembre y enero durante ocho días una hora al mediodía. La frecuencia de adquisición de datos fue cada 5 s. La tabla 2 muestra el rango de variables operativas experimentales de entrada y salida.

Tabla 2 Variables y límites de operación del Colector Solar Parabólico

Variable Experimental	Intervalo de trabajo	Unidad de medición
Entrada		
Angulo de apertura	45 – 90	°
Temperatura de entrada	27.75 – 86.29	°C
Temperatura ambiente	24.62 -36.60	°C
Flujo del Agua	0.69 – 6.19	[l/min]
Radiación Solar	653.80 – 1014.00	[W/m ²]
Velocidad del Viento	0.93 – 3.98	[m/s]
Salida		
Eficiencia Térmica	0.1728 – 0.7392	[-]

En la figura 8 se muestra un diagrama del sistema experimental, con el que se proporciona agua precalentada, con la finalidad de llevar a cabo la caracterización del PTC y además contar con un almacenamiento de calor a la vez, consistente en un acumulador térmico de 120 l, un sistema eléctrico de calentamiento de agua y un circuito hidráulico. Con esta configuración el PTC Puede suministrar agua caliente en un intervalo de temperatura iniciando a partir de temperatura ambiente hasta los 90 con más o menos un error de 1,0° C.

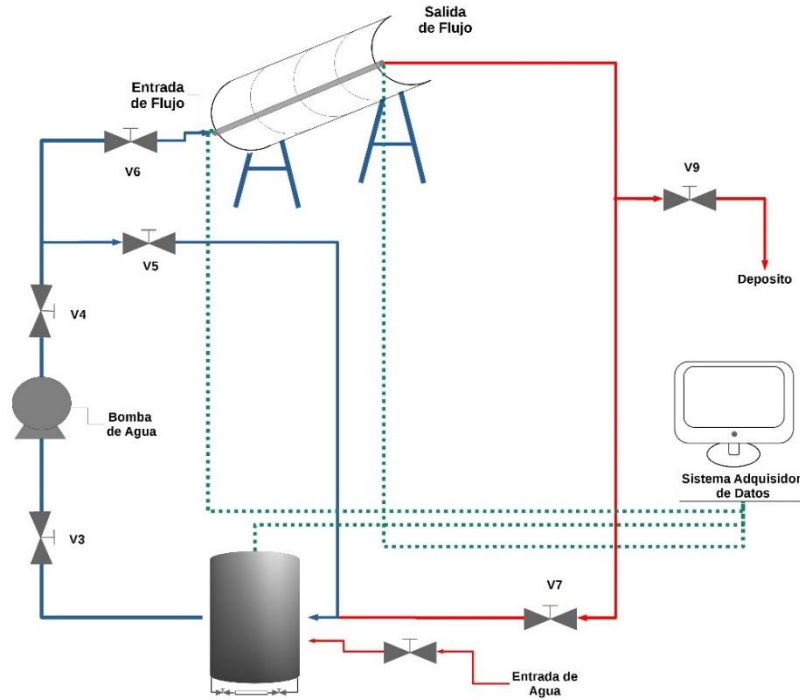


Figura 8 Diagrama experimental del Colector Solar Parabólico

Antes de iniciar el ciclo de operación, el agua contenida en el tanque de almacenamiento se precalentó con el uso de resistencias eléctricas de 3 y 6 kW. Posteriormente, el fluido de trabajo precalentado se alimenta al tubo receptor del PTC mediante una bomba centrífuga de 1/2 hp, manteniendo un flujo constante proporcionado por la regulación de las válvulas de corte. El caudal se controla mediante una válvula de aguja y se supervisa con el flujómetro de la serie HB2800 de Headland (con una precisión de $\pm 0,1 \%$). También se observan la temperatura y la presión a la salida del tanque de almacenamiento. El sistema está equipado con termopares tipo T (una precisión de $\pm 0,5 \text{ C}$ para un rango de operación de 0 a 120 C) adecuadamente calibrados para medir las temperaturas a la entrada y salida del PTC, así como la temperatura ambiente. También se instala un anemómetro para medir la velocidad del viento. (Sensor de velocidad y dirección del viento RM Young Wind Sentry. CS3001 con una precisión de $\pm 0,5 \text{ m/s}$). Para medir la radiación del haz solar se utilizó un pirheliómetro Eppley, NIP (con una precisión de $\pm 2\%$). Las mediciones de temperatura, flujo y otros parámetros mencionados anteriormente, incluida la fecha y la hora, se registraron utilizando una tarjeta de adquisición de datos Agilent Technologies 34970A (6½ dígitos) con tarjeta multiplexora HP34901A y una computadora personal. Se realizaron varias pruebas experimentales para seis caudales desde 1 LPM (litros por minuto) hasta 6 LPM y diferentes temperaturas de entrada (27, 30, 50, 68, 70, 80 y 86 C) en mayo, diciembre y enero durante ocho días una hora al mediodía. La frecuencia de adquisición de datos fue cada 5 s. La Tabla 2 muestra el rango de variables operativas experimentales de entrada y salida.

3.3.- Reactor de degradación por sonofotocatálisis

Para la agricultura, la aplicación de fertilizantes y plaguicidas han logrado mejorar la calidad en la producción de diferentes cultivos, con estos productos químicos se favorece el crecimiento vegetal y el control de las plagas. Si bien en un principio la aplicación de estos químicos logra un incremento en la producción en los campos de cultivo, su uso excesivo produciendo diferentes efectos negativos, provocando cambios significativos en la composición y reducción de especies específicas de flora, contaminación al ambiente urbano, toxicidad en mamíferos afectando los sistemas endocrino, reproductivo, neural, e hígado inmune, contaminación de aguas subterráneas, etc. Siguiendo con los efectos negativos mencionados, la contaminación de aguas subterráneas es uno de los más alarmantes. Esto se debe al impacto directo que se produce en la cadena alimentaria entre la flora y la fauna, así como la población que depende de ella. Por esto es que es necesario desatollar un método que permita la eliminación de los compuestos químicos derivados de estos herbicidas disueltos en el agua, con esta finalidad se lleva a cabo este trabajo de investigación en el que se incrementa la eficiencia de degradación de los contaminantes.

En este sistema experimental estudiado, se utilizan como contaminantes dos de los herbicidas generalmente más utilizados en la agricultura. Primeramente, la Alazina (30/18 LM), compuesta por Alachlor, Atrazine y agentes de formulación como principios activos. En segundo término, el Gesaprim (90 GDA) compuesto por atrazina y agentes formulantes. Los herbicidas se obtuvieron mediante compra directa con Syngenta Crop Protection Inc. (EE. UU.). Los compuestos puros de atrazina y alachloro eran de grado HPLC (99,9%) y se adquirieron de Sigma-Aldrich. TiO_2 (Degussa P25) y H_2SO_4 fueron grado analítico (Sigma-Aldrich). Los productos químicos se aplicaron tal como se compraron, sin purificación adicional. El agua destilada fue suministrada por la empresa Baxter México S.A.

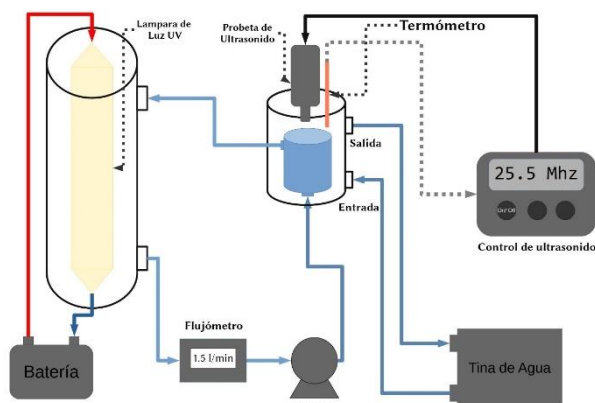


Figura 9 Diagrama experimental del Reactor Químico de degradación

Las pruebas experimentales de foto degradación se realizaron para cada uno de los herbicidas utilizando un reactor químico en el que se hace circular un volumen de 250 ml y un caudal de 5.63 l/min. Este reactor fotoquímico cuenta con una sonda ultrasónica de 500 W de potencia que trabaja en una frecuencia de 20 kHz, marca Cole Parmer, la temperatura también es controlada mediante la con recirculación de agua. El reactor usa una bomba centrífuga de flujo de polipropileno marca Cole Parmer además de una lámpara ultravioleta de 44 cm de largo y 3 cm de diámetro tiene 15 W de potencia y trabaja en el intervalo de los 352 nm. También se utiliza una celda de ultrasonido para suministrar un flujo de oxígeno en la muestra experimental como se muestra en la figura 9.

Tabla 3 Intervalos de operación del reactor químico

Nº	VARIABLES DE LA CAPA DE ENTRADA	ABREVIATURA	INTERVALO DE OPERACIÓN
1	Tiempo de reacción (min)	<i>Time</i>	0 – 480
2	pH	<i>pH</i>	1 – 5
3	Concentración Inicial del herbicida	<i>mM</i>	0.1540 – 0.3090
4	Contaminante	Contaminante	1 – 9
5	Ultrasonido (Khz)	<i>Us</i>	0 - 20
6	Radiación Ultravioleta (nm)	<i>Uv</i>	0 - 352
7	TiO ₂ (mg/L)	<i>TiO₂</i>	0 - 300
8	K ₂ SO ₄ (mM)	<i>K₂SO₄</i>	0 - 13
9	Radicación Solar (W/m ²)	<i>RS</i>	0 – 820

Las muestras experimentales se extrajeron a diferentes intervalos de tiempo de degradación para analizar la concentración de atrazina y alacloro mediante HPLC. Para el control de las pruebas experimentales fue necesario realizar muestreos, removiendo menos del 10% del volumen total y filtrando de acuerdo con lo recolectado antes del análisis. La demanda química de oxígeno (DQO) en el experimento, se determinó utilizando métodos y tubos estándar dentro del rango de concentración de 0–150 mg/l y 0–20 mg/l. En la tabla 1 se muestran los parámetros para las pruebas experimentales durante el proceso de degradación.

Por otro lado, el proceso de aprendizaje de una ANN es fundamental en el desarrollo del modelo ANN. Para llevar a cabo este proceso de manera efectiva, las variables de entrada (In_{exp}) fueron normalizadas (In_{Norm}) en un intervalo de [0.1-0.9] para facilitar la obtención de coeficientes, a través de la Ec. 5. En este trabajo los datos experimentales se dividieron en entrenamiento con 60%, prueba 20% y validación 20%. El ajuste de los coeficientes se realizó mediante un algoritmo de aprendizaje conocido como Backpropagation. Entre los algoritmos de Backpropagation más utilizados en los modelos de ANNs destaca el algoritmo de optimización de Levenberg-Marquardt y para establecer el número de neuronas óptimas en la capa oculta en procesos relacionados con la eliminación de la turbidez en el agua.

CAPITULO IV Descripción de la metodología de optimización multivariable (ANNi)

4.1.- Desarrollo de la Metodología de Optimización Multivariable

La metodología de optimización utilizada en diversos sistemas de ingeniería aplicada, que describiremos en este capítulo se realiza en diferentes fases.

La primera fase, se trata del entrenamiento de la red neuronal artificial (ANN) a partir de este entrenamiento se obtiene la mejor arquitectura de la red neuronal artificial. En esta fase la ANN obtiene un modelo que describe el comportamiento complejo del fenómeno que se estudia. El ajuste del modelo matemático obtenido se logra mediante el paso de los datos experimentales normalizados de forma recursiva a la red neuronal artificial hasta que encuentra los pesos y bias con los que se minimiza el error entre los datos experimentales y los datos simulados y una vez alcanzados los criterios de entrenamiento como son R^2 y MAPE.

El entrenamiento de la red neuronal artificial, está relacionado fuertemente con el número de neuronas que se encuentran en la capa oculta, mientras se tenga un mayor número de neuronas se tendrá un modelo más complejo, si por el contrario se tiene un número menor de neuronas en la capa oculta el modelo obtenido será menos complejo, en otras palabras, a un mayor número de neuronas en la capa oculta el rendimiento en la capacidad de predicción de la ANN y puede aumentar el tiempo de predicción sin olvidar que puede presentar el efecto de sobre ajuste. Al modelo resultante se le conoce como modelo del proceso o del fenómeno estudiado. En la figura 10 se muestra gráficamente como se lleva a cabo este proceso en los diferentes casos

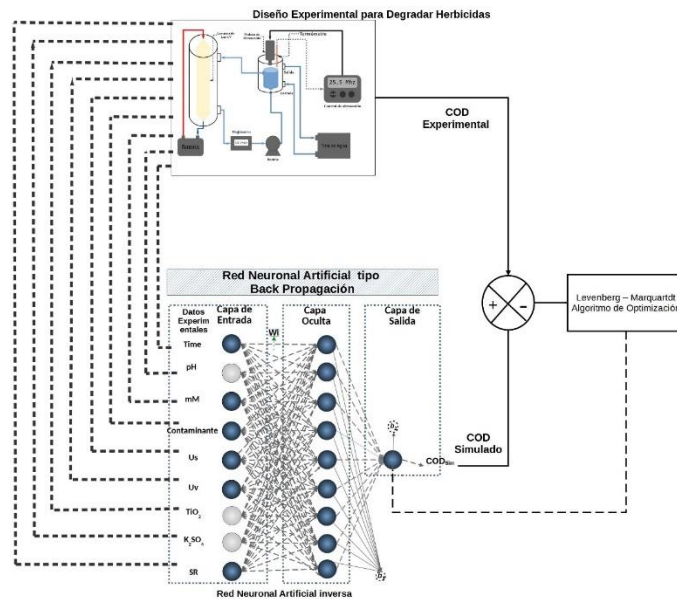


Figura 10 Entrenamiento Reactor Químico

Para la segunda fase, se toma el modelo matemático resultante del entrenamiento de la red neuronal artificial y se establece un valor requerido para la variable dependiente y que es un valor que mejora el proceso, para los casos en los que se aplicó esta metodología, puede tratarse del coeficiente de operación COP, la eficiencia de operación en el colector parabólico o la necesidad química de oxígeno COD.

Una vez que ya se ha fijado el valor de la variable dependiente, se toma un grupo de variables de entrada o variables independientes, a las que ahora se tomara como variables desconocidas, esto quiere decir que tenemos una función objetivo, que es la función inversa del modelo obtenido en el entrenamiento. El modelo resultante se denomina función objetivo esta función objetivo tienen restricciones propias descritas por el fenómeno experimental, estas restricciones pueden ser temperaturas máximas y mínimas, así como velocidades de flujo de líquidos, también niveles de concentración además de la medición de las presiones desarrolladas dentro del sistema estudiado.

En la tercera fase, consiste en solucionar la función objetivo, las funciones objetivo-desarrolladas en este trabajo son multivariantes y debido a su complejidad son altamente no lineales, por esta razón es que es necesario aplicar algún algoritmo que permita solucionar la función, dentro de estos algoritmos podemos utilizar alguna de las metaheurísticas descritas. Esta metaheurística encuentra los valores óptimos para el grupo de variables en el espacio de búsqueda definido por las restricciones, estos valores son evaluados dentro de la función objetivo y su resultado es medido obteniendo el error entre el valor requerido con anterioridad y el obtenido con los valores aportados por la metaheurística. Esta fase se

ejecuta de manera recursiva hasta que el error obtenido en la función objetivo sea mínimo de acuerdo con los criterios de ejecución y de paro del algoritmo.

En la valoración del error se han aplicado diversas métricas, como el Root Mean Squared Error RMSE y el Mean Absolute Percentage Error MAPE, ambas descritas por las ecuaciones 0 y 00

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_{Sim(i)} - P_{Exp(i)})^2}{n}} \quad (0)$$

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{x_{exp(i)} - y_{sim(i)}}{x_{exp(i)}} \right|}{n} \times 100 (\%) \quad (00)$$

Este algoritmo de optimización puede ser aplicado en diferentes áreas de ingeniería, entre las cuales destacamos el área térmica, la de energía renovable y la degradación de contaminantes, estos son los casos en los que se aplicó y cuyo desarrollo explicaremos en el siguiente capítulo.

4.2.- Transformador térmico por absorción incremento del rendimiento.

4.2.1.- Desarrollo

Retomando lo dicho en capítulos anteriores se cuenta una base de datos experimental de 4702 datos que representa el comportamiento físico experimental, en esta base también se tiene el coeficiente de rendimiento del AHTER, en donde se aplicara la metodología usando los 4 algoritmos de optimización, algoritmos genéticos, búsqueda Kuckoo, enjambre de partículas, y recosido simulado.

Las metodologías aplicadas ANNi-CS, ANNi-PSO, ANNi-AG y ANNi-RS son evaluadas considerando el promedio de los grupos de COP y sus desviaciones estándar. Considerando que este sistema físico cuenta con hasta 16 variables de entrada que son susceptibles de ser optimizadas mediante la función objetivo derivada del modelo obtenido en la fase de entrenamiento. Por esta razón es que se formaron grupos de variables, a los cuales se les analizo tomando en cuenta la media y sus respectivas desviaciones estándar. De las diferentes pruebas la que mejor desempeño obtiene es la realizada al aplicarse los algoritmos a 4 variables de entrada con un $COP_{Exp} = 0,31$, se utiliza el MAPE para determinar la precisión de los resultados obtenidos por la metodología. Como se puede ver en la Tabla 4.

4.2.2.- Resultados parciales

Tabla 4 Resultado de simulados contra experimentales de cuatro variables manipulables

*T_{Salida GE-AB}, *T_{Salida CO}, •T_{EV-AB} y ♦T_{AB-GE}, COP=0.31.

Algoritmo	Experimental	* Estimado	MAPE	Experimental	*Estimado	MAPE
CS	87.901	88.393	0.55987	31.066	31.343	0.89351
PSO	87.901	88.865	1.0966	31.066	31.341	0.8874
GA	87.901	88.127	0.25669	31.066	30.7	1.1792
SA	87.901	88.727	0.93905	31.066	30.734	1.0691

Algoritmo	Experimental	• Estimado	MAPE	Experimental	♦ Estimado	MAPE
CS	84.156	83.981	0.20854	94.503	94.029	0.501
PSO	84.156	84.943	0.93504	94.503	94.777	0.29062
GA	84.156	84.734	0.68646	94.503	94.29	0.22503
SA	84.156	83.259	1.066	94.503	94.155	0.36756

Los valores mostrados son utilizados con el objetivo de maximizar el COP lo cual se logra ya que en al aplicarse al grupo de datos experimentales con un $COP_{Exp} = 0.34$ se incrementa hasta llegar a $COP_{Deseado} = 0.40$, de esta prueba se deduce que los algoritmos que mayor exactitud son ANNi-CS y ANNi-RS,

Por último, al considerar la evaluación de las 4 metodologías aplicadas (ANNi - BC, ANNi-RS, ANNi-PSO y ANNi-AG), se puede confirmar que las 4 metodologías fueron precisas para determinar el COP en el AHTER. Además, para validar ANNi-CS y ANNi-SA con datos experimentales, la Fig. 10 muestra el COP experimental contrastado frente al COP simulado para ambos modelos ANNi, los coeficientes de regresión fueron superiores a 0,988.




Figura 11 Comparación del COP experimental contra el COP simulado

4.3.- Colector solar de canal parabólico, incremento del rendimiento

En este trabajo se aplicaron dos algoritmos metaheurísticos diferentes: algoritmos genéticos (GA) y optimización de enjambre de partículas (PSO), estos ya se describieron en el capítulo. Las funciones TANSIG y LOGSIG se evaluaron y compararon en el enfoque del modelo ANNi (6 neuronas de entrada, 4 neuronas en la capa oculta y 1 neurona de salida), ambas se programaron para ser resueltas por ambos algoritmos metaheurísticos.

4.3.1.- Desarrollo

La Tabla 4 y la Tabla 5 se muestran los errores y el tiempo de cómputo al realizar la optimización de una prueba aleatoria aplicando las funciones TANSIG y LOGSIG, respectivamente.

Tabla 5 TANSIG MAPE en el entrenamiento/

Datos Experimentales	ϕ_r [°]	T_{in} [°C]	T_{amb} [°C]	F_w [l/min]	G_b W/m ²	VV [m/s]	$\eta_{t,exp}$	MAPE (%error)	Tiempo de Computo (s)
	90	29.372	33.0659	6.1388	712.5	2.078	0.7088		
ANNim-GA									
1	90.00						0.7088	0.000	0.0360
2	90.00	27.7858					0.7122	2.7001	0.8690
3	90.00	33.3713	28.00				0.6674	9.6455	0.8634
4	90.00	20.9741	27.1591	5.2620			0.6236	15.1845	0.8366
5	86.83	22.7164	30.8748	1.1104	713.9143		0.7478	22.2792	1.8029
6	89.77	31.9733	33.6811	2.1095	603.0615	1.2280	0.7387	22.1030	1.6024
ANNim-PSO									
1	90						0.7088	0	3.0449
2	90	26.8900					0.7122	4.2251	5.2622
3	90	34.7459	35.0000				0.7085	6.3325	7.5660
4	90	27.76	35.000	6.00			0.7255	3.2798	9.8604
5	90	29.3477	35.00	5.9677	621.2399		0.7087	0.1069	13.0801
6	90	27.2884	33.3732	4.8597	702.3047	1.5322	0.7147	3.9605	14.3998

Tabla 6 LOGSIG MAPE en el entrenamiento

Datos Experimentales	ϕ_r [°]	T_{in} [°C]	T_{amb} [°C]	F_w [l/min]	G_b W/m ²	VV [m/s]	$\eta_{t,exp}$	MAPE (% error)	Tiempo de Computo (s)
	90	29.372	33.0659	6.1388		2.078	0.7088		
ANNim-GA									
1	90						0.6870	0.000	1.5999
2	90	29.000					0.6873	0.6332	1.0600
3	90	33.7383	22.00				0.6792	16.1105	0.7275

4	89	21.00	34.66	5.778			0.6769	10.0781	0.7395
5	90	35.1328	32.1103	4.0507	554		0.6825	15.7527	0.7548
6	90	44.6777	31.0196	6.7969	610	1.6152	0.6856	17.6129	0.7906
ANNim-PSO									
1	90						0.6870	0	2.9031
2	90	29.3100					0.6870	0.1055	5.1870
3	90	34.7459	35.0000				0.6715	8.0484	7.5660
4	90	24.000	24.000	4.3588			0.6870	18.675	9.8912
5	90	33.9027	30.7653	6.00	714.92		0.6870	4.9967	12.3263
6	90	24.000	25.600	6.000	646.34	2.4200	0.6842	11.4785	14.5639

Adicionalmente, se muestra la forma gradual de realizar la optimización, encontrando desde una variable hasta encontrar el total de las variables de entrada.

De acuerdo con los valores de respuesta obtenidos, se observó que la función TANSIG es mejor para el modelo ANNi. El error más pequeño al comparar el valor experimental y el valor obtenido por ANNim-PSO fue de 3,96%, con un tiempo de cálculo de 14,39 s. Por otro lado, aplicando ANNim-GA el error mínimo fue de 22.10% con un tiempo de cálculo de 1.60 s, logrando en ambos algoritmos de optimización la búsqueda de todas las variables de entrada del PTC. Por esta razón, se aplica la función TANSIG con PSO para mejorar la eficiencia térmica a través de tres pruebas experimentales. La Tabla 12 muestra las condiciones de tres pruebas experimentales seleccionadas al azar para utilizar la metodología ANNim-PSO.

Las variables de entrada a optimizar en los experimentos son ϕ y F. La elección de estas variables se debe a que el operador puede controlarlas. La optimización se realizó de manera gradual: encontrando una variable a la vez, dos variables al mismo tiempo y tres variables al mismo tiempo, para analizar qué combinación de variables permite aumentar la eficiencia térmica.

La Tabla 7 muestra la aplicación del modelo ANNim-PSO para las tres pruebas de datos experimentales mediante la optimización de tres variables a la vez.

En la prueba 1, el aumento más significativo de la eficiencia térmica (4,43 %) se produce en el segundo escenario al cambiar el ángulo de la llanta de 90° a $46,29^\circ$, aumentar la temperatura de entrada de $29,37^\circ\text{C}$ a $31,00^\circ\text{C}$ y disminuir el caudal volumétrico de agua de $6,13\text{ l/min}$ a $4,32\text{ l/min}$, simultáneamente.

En la prueba 2, al igual que en la prueba anterior, el aumento más significativo de la eficiencia térmica (18,96 %) se produce en el 2º escenario al cambiar el ángulo de la llanta de 90° a $45,97^\circ$, aumentando la temperatura de entrada de $51,86^\circ\text{C}$ a $86,00^\circ\text{C}$ y disminuir el caudal volumétrico de agua de $6,00\text{ l/min}$ a $5,89\text{ l/min}$, simultáneamente. En la prueba 3, el aumento más significativo de la eficiencia térmica (67,12 %) se produce en el 2º escenario utilizando un ángulo de llanta similar al experimental de 45° a $45,13^\circ$ de las pruebas anteriores, se debe disminuir la temperatura de entrada.

A diferencia de las pruebas anteriores, se debe disminuir la temperatura de entrada de 67,91 °C a 46,41 C y aumentar el caudal volumétrico de agua de 1,00 l/min a 4,06 l/min, simultáneamente.

Se observa que optimizando las tres variables simultáneamente se obtienen mejores resultados que optimizando una y dos variables simultáneamente.

Tabla 7 Optimización multivariables colector parabólico

Variable	Datos Experimentales	ANNim – PSO	
		T_{in}, Φ_r, F_w	Φ_r, T_{in}, F_w
	Prueba 1	Primero	Segundo
Φ_r	90.0000	46.2474	46.2969
T_{in} (°C)	29.3720	30.6556	31.0000
F_w (l/min)	6.1389	1.8538	4.3289
H_t	0.7086	0.7200	0.7400
Δ Eficiencia (%)	-	1.60	4.43
Tiempo de Computo (s)	-	76.1499	74.3913
	Prueba 2	Primero	Segundo
Φ_r	90.0000	45.6359	45.9778
T_{in} (°C)	51.8621	67.8306	86.0000
F_w (l/min)	6	5.1489	5.8985
H_t	0.5884	0.6000	0.7000
Δ Eficiencia (%)	-	1.97	18.96
Tiempo de Computo (s)	-	68.2928	71.4410
	Prueba 3	Primero	Segundo
Φ_r	45.0000	44.9088	45.1379
T_{in} (°C)	67.9173	47.5363	46.4193
F_w (l/min)	1		
H_t	0.3291	0.4500	0.5500
Δ Eficiencia (%)	-	36.73	67.12
Tiempo de Computo (s)	-	129.8209	129.7724

4.3.2.- Resultados parciales

Optimización multivariable realizada de forma gradual, encontrando valores óptimos para aumentar la eficiencia térmica.

Al optimizar una variable a la vez, el ángulo de la llanta impactó significativamente en el resultado deseado. Tanto es así que el cambio de 45° generó un aumento de la eficiencia térmica del 54,78% en el PTC.

Al optimizar dos variables simultáneamente se obtiene la menor eficiencia térmica del 36,73% que al optimizar una variable simultáneamente, coincidiendo en las tendencias de temperatura de entrada y caudal de agua para ambos escenarios de optimización.

Al optimizar tres variables simultáneamente se obtiene una eficiencia térmica del 67,12%, superior a la que se logra optimizando una y dos variables simultáneamente, manteniendo un ángulo de borde cercano a 45 y diferentes condiciones de temperatura-entrada del caudal volumétrico del agua.

4.4.- Reactor de degradación por sonofotocatalisis, disminución de la necesidad de oxígeno

Una vez realizado el entrenamiento en La figura 10 muestra un esquema del modelo ANN utilizando las variables experimentales obtenidas del proceso de sonofotocatálisis. Se desarrolló un modelo ANN tipo Feed – Forward aplicando una arquitectura con nueve neuronas en la capa oculta.

Durante la degradación de herbicidas comerciales, el proceso alcanzó un valor de DQO con un intervalo de [0.07-1], el cual fue simulado por el modelo ANN. De todas las combinaciones que se realizaron y de la comparación de diferentes funciones de transferencia y configuraciones de arquitectura empleadas por el modelo ANN para determinar la cantidad de neuronas óptimas. Se encontró un mejor desempeño de la arquitectura 09 – 9 – 1 con 9 neuronas en la capa oculta entrenada en 1000 épocas teniendo un error RMSE de 0.0052 y un R^2 de 0.9723. La función de transferencia tangente hiperbólica demostró una mejor adaptación al tipo de datos en comparación con la función logarítmica. Para verificar la precisión del modelo ANN, Eq. (9) fue programado para simular el valor COD. Se eligieron cuatro pruebas experimentales con diferentes condiciones de operación por su efectividad durante la degradación de herbicidas comerciales. La buena concordancia entre ambos datos confirma que el modelo ANN es sólido para continuar con la estrategia de optimización.

4.4.1.- Desarrollo

La Fig. 6 muestra la adaptación del algoritmo PSO para resolver la función objetivo multivariable (Ec. 11). Con esto, es posible encontrar la mejor solución determinando los parámetros óptimos en el menor tiempo posible. El algoritmo PSO comienza estableciendo parámetros iniciales para las partículas correspondientes a la primera generación. Posteriormente, estos se moverán según la inercia y la mejor posición dentro del espacio de posibles soluciones.

Con este enfoque matemático de la ANNim, es posible determinar múltiples variables de entrada (In_{x1}, In_{x2}) en función del valor deseado ($y_{deseado}$) integrando una función sigmoidea tangente hiperbólica (TANSING) y los coeficientes obtenidos durante el aprendizaje. El objetivo de este trabajo es minimizar el valor del COD en función del tiempo logrando aumentar la eficiencia de eliminación en una prueba experimental específica. La dificultad para solucionar el modelo ANNim propuesto por métodos algebraicos convencionales. Esto debido al alto número de coeficientes provenientes de la capa oculta además de la cantidad de variables a optimizar. Por esto, para minimizar la

función objetivo multivariable, es necesario adaptar un algoritmo que aproxime lo más posible a una solución global tomando en cuenta hacerlo en el menor tiempo posible.

La adaptación ANNim-PSO es eficiente cuando la función objetivo multivariable se minimiza lo más cercano a cero, obteniendo una serie de parámetros óptimos que satisfacen el valor COD deseado.

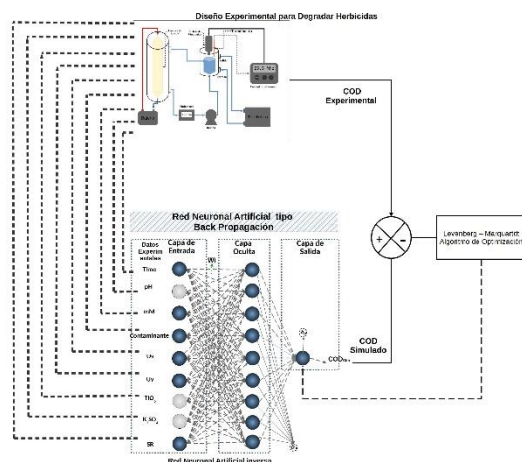


Figura 12 Diagrama del reactor sonofotocatalítico


4.4.2.- Resultados parciales

El modelo de optimización ANNim se desarrolló para determinar los valores óptimos de las variables de entrada del proceso, estas variables fueron: el pH y las concentraciones de catalizadores (TiO₂ y K₂SO₄). La función objetivo se planteó en función de reducir el valor de COD aplicándose en la mejor prueba obtenida experimentalmente. Los coeficientes generados a partir del modelo ANN se utilizaron posteriormente para el desarrollo del modelo ANNim. El modelo ANNim – PSO se aplicó en una prueba experimental específica para comprobar su eficacia en la búsqueda de parámetros óptimos, determinando todas las variables de entrada del proceso en un tiempo de 2,52s y un MAE de 0,426. Una vez validado el buen acoplamiento de la estrategia de optimización ANNim – PSO, se aumentó gradualmente la eficiencia de remoción utilizando la mejor prueba experimental obtenida durante la operación del proceso.

Optimizando dos variables al mismo tiempo, se logró el 100% de remoción en un tiempo de 27 min debido al efecto del pH sobre el catalizador de TiO₂.

Optimizando tres variables se obtuvo el 100% de remoción en 5 min por efecto del pH en ambos catalizadores (TiO₂ y K₂SO₄).

La Fig. 8 muestra la prueba experimental con la mejor reducción de DQO reportada por Bahena et al. y los datos optimizados por el modelo ANNim – PSO. De esta forma, la aplicación de la estrategia de optimización permitió extrapolar resultados no probados experimentalmente, obteniendo mejores valores de remoción y en menor tiempo.



CAPITULO V

5.1.- Resultados y Conclusiones Generales

En el presente trabajo se desarrolló un análisis de una nueva metodología de optimización utilizando la multivariabilidad usando una combinación entre una ANN y un algoritmo metaheurístico obteniendo valores óptimos para las variables.

Como primer paso se realizó el entrenamiento de las ANNs utilizando registros experimentales de tres experimentos físicos, un transformador térmico, un colector solar tipo parabólico y un reactor químico de degradación de herbicidas. Los resultados del entrenamiento para cada uno de los experimentos son satisfactorios tanto en precisión como en exactitud

En el siguiente paso, se realizó la optimización multivariable haciendo uso de una hibridación de la inversa de ANN con un algoritmo metaheurístico entre los que destacamos algoritmos genéticos, enjambre de partículas recocido simulado.

Con la intención de realizar una comparativa entre los resultados de aplicar la metodología de optimización multivariable se ha muestra la tabla 8 en donde se nota claramente que la optimización multivariable cumple con el objetivo de maximizar o minimizar los procesos mediante la búsqueda de valores óptimos con la herramienta.

Tabla 8 Comparativo de la optimización entre los procesos

Experimento	Numero de Variables Optimizadas	Metaheurística aplicada	Valor por maximizar	Valor optimizado
Transformador Térmico	4	ANNi - CS	COP = 31	COP = 40
Colector Solar Parabólico	3	ANNi - PSO	Eficiencia %	67.12%
Reactor Químico de sonofotodegradación	3	ANNi - PSO	COD mg/L = 1	COD mg/L = 0

La metodología de optimización multivariable mediante la aplicación de ANNi – Metaheurístico es capaz de encontrar en espacios de búsqueda diferentes valores para múltiples variables a la vez con exactitud y precisión.

Por lo anterior, podemos concluir que esta metodología puede utilizarse en diferentes áreas de la ingeniería como la térmica y la solar pasando por la eliminación de contaminantes, con lo que confirmamos que es de aplicación general obteniendo resultados confiables en tiempos de cómputo mínimos.

De primera vista podría decirse que la aplicación de cualquier metaheurística logra mejorar los resultados obtenidos por el experimento físico, se identifica el resultado que logra la mayor degradación de contaminantes o que incrementa el rendimiento del colector solar parabólico, así como incrementar el COP del transformador térmico.

PERSPECTIVAS FUTURAS

Las posibilidades de aplicación a futuro de esta metodología pueden ser las siguientes:

Adaptación esta metodología a un modelo físico de producción controlada en laboratorio con la finalidad de realizar la optimización de manera en línea.

Es posible aplicar la metodología estudiada a otros experimentos de otra naturaleza como la aeronáutica o la mecánica.

El uso de las metaheurísticas enunciadas no es limitante, por lo que es posible utilizar otros metaheurísticos basados en poblaciones, basados en trayectorias como programación genética o máquinas de soporte de vectores, lógica difusa, evolución diferencial, por mencionar algunos.

BIBLIOGRAFÍA

- Tomory, L. (2016). Technology in the British industrial revolution. *History Compass*, 14(4), 152-167.
- Kajela, D., & Manshahia, M. S. (2017). Optimization of renewable energy systems: a review. *Int. J. Sci. Res. Sci. Technol*, 3(8), 769-795.
- Ismail, M. S., Moghavvemi, M., & Mahlia, T. M. I. (2014). Genetic algorithm-based optimization on modeling and design of hybrid renewable energy systems. *Energy Conversion and Management*, 85, 120-130.
- Amer, M., Namaane, A., & M'sirdi, N. K. (2013). Optimization of hybrid renewable energy systems (HRES) using PSO for cost reduction. *Energy Procedia*, 42, 318-327.
- Çetin, G., & Keçebaş, A. (2021). Optimization of thermodynamic performance with simulated annealing algorithm: A geothermal power plant. *Renewable Energy*, 172, 968-982.
- Wang, J., Jiang, H., Wu, Y., & Dong, Y. (2015). Forecasting solar radiation using an optimized hybrid model by the Cuckoo Search algorithm. *Energy*, 81, 627-644.
- Kalogirou, S. A. (2001). Artificial neural networks in renewable energy systems applications: a review. *Renewable and sustainable energy reviews*, 5(4), 373-401.
- Azadeh, A., Babazadeh, R., & Asadzadeh, S. M. (2013). Optimum estimation and forecasting of renewable energy consumption by artificial neural networks. *Renewable and Sustainable Energy Reviews*, 27, 605-612.
- Zamee, M. A., & Won, D. (2020). Novel mode adaptive artificial neural network for dynamic learning: application in renewable energy sources power generation prediction. *Energies*, 13(23), 6405.
- Conde-Gutiérrez, R. A., Cruz-Jacobo, U., Huicochea, A., Casolco, S. R., & Hernández, J. A. (2018). Optimal multivariable conditions in the operation of an absorption heat transformer with energy recycling solved by the genetic algorithm in artificial neural network inverse. *Applied Soft Computing*, 72, 218-234.
- Abdulhamed, A. J., Adam, N. M., Ab-Kadir, M. Z. A., & Hairuddin, A. A. (2018). Review of solar parabolic-trough collector geometrical and thermal analyses, performance, and applications. *Renewable and Sustainable Energy Reviews*, 91, 822-831.]
- Pytilinski, J. T. (1978). Solar energy installations for pumping irrigation water. *Solar energy*, 21(4), 255-262.
- Venegas-Reyes, E., Jaramillo, O. A., Castrejón-García, R., Aguilar, J. O., & Sosa-Montemayor, F. (2012). Design, construction, and testing of a parabolic trough solar

concentrator for hot water and low enthalpy steam generation. *Journal of renewable and sustainable energy*, 4(5), 053103.

Jaramillo, O. A., Borunda, M., Velazquez-Lucho, K. M., & Robles, M. (2016). Parabolic trough solar collector for low enthalpy processes: An analysis of the efficiency enhancement by using twisted tape inserts. *Renewable energy*, 93, 125-141.

Bahena, C. L., Martínez, S. S., Guzmán, D. M., & Hernández, M. D. R. T. (2008). Sonophotocatalytic degradation of alazine and gesaprim commercial herbicides in TiO₂ slurry. *Chemosphere*, 71(5), 982-989.

Balghouthi, M., Ali, A. B. H., Trabelsi, S. E., & Guizani, A. (2014). Optical and thermal evaluations of a medium temperature parabolic trough solar collector used in a cooling installation. *Energy conversion and management*, 86, 1134-1146.

Bahena CL, Martínez SS, Guzmán DM, Hernández MD. Sonophotocatalytic degradation of alazine and gesaprim commercial herbicides in TiO₂ slurry. *Chemosphere*. 2008 Mar 1;71(5):982-9.

Schmitz J, Hahn M, Brühl CA. Agrochemicals in field margins—An experimental field study to assess the impacts of pesticides and fertilizers on a natural plant community. *Agriculture, ecosystems & environment*. 2014 Aug 1;193:60-9.

Meftaul IM, Venkateswarlu K, Dharmarajan R, Annamalai P, Megharaj M. Pesticides in the urban environment: A potential threat that knocks at the door. *Science of the Total Environment*. 2020 Apr 1;711:134612.

He B, Wang X, Yang C, Zhu J, Jin Y, Fu Z. The regulation of autophagy in the pesticide-induced toxicity: Angel or demon?. *Chemosphere*. 2020 Mar 1;242:125138.

De Souza RM, Seibert D, Quesada HB, de Jesus Bassetti F, Fagundes-Klen MR, Bergamasco R. Occurrence, impacts and general aspects of pesticides in surface water: A review. *Process Safety and Environmental Protection*. 2020 Mar 1;135:22-37.

Nollet LML, Leen SP. *Handbook of Water Analysis*. Vol. 29. Boca Raton: CRC Press; 2013.

Guadix A, Zapata JE, Almecija MC, Guadix EM. Predicting the flux decline in milk cross-flow ceramic ultrafiltration by artificial neural networks. *Desalination*. 2010 Jan 30;250(3):1118-20.

Ezemagu IG, Ejimofor MI, Menkiti MC, Nwobi-Okoye CC. Modeling and optimization of turbidity removal from produced water using response surface methodology and artificial neural network. *South African Journal of Chemical Engineering*. 2021 Jan 1;35:78-88.

A. Bassam, R.A. Conde-Gutierrez, J. Castillo, G. Laredo, J.A. Hernandez, Direct neural network modeling for separation of linear and branched paraffins by adsorption process for gasoline octane number improvement, *Fuel* (2014).

Cuernavaca, Morelos, 03 de junio de 2022.

DR. JUAN CARLOS GARCÍA CASTREJÓN
COORDINADOR DEL POSGRADO
EN INGENIERÍA Y CIENCIAS APLICADAS
P R E S E N T E

Atendiendo a la solicitud para emitir DICTAMEN sobre la revisión de la TESIS titulada: “La multivariabilidad de la inversa de la red neuronal artificial aplicada a procesos”, que presenta el alumno **Ulises Cruz Jacobo**, para obtener el título de **Doctorado en Ingeniería y Ciencias Aplicadas**.

Nos permitimos informarle que nuestro voto es **APROBATORIO**.

Atentamente
Por una humanidad culta

DR. ALBERTO ARMANDO ÁLVAREZ GALLEGOS

DR. JOSÉ ALFREDO RODRÍGUEZ RAMÍREZ

DR. ARMANDO HUICOCHEA RODRÍGUEZ

DRA. ARIANNA PARRALES BAHENA

DR. JESÚS EMMANUEL SOLÍS PÉREZ

DR. ROBERTO AGUSTÍN CONDE GUTIÉRREZ

DR. JOSÉ ALFREDO HERNÁNDEZ PÉREZ

Se adiciona efirma UAEM



UNIVERSIDAD AUTÓNOMA DEL
ESTADO DE MORELOS

Se expide el presente documento firmado electrónicamente de conformidad con el ACUERDO GENERAL PARA LA CONTINUIDAD DEL FUNCIONAMIENTO DE LA UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS DURANTE LA EMERGENCIA SANITARIA PROVOCADA POR EL VIRUS SARS-COV2 (COVID-19) emitido el 27 de abril del 2020.

El presente documento cuenta con la firma electrónica UAEM del funcionario universitario competente, amparada por un certificado vigente a la fecha de su elaboración y es válido de conformidad con los LINEAMIENTOS EN MATERIA DE FIRMA ELECTRÓNICA PARA LA UNIVERSIDAD AUTÓNOMA DE ESTADO DE MORELOS emitidos el 13 de noviembre del 2019 mediante circular No. 32.

Sello electrónico

JOSE ALFREDO RODRIGUEZ RAMIREZ | Fecha:2022-06-03 11:56:52 | Firmante

XP/8+k6OAEvNYtEmb0bM059aEKQ2hO3FxaKqWfVBBulS9aUTUv0okhY+GE5MLVM0LSiuhY7DbH/yawt8H4E5F0AzfAcU4pVt8r+uD+4Fu+P40rcKUDRpUUiRhlOvnr9Uo+rO
W6KNfclRg7+lxN13NWFrkRsNu1c7x+iXuH1/YpNGFVs5SluGpH9wU1o1HAIZJOM5XHvR1VMPhtIEcOjAFq4zY9KMqxWAZfINU3lqQb6HaKWdosEX68oRLmLwSFT4KhIvQM
4/Uz2y2h0FIHkeoUtGsoQ5S7f8vyELix6tZzIXOCCJ4JpfR3CbsHp2IAW2oujAhEQvicn3nirA==

ARIANNA PARRALES BAHENA | Fecha:2022-06-03 12:52:28 | Firmante

NsJpOqjI0OJZMLIdSa8o/qpBrrY0Gd8j9diILEXF52cln8+vr1ZqH1KLUJSuknbhBpQakWrdvCHADqzEzIQPwOkvcsgrZvm5SB+hJyAlv4s64EYfb2Fq99I8KVknzb1vpX5Jbd8jMb
LMq7WiyKYuLD3kQqWLBQD2IH5Q9X06j9f9GMYEFk8nS44BcXYFcoDRoe3cpCvcZ8KZWKbpDJpJbR4W12Lsuf+nMDFYISEvRrj8M30qzivRoemkDuH2y82LnxgGCDWC4Ruw
5iqDBV9W2ziSVAd1+VisGgn2gNMJ+a6wywmNrwuFuJoQgNnpB9BWemC9U1WdpNs62bjag==

ALBERTO ARMANDO ALVAREZ GALLEGOS | Fecha:2022-06-06 10:34:00 | Firmante

DEGaDYezmcuEDhq9Ry5QAuUypA6eL6ajDwls00gJrwZ1zgKmt2kVwCmrkTD+N6LKxdEaOznEVfHnn6zNW/ucULOn5TWqEpm7dWUc2Ql3PyZ5z4wLgvXRakK5Jq2EnvrCd
nui1Ij2VMH/mSakXXKREciGmF76QPk+j0OfQBcgt9256DeXl7cSxqJgUCIMWHPk2iF+1SpWdViqdJqlqyYmZPjis4N3b0o9ak/rqZ2QaNZY0VrxBzWSLACNPrtI5MJK0LCjOc1A
cl/s858QRwqw7whzMF8URxntiiFa02ikTihF5njBb84j4RtSw/iGyHo3GXPTqPF66BuA65Bw==

JOSE ALFREDO HERNANDEZ PEREZ | Fecha:2022-06-06 15:33:43 | Firmante

HsAOacCOLM1m0Vmu452/N5S9m1gImujieuHKhrllKOG1gjmKTRCBH0wARfMn/hqX0H+UtEDQJMNvif68L4VuYo+8fn5V7DheuQ1p0jCfABd7TydW6QXfM+gWY3Qy3DGFMD
Lp7l/ljLs1repB7COWX15mmSR316W0+ihj30hzj/wu7kyOP88Dnu/l6IDFZVBT0Hfjy5Uk8KUZgHPxa6SToozIPoW4bDohzT8DjvG9C4sJtAbQl8IOYVkoaYEVUWGRdIsAy7rQoz
59zLy1diLRpk5p9b6H5bng0DX8cb8jEzElr+b91I6d9UXWbOdtOiSxEffrY9s2/c4JKXCFg==

ARMANDO HUICOCHEA RODRIGUEZ | Fecha:2022-06-06 16:47:05 | Firmante

EjR4xKiCvabNaiXqjVhooG9g4hR3BAWnD/mBNVDD8N1Q78eGc9S2ZYQ12ES0aejDNhDJsIc1wxHepG8N5PSyP/ohMs62IV6DQMn/3RcZ8QLZ9roCYOLtKl7fjmcYEMkGpxrgs
/fa/zB9OLsYiVvdOfg7MabmvCqv50HW5i/N5rr5GF2hB7Qt3LQ46pxSoqHiJmv6aOvV2sE8Ew9A9y3dO+bFLXJerTky6FpP3HDy6fYQQPA7rSSXF4mZAHPrWf8SA3/FKEjbgUg
GqqUPieRgPKBmw0AiUJwTmsl5RplmZhaSOQxr65q/6jLuAD6GscywjfcyGQu7hAvhcQ==

JESÚS EMMANUEL SOLIS PÉREZ | Fecha:2022-06-07 09:39:48 | Firmante

jf5jVASyBGAni3rT8oQC1F0D6jdoykFLmqfTXNcnSWeRUj3dggMCA0JWh589Na1BskfhleoSY2t2X+jG2Qm7rlvakddRDdL6L+ZsH7ic7YLA8PF6ERGEA06Oor9ERYNn33KVtA+F4
yrw6aQNHDKnjWu+g4b4vPDQn6TcWuxQfpyLIG38kt4DKRQzKqa1qbxhu44UqbuE63ah88yiEVtCDq+1IsTmYhDJc5asxF53WJBgs2IrbHKmsdE83THg13Pi/MtPQCGRZy71WGbX
q2WI0wCle4ygi8AXPQBVIvT0/8LYRWU+r3plA35RjtkdpSaTTvZQzKIXX5SqtKpyyc8w==

ROBERTO AGUSTÍN CONDE GUTIERREZ | Fecha:2022-06-07 10:20:25 | Firmante

hQCqqlnTvKc+LMpe967h2S1xqpmDMomDoypKPGyl/3JeFMnsXLl8h6pkH5i2O5e5/eWd31laM+V/ZdBVpsh8NpKyU+baVXp7tzZ9//k3nhqBhS4E+Ybjug8yYqWc0zL+ONyYxYrQE
gv6hb8xyFwqxcmYQ2bbqtAT++icMFvizNZM8asHofJfzEvS3JcbPE6+trYfksutEvAPaDhNBfmVdXVqSWHfKE2DE7ecWm72fJMW4ATwq8oDjbflipc+R4/U8IS5hZlIDj6+gUml
EFTozSbPZE5I+ZuqLzYJIG0L4Pr0BPJ4FVHIUzjj0vGGuAsrRQ+BHGw8dW6IU654QvQ==

Puede verificar la autenticidad del documento en la siguiente dirección electrónica o
escaneando el código QR ingresando la siguiente clave:



cAQakN723

<https://efirma.uaem.mx/noRepudio/SbcQJDEhdibyKarBGxSMas9QL6cCcSFI>

