

Universidad de Matanzas
Sede "Camilo Cienfuegos"
Facultad de Ciencias Técnicas
Departamento de Química e Ingeniería Química



Trabajo de Diploma para optar al título de Ingeniero Químico

TÍTULO: *Obtención de un modelo neuronal para el cálculo de la eficiencia del generador de vapor de la DTCCM*

Autor: *Alejandro Linares Herrera*

Tutor: *Ing. Pavel Ramos Fundora*

Matanzas, Cuba 2021

A Dios sea toda la gloria porque voy a cumplir mi sueño y Él ha estado en cada una de mis victorias y mis derrotas, en mis mejores y peores días.

A mi madre Odalis Herrera González por ser la mujer más importante en mi vida y porque me ha ayudado a crecer como persona y como hombre.

A mi abuelo Enrique Herrera que desde pequeño siempre quiso que fuera alguien útil en la sociedad y siempre fue un ejemplo a seguir para mí.

A mi súper tutor Ing. Pavel Ramos Fundora por ser una persona muy especial y que en tan poco tiempo que lo conozco se ha ganado mucho cariño de mi parte.

A mi padre Domingo E. Linares por estar siempre para mí y educarme por el buen camino.

A mis hermanos por ser apoyo en cada uno de mis momentos difíciles y siempre confiar en mí y saber que algún día lograría mis sueños.

A todos mis amigos y compañeros de aula que son un factor fundamental para que este día llegara y sin ellos no hubiera sido posible.

Resumen

La presente investigación tiene como objetivo evaluar el comportamiento de la eficiencia del generador de vapor de la División Territorial de Comercialización de Combustibles de Matanzas, empleando un modelo de inteligencia artificial basado en redes neuronales artificiales. El entrenamiento de la red neuronal se lleva a cabo a partir de las variables de operación del proceso de producción de vapor que se registran en bases de datos referidas al segundo trimestre del año 2021. Se plantea la metodología a seguir para el entrenamiento y aprendizaje de la red neuronal mediante la aplicación de la técnica de propagación hacia atrás del error y arquitectura perceptrón multicapa. Se obtuvieron topologías desde dos neuronas en la capa oculta hasta 10. Para la selección se aplicaron las pruebas de Friedman y Wilcoxon de comparación de medianas. Se seleccionó la topología con seis neuronas en la capa oculta, con una media del error cuadrático medio de $1,01 \cdot 10^{-4}$, una desviación estándar del error cuadrático medio de $1,05 \cdot 10^{-4}$ y un coeficiente de correlación de 0,9925. Se evaluó la respuesta del modelo ante variaciones de temperatura de salida de los gases de combustión y temperatura del agua de alimentación.

Abstract

The objective of this research is to evaluate the efficiency behavior of the steam generator of the Territorial Division of Fuel Marketing of Matanzas, using an artificial intelligence model based on artificial neural networks. The training of the neural network is carried out from the operating variables of the steam production process that are recorded in databases referring to the second quarter of 2021. The methodology to be followed for the training and learning of the neural network by applying the error backpropagation technique and multilayer perceptron architecture. Topologies were obtained from two neurons in the hidden layer up to 10. For the selection, the Friedman and Wilcoxon tests of comparison of medians were applied. The topology with six neurons in the hidden layer was selected, with a mean square error of $1,01 \cdot 10^{-4}$, a standard deviation of the mean square error of $1,05 \cdot 10^{-4}$ and a correlation coefficient of 0,9925. The response of the model to variations in the exit temperature of the combustion gases and the temperature of the feed water was evaluated.

ÍNDICE

INTRODUCCIÓN.....	1
CAPÍTULO 1. Marco teórico y referencial	5
1.1. Generadores de Vapor	5
1.2. Cálculo de la eficiencia energética en generadores de vapor.....	5
1.2.1. Método analítico.....	5
1.2.2. Modelos mecánicos	10
1.2.3. Modelado matemático no lineal.....	11
1.3. Modelos neuronales.....	12
1.3.1. Antecedentes de las redes neuronales artificiales.....	13
1.3.2. Neurona artificial.....	14
1.3.3. Características generales de las RNA	15
1.3.4. Estructuras de las RNA	16
1.3.5. Estructura del Perceptrón multicapa	18
1.3.6. Entrenamiento o aprendizaje de las RNA.....	18
1.3.7. Funciones, características, estructuras y forma de selección.....	20
1.3.8. Principales redes neuronales artificiales.....	21
1.3.9. Aplicaciones de las redes neuronales.....	23
1.3.10. Aplicación de las RNA al ámbito de la Ingeniería Química.....	24
1.3.11. Aplicación de las RNA en generadores de vapor.....	25
1.4. Selección del software.....	27
1.4.1. Matlab. Toolbox	28
CAPÍTULO 2. Materiales y métodos	29
2.1. Procesamiento de la información.....	29
2.1.1. Introducción a la GUI	30
2.1.2. Parámetros de entrenamiento.....	31
2.1.3. Datos de entrenamiento, validación y prueba.....	33
2.1.4. Normalización de datos.....	35
2.1.5. Comparación entre topologías	35
CAPÍTULO 3. Análisis de resultados	37
3.1. Resultados del modelado en Matlab	37
3.2. Comparación del modelo obtenido con otros modelos	40
3.3. Evaluación del comportamiento del modelo ante variaciones en las condiciones de operación	41

3.3.1. Influencia de la temperatura de salida de los gases de combustión sobre la eficiencia del proceso	41
3.3.2. Influencia de la temperatura del agua de alimentación sobre la eficiencia del proceso	42
CONCLUSIONES.....	44
REFERENCIAS BIBLIOGRAFICAS	45

INTRODUCCIÓN

Hoy en día los generadores de vapor constituyen un elemento esencial en el funcionamiento de prácticamente todas las empresas industriales al proporcionar la potencia o el calor necesario para el proceso, dependiendo sus resultados productivos y económicos en gran medida de la confiabilidad, seguridad y eficiencia con que operen. Para ello se hace necesario el adecuado manejo de las técnicas y procedimientos para garantizar la estabilidad y seguridad en el suministro de vapor según los requerimientos del proceso, con el menor consumo de combustible, menor gasto y mínimo impacto ambiental (Tapanes, 2008).

El generador de vapor está constituido por un conjunto de superficies de calentamiento y equipos, integrados en un esquema tecnológico para generar y entregar vapor en la cantidad, con los parámetros, calidad y en el momento requerido por los equipos de uso final, en forma continua y segura, a partir de la energía liberada en la combustión de un combustible orgánico.

Debido a la creciente escasez de combustibles fósiles, se hace necesario que las industrias que utilizan generadores de vapor operen bajo condiciones de máxima eficiencia, dado que la operación inadecuada de producción y distribución de energía térmica contribuye al incremento de los costos generales.(Kljajić *et al.*, 2012)

El deseo de alcanzar estos objetivos se guio por el principio básico del análisis de los factores que influyen en el rendimiento de los generadores de vapor según lo recomendado por (Morvay y Gvozdenac, 2008). Donde se incluyen actividades de auditoría energética sistemáticas e integrales para evaluar el rendimiento energético y las prácticas de gestión actuales y pasadas.

Actualmente existe marcada tendencia a la simulación y optimización de procesos para contribuir a la disminución de los tiempos de operación y el incremento de los rendimientos. Los modelos matemáticos constituyen valiosas herramientas para lograr este objetivo pues permiten simular diversas

condiciones operacionales y diseñar equipamiento para lograr volúmenes de producción deseados.

Los modelos matemáticos son muy útiles en el área de investigación y desarrollo para poder determinar parámetros de laboratorio o de un sistema determinado, investigar las condiciones de operación de un sistema u optimizarlo; también son útiles para diseño, hacer pruebas y evaluaciones de control, simular situaciones de emergencia o paros inesperados, resolver problemas de control y capacitar a los operadores de una manera más barata, rápida y segura ya que las experimentaciones realizan sobre el modelo y no sobre el sistema.

El mayor problema en el análisis de la eficiencia energética está relacionado con la naturaleza estocástica de los factores influyentes. En tales circunstancias, un enfoque adecuado toma en consideración con mayor precisión la predicción de la producción de energía a través de una variación de entradas seleccionadas. La metodología de redes neuronales artificiales (RNA) permite una predicción confiable que, en consecuencia, permite planificar y realizar las medidas necesarias para alcanzar los objetivos especificados (Masters, 1993).

Los métodos clásicos para pronosticar incluyen métodos de regresión y espacio de estados. Los métodos más modernos incluyen sistemas expertos, sistemas difusos, programación evolutiva, RNA y varias combinaciones de estas herramientas. Entre muchas herramientas existentes, las RNA han recibido mucha atención debido a su modelo claro, fácil implementación y buen desempeño. Las RNA se han vuelto populares en varias aplicaciones del mundo real, incluidas la predicción y el pronóstico, la aproximación de funciones, la agrupación, el reconocimiento y síntesis de voz, y el reconocimiento y clasificación de patrones, entre otros (Masters, 1993).

Los modelos de RNA surgen como una herramienta para la clasificación, predicción, entre otros usos a los que se extiende. Están basadas en la semejanza con una neurona biológica, por lo que es necesario al igual que al cerebro, entrenar la red para que llegue a entender el comportamiento en cuestión (Lopez, 2017).

En otras palabras, las redes neuronales son un método sofisticado para procesar información, puesto que se procesa de forma simultánea partiendo de la sincronización de las neuronas y no de forma secuencial. Una de sus principales ventajas es la capacidad para establecer relaciones no lineales entre variables independientes y dependientes, algo que es de mucha utilidad para añadir variables y proveer información (Hernández, 2017).

El análisis de la eficiencia energética de una caldera mediante un modelo RNA desarrollado se puede aplicar a los procedimientos de control operativo. Esta técnica es capaz de cuantificar las desviaciones en la eficiencia y, en consecuencia, el consumo específico de energía del combustible provocado por las desviaciones en los parámetros operativos de los valores de referencia. La información cuantitativa sobre las desviaciones de los principales parámetros operativos puede ser un punto de partida para que los operadores de la unidad de potencia mejoren el funcionamiento de la caldera (Kljajić *et al.*, 2012).

En las plantas existentes, sistemas de monitoreo donde se captura continuamente una gran cantidad de datos operativos para su correcto funcionamiento. Por lo general, se almacenan solo como base de datos. Con estos datos, se pueden crear modelos neuronales para la simulación de la operación de la planta (Smrekar *et al.*, 2009).

Por lo antes expuesto se plantea el problema de investigación siguiente:

Problema: No se cuenta con una herramienta que permita establecer la relación que existe entre las condiciones de operación agrupadas en las bases de datos y la eficiencia del generador de vapor.

Hipótesis: Aplicando técnicas de inteligencia artificial es posible obtener un modelo neuronal que prediga la eficiencia del generador de vapor de la División Territorial de Comercialización de Combustibles de Matanzas a partir de las condiciones de operación que se registran en bases de datos.

Objetivo General

Obtener un modelo para predecir la eficiencia del generador de vapor de la División Territorial de Comercialización de Combustibles de Matanzas en función de las variables del proceso que se registran.

Objetivos Específicos

1. Seleccionar la mejor topología de red neuronal.
2. Comparar los resultados aportados por el modelo con otros métodos de cálculo de eficiencia.
3. Evaluar la influencia de las variables de operación a partir del modelo obtenido.

CAPÍTULO 1. Marco teórico y referencial

1.1. Generadores de Vapor

La energía térmica para usos industriales se puede obtener a partir de varias fuentes, aunque en la mayoría de los casos, se obtiene a partir de la energía química liberada en forma de calor por los combustibles, al quemarse en los hogares de los generadores de vapor. De ahí la importancia que tiene la correcta explotación de estos equipos, logrando una operación óptima y eficiente (Tapanes, 2008).

Un generador de vapor es un conjunto de equipos y agregados auxiliares, integrados en un esquema tecnológico con el objetivo de producir vapor a partir de agua de alimentación, para lo cual utilizan energía proveniente de una fuente de calor. La fuente de calor puede ser de combustión, que son los generadores de vapor convencionales, calor residual o gases de escape, que son las calderas recuperadoras, fisión nuclear: que son los generadores de vapor de centrales nucleares (Nordelo y González, 2010)

1.2. Cálculo de la eficiencia energética en generadores de vapor

En la literatura se encuentran metodologías para el cálculo de la eficiencia energéticas que van desde lo analítico, pasando por lo mecanístico, hasta llegar a modelos empíricos basados en heurística, ajustes matemáticos o inteligencia artificial (Savargave y Lengare, 2018).

1.2.1. Método analítico

En el método analítico, se calcula la eficiencia a partir de balances energéticos y ecuaciones, pero se limita en cuanto al poder visualizar de manera directa cómo influyen las diferentes variables operativas sobre la eficiencia. Dentro del método analítico, existe otra división en cuanto al cálculo de eficiencia energética de acuerdo con el *Performance Test Code (PTC)* de *The American Society of Mechanical Engineers (ASME)* en su edición 4-2013, el método directo e

indirecto, entendiéndose el primero como la relación directa entre la energía aprovechada y la suministrada, y la segunda como una eficiencia calculada a partir de las pérdidas generadas en los diferentes subsistemas que constituyen la caldera.

1.2.1.1. Método directo

El método directo relaciona la energía presente en el vapor producido (energía aprovechada) y la energía disponible en el combustible empleado como se muestra en la ecuación 1.1 (Lang, 2009), siendo valores de interés el poder calorífico y la caracterización del combustible (Kaewboonsong *et al.*, 2006). En la práctica, el cálculo suele basarse en el Poder Calorífico Inferior (PCI), que ya tiene en cuenta el calor perdido por la vaporización del agua en los productos, es decir para hacer el cálculo a partir del Poder Calorífico Superior (PCS) se debería eliminar el agua de los productos en estado líquido, por lo que su vaporización constituye una pérdida energética usualmente asociada al calor perdido con los gases (Arrieta *et al.*, 2003).

$$\eta_c (\%) = \frac{Q_w}{Q_c} * 100 \quad (1.1)$$

En la ecuación 1.1 η_c es la eficiencia de la caldera, Q_w corresponde a la energía asociada al vapor producido y Q_c es la energía suministrada por el combustible en forma de calor.

1.2.1.2. Método indirecto

El método indirecto se basa, esencialmente, en la suma de pérdidas energéticas, como se observa en las ecuaciones 1.2 y 1.3. Las principales pérdidas de calor de una caldera incluyen (1) gases de combustión seco que sale, (2) humedad en los gases de combustión, (3) humedad en el aire de combustión, (4) radiación de la superficie de la caldera, (5) purga de agua y (6) otras pérdidas. En un estudio particular, Qu *et al.* (2014) y Retirado *et al.* (2020), asumen las pérdidas debidas a 4, 5 y 6 como las constantes 0,015; 0,04 y 0,005 respectivamente.

$$\eta_c = 100 - \sum q_n \quad (1.2)$$

$$\sum q_n = q_1 + q_2 + q_3 + q_4 + q_5 + q_6 \quad (1.3)$$

En la ecuación 1.2, η_c es la eficiencia de la caldera. Se sustrae la sumatoria de las pérdidas energéticas para hallar la eficiencia en porcentaje. En la sumatoria, ecuación 1.3, el término q_1 corresponde a las pérdidas en los gases de combustión, q_2 y q_3 a la humedad en los gases y el aire de combustión, respectivamente, q_4 a las pérdidas por radiación, q_5 es la pérdida debida a la purga y q_6 es la suma de las demás pérdidas.

Diferentes autores difieren en cuanto al número de pérdidas principales. Para Bujak (2008), se pueden identificar nueve (9), incluyendo las anteriormente mencionadas. Sin embargo, la mayoría de los estudios coinciden en que la mayor cantidad de energía se pierde en la combustión, en los gases de combustión y en el intercambiador de calor (Barma *et al.*, 2017; Trojan, 2019).

1.2.1.3. Balance exegético

Una vez se abordan temas como balances energéticos y pérdidas energéticas en procesos, hay un concepto que aparece necesariamente, la exergía. La exergía es el trabajo máximo disponible generado por una cantidad específica de energía o un flujo al llevarlo de un estado de referencia a un equilibrio termodinámico, tomando como referencia las condiciones ambientales. Un análisis exegético implementa simultáneamente la primera y segunda ley de la termodinámica (Behbahaninia *et al.*, 2017). También puede emplearse para calcular la pérdida irreversible de energía en un proceso, entendiendo que no todas las irreversibilidades se pueden evitar y aun las que se pueden evitar no son equivalentes energéticamente, es decir, en la realidad ningún proceso llega a ser un 100% eficiente (Lozano *et al.*, 1993).

Behbahaninia *et al.* (2017) realizan un análisis paramétrico de destrucción exegética y eficiencia exegética en relación con las condiciones de referencia ($T = 25 \text{ }^\circ\text{C}$ y $P = 1 \text{ bar}$), que, siendo estrictos, debería tomarse como la condición ambiental más fría (Lang, 2009), hallando que la destrucción aumenta con el aumento de la temperatura mientras que la eficiencia disminuye.

En ese mismo estudio, se encontró que la mayor cantidad de exergía se pierde en la unidad de combustión en comparación con la de intercambio de calor, ergo la eficiencia es mayor en el intercambiador debido a las grandes irreversibilidades que ocurren en la unidad de combustión (Terhan y Comakli, 2017).

De manera análoga al cálculo indirecto de la eficiencia energética, se puede dividir el cálculo de la exergía en 6 subsistemas: destrucción exegética en la caldera (combustión, como la principal pérdida), pérdidas a través de los muros, destrucción en el calentador, pérdida en el gas emitido, pérdida por formación de CO y pérdida por combustible sin quemar. Esto teniendo en cuenta que: (1) no se considera la purga como pérdida sino como exergía de producto, ya que esta depende de la calidad del agua y no de la eficiencia de la caldera como tal; (2) se considera el mezclador de aire, en el cual no hay pérdida energética, pero sí exegética debida a la mezcla y transferencia de calor; (3) no se tienen en cuenta la energía cinética y potencial en los balances; y (4) la pérdida exegética por combustión incompleta y por radiación son descartables en los cálculos, ya que se encontró que para un buen funcionamiento de los quemadores y un buen aislamiento, respectivamente, estos valores son despreciables (Behbahaninia *et al.*, 2017; Dorotić *et al.*, 2020).

1.2.1.4. ϵ -NTU Y LMTD

El método de número de unidades transferidas (NTU por sus siglas en inglés) es usado para calcular la tasa de transferencia de calor en intercambiadores de calor, especialmente aquellos que funcionan a contracorriente, cuando no hay suficiente información para calcular la diferencia de temperatura media logarítmica (LMTD por sus siglas en inglés). La LMTD es usada para determinar

la temperatura que impulsa el intercambio de calor en sistemas de flujo, mayormente intercambiadores de calor. La LMTD es una aproximación logarítmica de la diferencia de temperatura entre las entradas caliente y fría del intercambiador de calor y ambas salidas del intercambiador de calor, como puede observarse en la ecuación 1.4. Entre más grande sea la LMTD, mayor calor transferido (Modliński *et al.*, 2019).

$$LMDT = \frac{\Delta T_A - \Delta T_B}{\ln \Delta T_A - \ln \Delta T_B} \quad (1.4)$$

Donde ΔT_A es la diferencia de temperatura entre las dos corrientes en el punto A, ΔT_B es la diferencia de temperatura entre las dos corrientes en el lado contrario, en el punto B.

El método NTU es aplicable sin importar la distribución del flujo (flujo paralelo o contraflujo) porque la efectividad de los demás métodos depende de cálculos diferenciales y la temperatura logarítmica. Así, la efectividad de un intercambiador de calor, requiere definir la mayor cantidad de calor transferido posible, que se logra con contraflujo o una longitud que tiende a infinito, sometiendo los fluidos a una diferencia considerable de temperatura. Estas metodologías son aplicadas para calcular subsistemas de la caldera que se pueden aproximar al comportamiento de un intercambiador de calor (intercambiador de calor principal, pre-calentadores, economizador) (Trojan, 2019).

Para el cálculo de la efectividad térmica del intercambiador a contracorriente, para el método NTU, a partir de las ecuaciones 1.5, 1.6 y 1.7.

$$\varepsilon = \frac{1 - e^{(-NTU * (1 - \frac{C_{min}}{C_{max}}))}}{1 - \frac{C_{min}}{C_{max}} * e^{(-NTU * (1 - \frac{C_{min}}{C_{max}}))}} \quad (1.5)$$

Donde:

$$NTU = \frac{k * A}{C_{min}} \quad (1.6)$$

$$C_{min} = \min \left[(C_p m)_{gas} * (C_p m)_{vapor} \right] \quad (1.7)$$

Donde C_{min} es el mínimo valor entre el flujo de vapor y de gases de chimenea, multiplicados por su respectiva capacidad calorífica, k es la constante de transferencia y A es el área superficial de intercambio de calor (Modliński *et al.*, 2019).

1.2.2. Modelos mecánicos

En este modelo se asume que puede comprenderse un sistema complejo examinando el funcionamiento de sus partes y la manera en que se juntan. Los modelos mecánicos suelen tener un aspecto físico, tangible, los componentes del sistema son reales, sólidos y visibles (Mojica *et al.*, 2020).

1.2.2.1. Método de Elementos Finitos

El Método de Elementos Finitos, FEM por sus siglas en inglés, es un método numérico general para la aproximación de soluciones de ecuaciones diferenciales parciales muy complejas utilizado en diversos problemas de ingeniería y física. Se usa para resolver ecuaciones diferenciales asociadas a un problema físico sobre geometrías complicadas, en el diseño de aplicaciones industriales y en la simulación de sistemas físicos complejos. Su principal requisito es que las ecuaciones constitutivas y ecuaciones de evolución temporal del problema sean conocidas de antemano (Tognoli *et al.*, 2018).

Se divide el sistema para hacer un cálculo progresivo de las partes. Normalmente es empleado en los intercambiadores de calor, de manera que se plantea un balance de masa y de energía para cada uno de los n elementos en los que se divide el subsistema (Zhang *et al.*, 2013).

1.2.2.2. Modelado Dinámico Computacional de Fluidos

Una de las metodologías más complejas, y, por lo tanto, la que mejor describe el comportamiento real de una caldera es el Modelado Dinámico Computacional de Fluidos (CFD por sus siglas en inglés). Esta técnica consiste en el modelado detallado de los líquidos o gases presentes en el proceso basándose en las propiedades fisicoquímicas de los mismos, generando modelos tridimensionales realistas del comportamiento de los fluidos (Hasini *et al.*, 2009).

Estos modelos facilitan la correcta simulación del flujo turbulento del gas, la transferencia de calor por radiación durante los pasos del gas y las interacciones por convección con las paredes de la cámara de combustión, pero debido a los altos requerimientos computacionales, su uso para el monitoreo y simulación online depende de la capacidad de cómputo disponible, y suele emplearse para casos de estudio específicos o de manera académica (Díez *et al.*, 2005; Tognoli *et al.*, 2018).

Cuando el nivel de detalle requiere una simulación por medio de CFD, se realiza la misma para el subsistema específico que lo requiere. Normalmente, se modela el intercambiador de calor y la zona de transferencia de calor por régimen convectivo, así como para predecir la emisión de contaminantes (Modliński *et al.*, 2019), y en casos específicos para encontrar fallas en el funcionamiento de una caldera o para prevenirlos. Los demás subsistemas se calculan a partir de modelos matemáticos menos complejos, para los cuales la caldera funciona de alguna manera como una caja negra comparado con la complejidad del CFD (Abroshan, 2020).

1.2.3. Modelado matemático no lineal

Los modelados matemáticos tienen como objetivo principal encontrar las variables más influyentes del sistema, así como las variables de salida de interés y generar un modelo alrededor de estos datos (Bujak, 2008). Por ejemplo, Zhou *et al.* (2002), a partir de cálculos realizados siguiendo la ASME-PTC, obtiene curvas de temperatura del aire vs. eficiencia, que emplea para modelar la

eficiencia respecto a la temperatura del aire a la entrada del quemador. En el caso de Ochoa (2019) se emplea el índice de rendimiento energético. En otro estudio se emplea una proyección económica también conocida como el sistema 3E (Eficiencia, Economía, Medioambiente), manejan los cálculos energéticos básicos y se centran más en la disponibilidad energética del combustible que en la eficiencia como tal de la caldera (Zhao *et al.*, 2019). De manera complementaria, en la metodología descrita por Rusinowski (2007) se emplea la norma DIN 1942 para los balances de materia y energía, que posteriormente se emplea como entrada de una red neuronal.

1.3. Modelos neuronales

Debido a que los modelos mecánicos encuentran cierta dificultad a la hora de ajustarse al comportamiento no lineal de las calderas, últimamente, se han realizado una buena cantidad de estudios en cuanto a la optimización del funcionamiento de la inteligencia artificial como una alternativa al modelado matemático no lineal básico. En la inteligencia artificial, las RNA se consolidan como una de las herramientas más usadas para generar estas aproximaciones basadas en datos empíricos o provenientes de su contraparte analítica, constituyendo estos últimos, sistemas híbridos (Rusinowski, 2007).

Las RNA consisten en una aproximación al funcionamiento de las neuronas, de ahí su nombre, contando con diferentes capas: una capa donde se ubican las variables de entrada (*input*), y una o varias capas intermedias que finalmente derivan en la capa que genera las variables de interés (*output*). La comunicación, o relación entre las capas está dada por la conexión de los componentes de esta, generando una red. Dicha comunicación se rige por un peso, que es un valor obtenido a través del entrenamiento de la red (Irwin *et al.*, 1995; Rusinowski, 2007).

Como las redes neuronales dependen estrictamente del conjunto de entrenamiento que se emplee, pueden constituir modelos híbridos dependiendo de si el conjunto de entrenamiento proviene de un análisis analítico, o es un conjunto de datos obtenidos de la literatura. El modelado mediante inteligencia

artificial tiene dos fases principales, una fase de aprendizaje o entrenamiento y otra de operación o aplicación. En la primera se usa un modelo ajustado al sistema de interés o una base de datos para generar los coeficientes asociados a cada una de las variables que posteriormente se emplean para hacer las predicciones (Saha *et al.*, 1998).

1.3.1. Antecedentes de las redes neuronales artificiales

Dentro las técnicas de Inteligencia artificial se encuentran las redes neuronales artificiales. Esta técnica utiliza modelos computacionales que semejan el comportamiento y funcionamiento de porciones del cerebro humano. La figura 1.1 a) ejemplifica una neurona biológica con sus conexiones, señales de entrada y de salida mientras que la b) representa una neurona artificial que posee la misma estructura, análoga a la simbolizada en a) (Quintana, 2015). Las redes neuronales artificiales son una herramienta empírica que permiten modelar disímiles procesos y predecir su comportamiento utilizando bases de datos, los juegos de valores, en algunos casos, no se necesita que excedan los 10 datos (Azari *et al.*, 2013).




Figura 1.1 Similitud entre la neurona biológica y la artificial; a) biológica; b) artificial

1.3.2. Neurona artificial

Naturalmente las neuronas poseen más de una entrada. En la figura 1.2 se observa una neurona con X_n entradas; las entradas correspondientes se multiplican por los pesos correspondientes W_{in} , pertenecientes a la matriz de pesos W . La neurona tiene una ganancia o umbral que llega al mismo sumador al que llegan las entradas multiplicadas por los pesos para formar la salida.

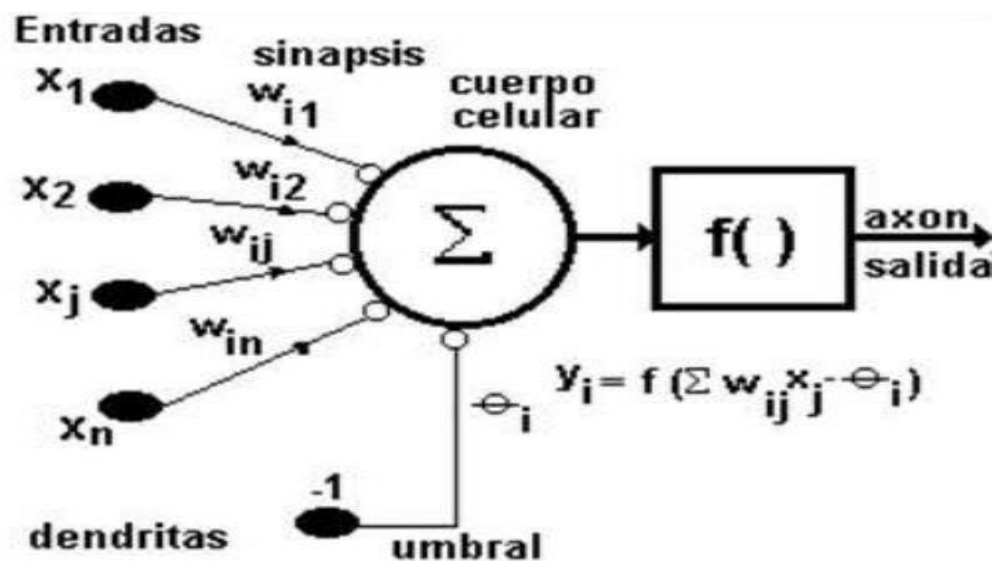


Figura 1. 2 Estructura de la neurona artificial

Los subíndices de la matriz de los pesos representan los términos involucrados en la conexión. El primer subíndice representa la neurona de destino, el segundo constituye la fuente de la señal que alimenta a la neurona, que también puede ser la salida de otra neurona. Por ejemplo, los subíndices de W_{23} indican que esta es la conexión desde la tercera entrada a la segunda neurona (Quintana, 2015).

La función principal de las redes neuronales artificiales es lograr un comportamiento de respuesta similar al que desarrolla el cerebro humano. Pero no quiere decir que se logre como muchos idealistas piensan, sabiendo que aún se desconocen complejas funciones que desarrolla el sistema neuronal del cerebro. Dichos modelos neuronales se obtienen mediante la ayuda de programas computacionales.

Una de las definiciones que se propone de las redes neuronales artificiales es: “Las redes neuronales son conjuntos de elementos de cálculos simples, usualmente adaptativos, interconectados masivamente en paralelo y con una organización jerárquica que le permite interactuar con algún sistema del mismo modo que lo hace el sistema nervioso biológico”(Pose, 2009).

1.3.3. Características generales de las RNA

Como antes se comentó las RNA poseen semejanzas con el sistema neuronal del cerebro humano. Estas redes son capaces de aprender mediante conocimientos previos, de generalizar a partir de casos precedentes, a casos nuevos (Hernández, 2017).

1.3.3.1. Aprendizaje adaptativo

El aprendizaje adaptativo permite adquirir, asimilar, aprender del conocimiento mediante el estudio, a partir de un entrenamiento o de una experiencia inicial; elimina la necesidad de elaborar modelos o de especificar funciones de distribución de probabilidad con antelación. Las redes neuronales son sistemas dinámicos auto adaptativos. Son adaptables debido a la capacidad que tienen las neuronas de ajustarse. Son dinámicos pues son capaces de estar continuamente adaptándose a las nuevas condiciones. Una red neuronal no necesita un algoritmo para resolver su problema, ya que puede generar su propia distribución de los pesos de los enlaces mediante el aprendizaje. Una de las funciones del diseñador es la obtención de la arquitectura apropiada; no es un problema del diseñador cómo la red aprende a discriminar, sin embargo, debe desarrollar un buen algoritmo de aprendizaje que proporcione a la red la capacidad de discriminar mediante un entrenamiento de patrones (Villanueva, 2002).


1.3.3.2. Auto organización

Mediante su capacidad de aprendizaje adaptativo, las redes neuronales, organizan la información que reciben durante el aprendizaje y operación. Mientras el aprendizaje es la modificación de cada elemento procesal, la auto-organización consiste en la modificación de la red neuronal completa para llevar a cabo un objetivo específico.

1.3.4. Estructuras de las RNA

La estructura o arquitectura de una red consiste en la disposición y pesos de las neuronas. Podemos distinguir en una red, el número de capas, el tipo de las capas, que pueden ser ocultas o visibles, de entrada, o de salida y la direccionalidad de las conexiones de las neuronas. La configuración de las redes puede ir desde una capa hasta multicapas (Olabe, 1998).

La figura 1.3 muestra los componentes que integran una red neuronal, donde: a) es la neurona, b) la capa oculta de la neurona, que alcanza desde una capa oculta con una sola neurona, hasta obtener un conjunto de varias capas con varias neuronas y c) son las conexiones que se establecen entre las neuronas.



a) Neurona

b) Capa de neuronas

c) Conexiones

Figura 1.3. Partes de la neurona artificial

1.3.4.1. Red neuronal de una capa

La red neuronal más sencilla es la de una sola capa, como se muestra en la figura 1.4 donde las tres figuras rectangulares que se encuentran de forma descendente indican las variables de entrada, las circulares las neuronas de la capa oculta y el rectángulo final la respuesta o neurona de salida; para este ejemplo hay tres neuronas en la capa oculta.




Figura 1.4 Red neuronal de una capa

1.3.4.2. Red neuronal multicapa

Las redes multicapas están formadas por dos o más capas de neuronas conectadas entre ellas como muestra la figura 1.5, donde la salida de una capa es la entrada de la siguiente capa. La literatura especializada ha demostrado que las redes multicapas presentan aspectos y cualidades por encima de las redes de simple capa (Olabe, 1998).

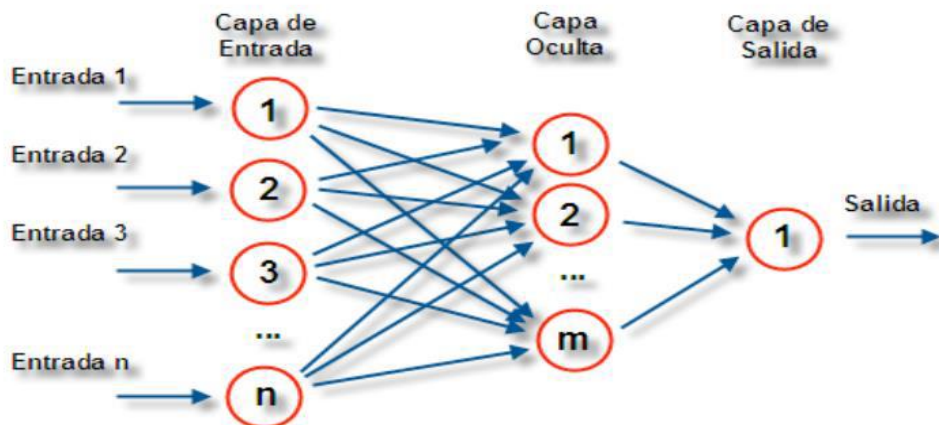


Figura 1.5. Red neuronal multicapa

1.3.5. Estructura del Perceptrón multicapa

El Perceptrón multicapa (*Multilayer Perceptron*) es una red de alimentación hacia adelante (*feed-forward*), como se muestra en la figura 1.6 compuesta por una capa de unidades de entrada (sensores), otra capa de unidades de salida y un número determinado de capas intermedias de unidades de proceso, o conocidas como capas ocultas (Quintana, 2015; Teixeira, 2014).

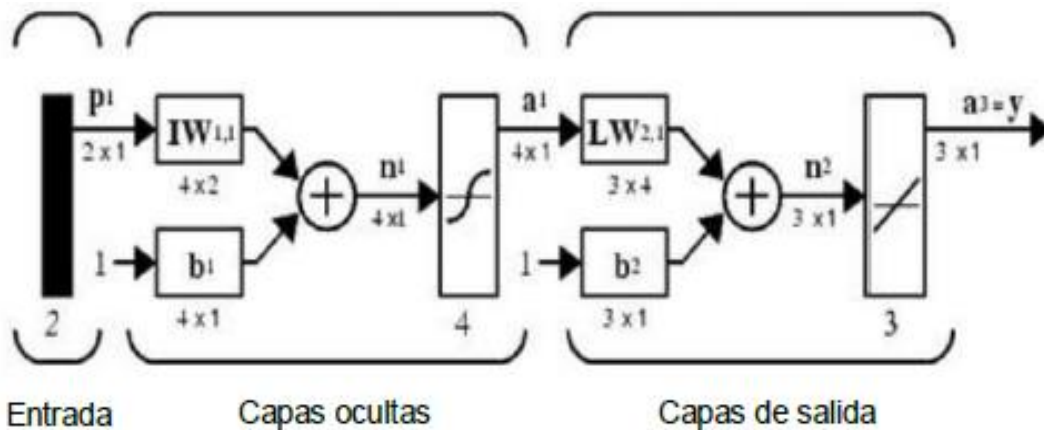


Figura 1.6. Estructura del Perceptrón multicapa (Quintana, 2015)

1.3.6. Entrenamiento o aprendizaje de las RNA

El entrenamiento o aprendizaje de las RNA se obtiene o se incorpora mediante ejemplos. Dicho proceso se ve influenciado por parámetros que pueden afectar el aprendizaje de dicha red. Los parámetros son: el número de iteraciones, el número de capas ocultas, el número de neuronas en la o las capas ocultas y el tipo de entrenamiento realizado, siendo el de retropropagación (*backpropagation*) el más utilizado.

Se ha demostrado que ordenar las entradas de la red para que sigan una distribución uniforme puede ayudar a un mejor proceso de transformación en los valores de salida por la red de neuronas y, conformemente, un mejor proceso de entrenamiento de la red (Pose, 2009).

El objetivo del entrenamiento es conseguir que una aplicación determinada, para un conjunto de datos de entrada, produzca el conjunto de valores de salida deseados o mínimamente consistentes, o lograr que la red neuronal sea capaz de reproducir el comportamiento subyacente de los datos aportados. Consiste básicamente en la minimización de la función rendimiento, lo que equivale a que la red se aproxime a la salida de los datos (Hernández *et al.*, 2004; Olabe, 1998; Quintana, 2015).

Los algoritmos de entrenamiento o los procedimientos de ajuste de los valores de las conexiones de las redes neuronales se pueden clasificar en dos grupos: supervisado y no supervisado. Aquí solamente se comentará el primero (Villanueva, 2002).

1.3.6.1. Aprendizaje supervisado

Estos algoritmos requieren que a la red se le presenten parejas de valores de entradas y salidas, las que se usan para asociar el comportamiento de los datos. En terminología estadística equivale a los modelos en los que hay vectores de variables independientes y dependientes: técnicas de regresión, análisis discriminantes o modelos de series temporales (Hernández *et al.*, 2004; Pose, 2009; Villanueva, 2002).

Al realizar este entrenamiento la respuesta que da la red a cada patrón se compara con la respuesta correcta ante dicho patrón y, como resultado de esto, se reajustan los pesos sinápticos; este reajuste está encaminado a que, ante el patrón de entrada, la red se acerque más a la respuesta correcta. Cuando ante un patrón de entrada la red neuronal responde correctamente, se pasa al siguiente patrón del juego de valores y se procede de la misma manera. Cuando se termina con el último patrón del juego de valores, se tiene que volver a empezar con el primero, ya que los pesos se han seguido modificando (Ye, 2003).

Para casos sencillos, cuando se han realizado pasos de entrenamientos completos, con todos los elementos del juego de ensayo, los pesos sinápticos de todas las neuronas se estabilizan en torno a sus valores óptimos, entonces el algoritmo de aprendizaje converge. Es decir, después de que hayan ocurrido todas las series de patrones de estímulos del juego de ensayos, el resultado es que la red responderá correctamente a todos ellos y se puede considerar entrenada y dar por terminada la fase de aprendizaje (Pose, 2009). En este tipo de aprendizaje se suelen considerar tres formas: por corrección de error, por refuerzo y estocástico (Matich, 2001; Villanueva, 2002).

1.3.6.2. Aprendizaje por corrección de error

Consiste en ajustar los pesos de las conexiones de la red en función de la diferencia entre los valores deseados y los obtenidos en la salida, es decir, en función del error cometido. Otro algoritmo de aprendizaje por corrección de error, constituye el denominado regla delta generalizada o algoritmo de retro propagación del error (*error backpropagation*), conocido también como regla LMS (*Least-Mean-Square Error*) multicapa. Se trata de una generalización de la regla delta para poder aplicarla a redes con conexiones hacia adelante (*feedforward*) con capas o niveles ocultos de neuronas que no tienen relación con el exterior. Son redes con capas de entrada, capas ocultas y capas de salida (Hernández, 2017).

1.3.7. Funciones, características, estructuras y forma de selección

La clasificación de las redes neuronales que a continuación se muestra es una breve descripción de las redes más comunes y frecuentes de los simuladores de sistemas de computación neuronal (Hernández, 2017). Aunque existen debates permanentes sobre las estrategias de selección de modelos, es evidente que la aplicación exitosa de redes neuronales artificiales en problemas de modelado de ingeniería se ve muy afectada por cuatro factores principales: (Quintana, 2015).

1. Tipo de red (redes recurrentes, *backpropagation*, *feedforward*, la redes neuronales *wavelets*, funciones de base radial, etc.).

2. Estructura de la red (número de capas ocultas, número de neuronas por capa oculta).
3. Funciones de activación o funciones de transferencia.
4. Algoritmos de entrenamiento.

De acuerdo a las características del problema a resolver se tienen en cuenta otros aspectos de las redes. La mayoría de estos se pueden clasificar en aplicaciones de predicción, clasificación, asociación, conceptualización, filtrado y optimización. Los tres primeros tipos de aplicación requieren un entrenamiento supervisado (Olabe, 1998).

1.3.8. Principales redes neuronales artificiales

Entre las RNA más utilizadas se encuentran el *perceptrón*, *adeline-madeline* y *backpropagation*. La red *backpropagation*, utilizada en este trabajo se describe a continuación.

1.3.8.1. Backpropagation

Backpropagation es un método de entrenamiento de redes multicapa. Su potencia reside en su capacidad de entrenar capas ocultas y de este modo supera las posibilidades restringidas de las redes de una única capa. Las redes *Backpropagation* tienen un método de entrenamiento supervisado (Quintana, 2015). A la red se le introducen parejas de patrones, un patrón de entrada emparejado con un patrón de salida deseada. Por cada presentación, los pesos se ajustan de forma que disminuya el error entre la salida deseada y la respuesta de la red (Hernández *et al.*, 2004).

El algoritmo de aprendizaje *Backpropagation* conlleva una fase de propagación hacia adelante y otra fase de propagación hacia atrás. Ambas fases se realizan por cada patrón presentado en la sesión de entrenamiento (Olabe, 1998). El funcionamiento de la red *Backpropagation* consiste en el aprendizaje de un conjunto predefinido de pares de entrada-salida dadas como ejemplo, empleando un ciclo propagación-adaptación de dos fases: en la primera, se

aplica un patrón de entrada como estímulo para la primera capa de neuronas de la red, se va propagando a través de todas las capas de superiores hasta generar una salida, se compara el resultado obtenido en las neuronas de salida con la salida que se desea obtener, y se calcula un valor del error para cada neurona de salida (Teixeira, 2014).

A continuación, estos errores se transmiten hacia atrás, partiendo de la capa de salida, hacia todas las neuronas de la capa intermedia que contribuyen directamente a la salida, recibiendo el porcentaje de error aproximado de la participación de la neurona intermedia con la salida original. Este proceso se repite capa por capa, hasta que todas las neuronas de la red hayan recibido un error que describa su aportación relativa al error total. Basándose en el valor del error recibido, se reajustan los pesos de conexión de cada neurona, de manera que en la siguiente vez que se presente el mismo patrón, la salida esté más cerca de la deseada, es decir, que se disminuya el error (Karunnamithi *et al.*, 2014).

La importancia de la red *Backpropagation* consiste en auto adaptar los pesos de las neuronas de las capas intermedias para aprender la relación entre un conjunto de patrones dados como ejemplo y sus salidas correspondientes. Después del entrenamiento, puede aplicar esta misma relación a nuevos vectores de entrada con ruido o incompletas, dando una salida activa si la nueva entrada se parece a las presentadas durante el aprendizaje (Andrade *et al.*, 2016).

En el proceso de entrenamiento o aprendizaje de la *Backpropagation* es frecuente medir cuantitativamente el aprendizaje mediante el valor RMS (*Root Mean Square*) del error de la red. Esta medida refleja el modo en el que la red está logrando respuestas correctas; a medida que la red aprende, su valor RMS decrece y el modelo converge (Modliński *et al.*, 2019).

1.3.9. Aplicaciones de las redes neuronales

En este epígrafe se recogen ejemplos de aplicaciones de las redes neuronales artificiales calificadas como herramientas que resuelven problemas de emparejamiento, clasificación, complemento de vectores patrones, etc.

Entre las áreas de aplicación de las redes se encuentran: análisis financiero; procesamiento de imágenes en el ámbito de la medicina, ingeniería, industria y defensa; diagnóstico médico y comercial; robótica y control; reconocimiento y síntesis de voz; clasificación de datos provenientes de sensores; compresión y codificación de información (Azari *et al.*, 2013; Villanueva, 2002).

1.3.9.1. Aplicaciones en la industria de procesos

Como se ha mencionado, las redes neuronales permiten al ingeniero crear modelos para procesos utilizando datos históricos del mismo proceso. Los modelos pronostican cómo el proceso responderá a los cambios de entradas y diferentes condiciones de trabajo. Las condiciones de operación óptima, sujetas a restricciones, pueden también determinarse con las redes correctamente formuladas (Abroshan, 2020).

Los modelos identificados empleando redes neuronales pueden utilizarse en estudios de proceso fuera de línea (off-line) o ser instalados en línea (on-line) para suministrar una detección precoz de los problemas durante la operación y determinar los puntos de ajustes que continuamente optimicen el proceso para maximizar las ganancias (Tang *et al.*, 2020).

1.3.9.2. Optimización de procesos

El valor de la optimización basada en modelos está bien probado, pero, en general, los modelos analíticos de un proceso pueden ser muy difíciles de obtener. Al emplear redes neuronales en conjunto con su capacidad de optimización en línea y en tiempo real, se puede obtener el mayor potencial económico de un proceso (Andrade *et al.*, 2016).

1.3.9.3. Predicción y estimación

El futuro puede ser predicho dentro de la precisión que dan los modelos basados en comportamientos. Las redes neuronales pueden aprender los modelos óptimos, adaptados continuamente con el empleo de los últimos datos medidos. Los ingenieros pueden emplear estas predicciones para estimar la demanda de mercado de corto plazo, predecir estados futuros del proceso o aún condiciones meteorológicas que afecten a las emisiones e impacten en la vecindad de la planta (Matich, 2001).

1.3.10. Aplicación de las RNA al ámbito de la Ingeniería Química

En la actualidad se reportan cuantiosos artículos que implementan redes neuronales artificiales en lo que se refiere a ingeniería, medicina, finanzas, etc. Existe oscilación en la aparición de los artículos. Por citar algunos ejemplos, en el 2013 se publicaron 6 963 documentos y en el 2014 esta cifra disminuyó a 5 995, siendo aproximadamente 13,9 % menor que el año anterior. El año en que se registró el mayor número de publicaciones fue el 2008 con 7 281 documentos, algo que da a entender el desarrollo que ha abarcado el tema. Las áreas con mayor volumen de publicaciones son: ingeniería y ciencias de la computación, con 40,9 % y 39,1 % de los documentos publicados respectivamente (Quintana, 2015).

Lo antes mencionado refleja el aporte de las redes neuronales al ámbito ingenieril. A continuación, se muestran estudios de RNA que dan solución a problemas de ingeniería química:

Ghaemi *et al.* (2008) emplearon RNA con arquitectura de perceptrón multicapa para la predicción del equilibrio líquido vapor en soluciones acuosas de electrolitos. Compararon los resultados con los obtenidos por modelos termodinámicos, obteniendo mejores resultados para la red neuronal.

Por otro lado, investigadores Moghadassi *et al.* (2009); Valderrama *et al.* (2009); emplearon las RNA en la predicción de propiedades como la viscosidad, densidad, entre otras. Los resultados de la primera investigación revelaron el empleo de una red con algoritmo de aprendizaje *back-propagation* y Levenberg-Marquardt (LM) como algoritmo de entrenamiento, obteniendo una red con seis neuronas en la capa oculta con un error cuadrático medio de 0,000606. Mientras que las otras dos utilizan como herramienta de predicción el *software* Matlab en su versión libre logrando resultado aceptable en su implementación para cálculos de ingeniería.

Según los resultados satisfactorios de Shojaee *et al.* (2014) en la obtención de una red de tres capas con una de entrada, un oculta con siete neuronas y otra de salida, es práctico utilizar como funciones de transferencia la *tansing* y la *purelin*, utilizando la red neuronal *feed forward backpropagation* para lograr predecir la densidad de las mezclas de líquidos iónicos y agua.

1.3.11. Aplicación de las RNA en generadores de vapor

Las RNA también se han utilizado para modelar calderas Smrekar *et al.* (2009) mostraron el procesamiento y selección de datos complejos con análisis de sensibilidad para estimar la influencia de cada parámetro de entrada asumido. Se seleccionaron parámetros de operación correspondiente a un periodo de trabajo de 12 días. Se utilizó para el entrenamiento de la red el algoritmo de aprendizaje *backpropagations* con una capa oculta, se utilizaron el 60% de los datos para el entrenamiento de la red y el 15% para la validación y 25% para prueba, se variaron la cantidad de neuronas en la capa oculta hasta 26, lográndose predecir de forma satisfactoria los valores de eficiencia del generador de vapor.

Fast *et al.* (2008) describió el uso de la RNA para el monitoreo y diagnóstico de las condiciones de operación del generador de vapor de una planta de generación eléctrica, actuando sobre las posibles desviaciones de las variables monitoreadas. La selección de los parámetros de entrada y salida de la red se basó en la disponibilidad de datos de la planta. Los resultados obtenidos por la

red se utilizaron para desarrollar un sistema de control en tiempo real de los parámetros de la planta y predecir posibles desviaciones de los parámetros de control.

Rusinowski (2007) desarrolló el modelado de una RNA, donde se analizaron la influencia de las variables de operación sobre la eficiencia térmica de las calderas. Se analizó la influencia de las pérdidas de calor en los gases de combustión, así como las pérdidas debido a combustible no quemado. Se utilizó el método de entrenamiento *backpropagations* y se varió el número de capas ocultas. El modelo neuronal obtenido fue aplicado al sistema de control de la planta para la optimización de los parámetros de operación.

Kalogirou (2000) reveló la capacidad de las RNA como herramientas en la predicción y el modelado de energía y también las recomendó para varias otras aplicaciones. Se usó para el entrenamiento de la red una arquitectura multicapa recurrente con algoritmo *backpropagations*. Se obtuvo un coeficiente de correlación igual a 0.9985 entre los valores generados por el modelo neuronal y los parámetros de operación de la planta. La RNA creada se utilizó para predecir los requerimientos energéticos del generador de vapor.

Otros autores Romeo (2006) han presentado la metodología de diseño y aplicación de redes neuronales para la monitorización de una caldera y señalan las ventajas de las RNA en estas situaciones. Se plantea que la combinación de métodos tradicionales con la ayuda de una estructura neuronal para monitorear la caldera podría resolver completamente el problema. Los resultados de la monitorización de modelos neuronales son coherentes con los datos reales. También se concluyó que las RNA son una herramienta de seguimiento más sólida que el seguimiento basado en ecuaciones.

Rusinowski (2010) concluyó que los sistemas contemporáneos de diagnóstico térmico de una operación requieren la aplicación de modelos de simulación y desarrollaron un modelo híbrido de caldera. A continuación, este modelo se aplicó a cálculos de simulación multivariante de la influencia de las condiciones de operación en la pérdida de energía de la caldera y su eficiencia energética.

Dhanuskodi *et al.* (2015) desarrollaron un modelo neuronal para predecir la temperatura de la pared en una caldera supercrítica. Se utilizaron como parámetros para el entrenamiento la presión y la entalpía del vapor y del agua, así como la cantidad de calor intercambiado. Los resultados se compararon con 403 condiciones experimentales y 72 condiciones reportadas por la literatura.

Prieto *et al.* (2011) utilizaron valores obtenidos de forma independiente para cada variable de entrada a partir de sus registros históricos sin considerar la relación entre ellos y concluyeron que las RNA son una técnica capaz de tratar de manera eficiente muchos problemas industriales que no pueden ser manejados con la misma precisión por otras técnicas.

1.4. Selección del software

Para el diseño de una red neuronal, para resolver problemas concretos dentro de las aplicaciones antes mencionadas conviene disponer de una herramienta *software* de diseño de RNA, existiendo herramientas que se diferencian en dependencia de sus prestaciones, complejidad de uso y adquisición (Arencibia, 2010).

Los diseñadores construyen dichos *softwares* con herramientas para diferentes redes, siendo el usuario el encargado de especificar el número de capas, de neuronas y los tipos de conexiones. Se definen los conjuntos de datos o ficheros de entrada y salida en el formato especificado, eligiéndose además los parámetros de los cálculos internos de la red. Se suma a esto la selección de las funciones de transferencia y procesamiento de neuronas, así como la posibilidad de construir variaciones de los modelos estándar.

En la fase de entrenamiento se debe especificar el número de iteraciones y la planificación de los cambios de los parámetros de aprendizaje. Generalmente esta fase requiere varias sesiones y la experimentación de diferentes parámetros de aprendizaje, diferentes vectores de entrada o diversas estrategias de

entrenamiento permiten obtener conclusiones definitivas para la solución más eficaz de una aplicación (Olabe, 1998).

1.4.1. Matlab. Toolbox

La *Neural Network Toolbox* es un paquete de Matlab que contiene una serie de funciones para crear y trabajar con redes neuronales artificiales. Así pues, proporciona las herramientas para el diseño, la puesta en práctica, la visualización, y la simulación de redes neuronales. La *Neural Network Toolbox* también proporciona una interfaz gráfica que permite diseñar y manejar las redes que el usuario desee. El diseño modular, abierto y extensible de la *Neural Network Toolbox* simplifica la creación de funciones y de redes. En resumen, como principales características presenta:

- Interfaz gráfica (GUI por sus siglas en inglés) para crear, entrenar y simular a sus redes neuronales, así como ayuda al usuario de las arquitecturas de redes supervisadas y no supervisadas más comunes.
- Un sistema sencillo para realizar el entrenamiento y creación de funciones de aprendizaje.
- Representación modular de la red, permitiendo un número ilimitado de la entrada que fija capas e interconexiones de la red, así como funciones para mejorar el entrenamiento, funcionamiento y visualización de la misma (Demuth *et al.*, 2008).

La implementación en Matlab de las redes neuronales puede realizarse de tres formas diferentes (Astocondor, 2010):

1. Mediante código desde la línea de comandos o desde el espacio de trabajo de MATLAB (*workspace*).
2. Utilizando el conjunto de bloques incluidos en el *toolbox* de *Control Systems de Neural Networks Blockseten Simulink*.
3. Empleando la interfaz gráfica de usuario de redes neuronales artificiales, la cual se puede desplegar empleando los comandos *nntool* (*Neural Network Toolbox*) o *nnstart* (*Neural Network Start*)

CAPÍTULO 2. Materiales y métodos

Debido a la necesidad de alimentar la red neuronal para lograr que se extraiga el conocimiento necesario para predecir de forma satisfactoria los valores de eficiencia del generador de vapor de la División Territorial de Comercialización de Combustibles de Matanzas, se necesitó recurrir a la búsqueda de datos que proporcionen la información deseada. Para ellos se recurrió al procesamiento de los datos recopilados en las hojas de parámetros de operación del generador de vapor comprendidos entre los meses de marzo y mayo de 2021. Las variables estudiadas se presentan en la tabla 2.1.

Tabla 2.1 Variables utilizadas para el entrenamiento de la red neuronal

Variables	Unidad	Intervalo
Temperatura de salida de gases de combustión	(°C)	120-204
Temperatura del vapor de la caldera	(°C)	159-194
Presión de trabajo de la caldera	(kPa)	450-900
Temperatura del precalentador	(°C)	80-93
Temperatura del agua de alimentación	(°C)	59-104
Temperatura de recirculación del combustible	(°C)	67-87
Temperatura del combustible	(°C)	45-73

2.1. Procesamiento de la información

Para el procesamiento de la información se utilizó el software MATLAB en su versión 2015, en el que se ingresaron los datos experimentales extraídos de la fuente. Se agruparon los datos por columnas obteniendo un ordenamiento que

comenzaba desde temperatura de salida de gases hasta la temperatura del combustible como se muestra en la tabla 2.1.

2.1.1. Introducción a la GUI

Al introducir el comando *nntool* en el espacio de trabajo de MATLAB se abre la ventana Administradora de redes neuronales artificiales *Network/Data Manager* como muestra la figura 2.1. Esta ventana tiene su propia área de trabajo, independiente de la línea de comandos. Por lo tanto, cuando se utiliza la Guía de Interfaz de Usuario (GUI por sus siglas en inglés), es posible exportar los resultados al espacio de trabajo (de línea de comandos). Del mismo modo, es posible importar resultados del área de trabajo para la GUI.

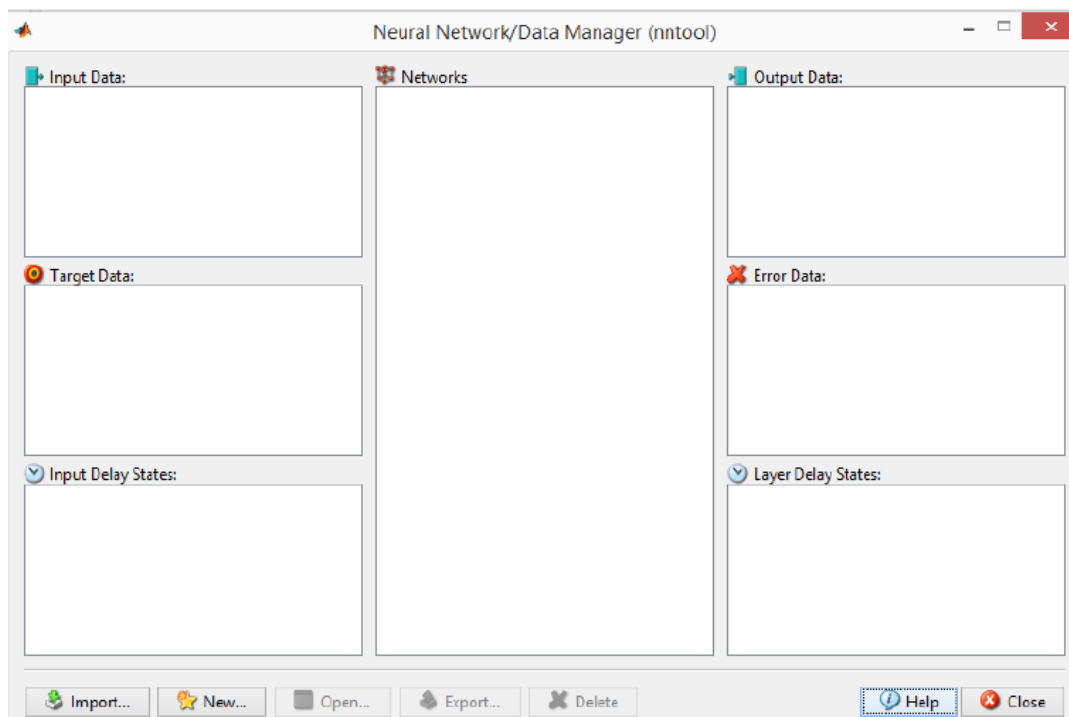


Figura 2.1 Ventana administradora de redes neuronales artificiales

Una vez que la ventana *Network/Data Manager* está en funcionamiento se puede crear una red, entrenarla, simularla y exportar los resultados al espacio de trabajo (*Workspace*). En esta ventana se cargan los datos que serán las variables de entrada (*Input Data*) y las variables objetivo (*Target Data*), que ya se habían organizados en un libro. Es necesario agregar que hubo que convertir los datos

en una matriz de ocho filas y de ciento cincuenta columnas y transponerlos de forma tal que se facilitara el entendimiento de los datos por el *software*. En la pestaña llamada nuevo (*New*) se introducen las configuraciones deseadas. Aquí se especifican el tipo de red neuronal (*feed-forward backpropagation*), la función de entrenamiento (*trainlm*), de aprendizaje (*learnngdm*), de rendimiento (*mse*), así como la cantidad capas (tres capas, una de entrada, una oculta y una de salida) y la cantidad de neuronas en la capa oculta. Se especificaron también las funciones de activación, la tangente sigmoidea (*tansig*) para la capa oculta y la lineal (*purelin*) para la capa de salida como muestra la figura 2.2

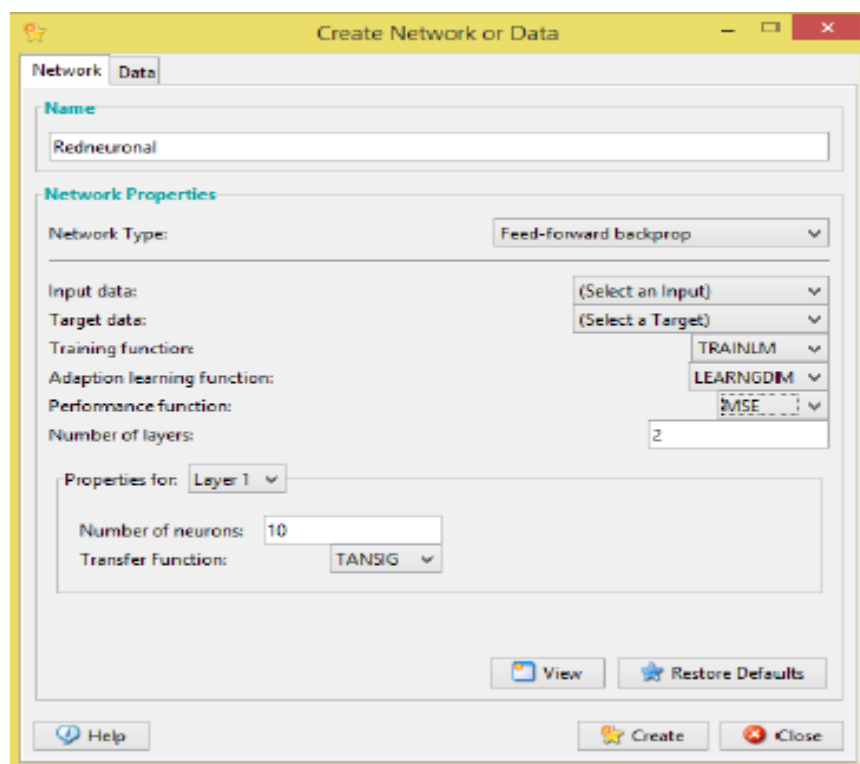


Figura 2.2 Ventana para la creación de la red neuronal

Posteriormente se crearon las diferentes arquitecturas y se especificaron otros parámetros para el entrenamiento.

2.1.2. Parámetros de entrenamiento

La magnitud del gradiente de rendimiento y el número de comprobaciones de validación son parámetros de entrenamiento de gran interés que se utilizan para finalizar el proceso. El gradiente se hará muy pequeño cuando el entrenamiento

alcance un mínimo en el rendimiento. Si la magnitud del gradiente es menor que 10^{-5} , el entrenamiento se detendrá; este límite puede ajustarse en *min_grad*. El número de comprobaciones de validación representa el número de iteraciones sucesivas en que el rendimiento de validación no logra disminuir. Si este número llega a 6 (valor predeterminado), el entrenamiento se detendrá (Hernández, 2017) este criterio se puede cambiar en *max_fail*. En la tabla 2.2 se muestran otros parámetros para detener el entrenamiento.

Tabla 2.2 Parámetros para detener el entrenamiento

Parámetros	Criterio
<i>Epochs</i>	Máximo número de iteraciones
<i>Time</i>	Tiempo máximo de entrenamiento
<i>Goal</i>	Valor mínimo de rendimiento

Aplicando el algoritmo de Levenberg-Marquardt (*trainlm*), están presentes ciertos parámetros *mu*, *mu_dec*, *mu_inc*, *mu_max*. El parámetro *mu* representa el valor inicial del parámetro de amortiguamiento. Este valor se multiplica por *mu_dec* siempre que la función de rendimiento se reduzca un paso. Se multiplica por *mu_inc* siempre que aumente la función de desempeño en un paso. Cuando *mu* es mayor que *mu_max*, el algoritmo se detiene (Hernández, 2017) .

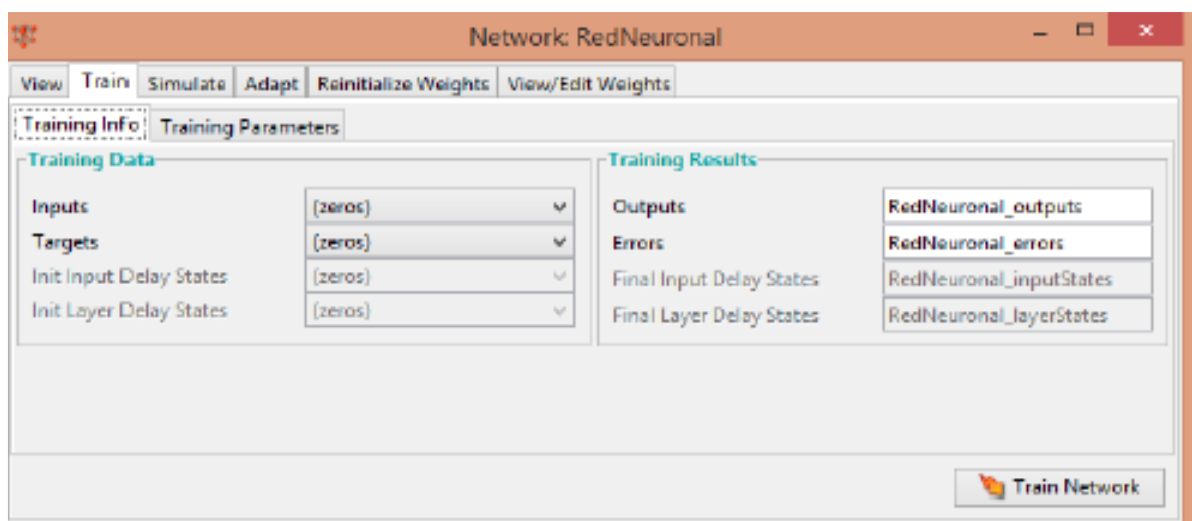


Figura 2.3. Ventana Network: RedNeuronal

En la figura 2.3, se muestra la ventana *Network: RedNeuronal*, que representa el nombre de la red. En este punto se puede ver la red haciendo clic en la ficha *View* como muestra la figura 2.4. En la pestaña *Train*, concretamente en *Training Info*, se especifican las entradas, y las salidas.

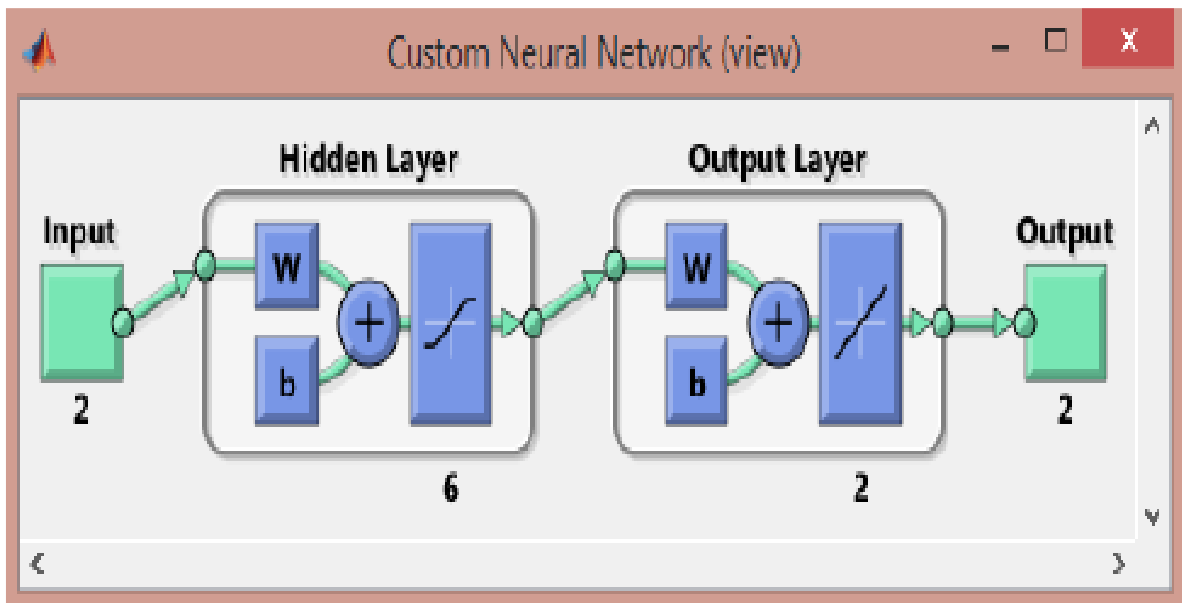


Figura 2.4. Ventana de la representación de la red neuronal en Matlab

2.1.3. Datos de entrenamiento, validación y prueba

Para controlar si una red neuronal ha sobre-aprendido se aplica la técnica *Early-stopping*. Para ello, los datos se dividen en diferentes grupos: entrenamiento, validación y prueba. Como se muestra en la figura 2.5, las curvas de validación y prueba son muy similares. Si la curva de prueba aumenta significativamente antes del aumento de la curva de validación, es posible que haya ocurrido un sobreajuste. La validación cruzada se puede realizar para estos datos, de modo que se puedan comparar las salidas deseadas (objetivos), con los datos simulados por la red.

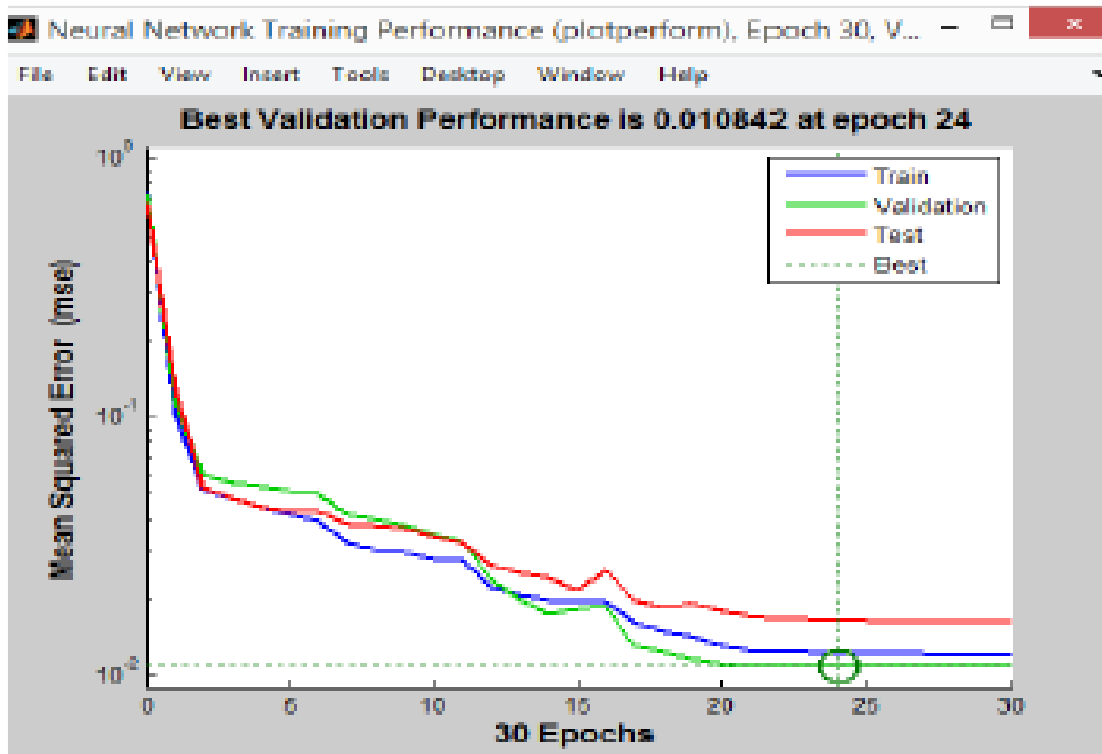


Figura 2.5. Datos de entrenamiento, validación y prueba

Matlab brinda otras opciones de visualización como son los gráficos de correlación entre las variables objetivos y las variables de salida. La figura 2.6 muestra el caso de una corrida donde se muestran las correlaciones para el entrenamiento, la validación y la prueba.

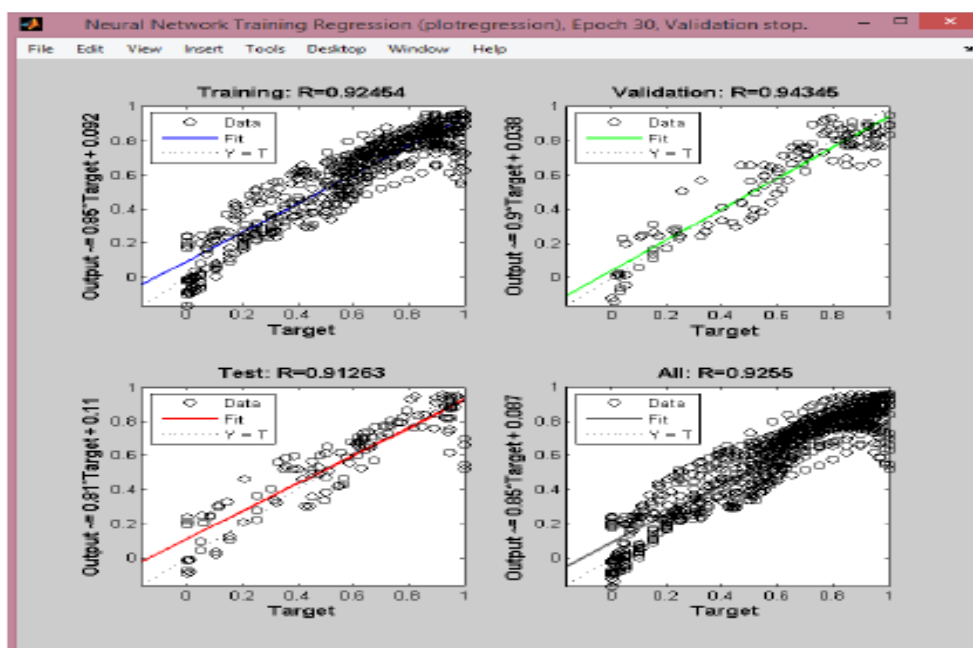


Figura 2.6. Gráficos de correlaciones de entrenamiento, validación y prueba

2.1.4. Normalización de datos

Hay que tener en cuenta que las variables de entrada pueden tener diferencias de valores de varios órdenes de magnitud de forma tal que el aprendizaje de la red se verá influenciado por estas, ya que el incremento de pesos de una neurona es proporcional a su entrada (Lopez, 2017).

Uno de los métodos más utilizados para normalizar datos es el Máximo y es el que se utilizó en el trabajo. Los datos que se quieren normalizar se encuentran dentro del vector $Datos(i)$, con $i = 1, \dots, n$. El procedimiento a seguir es el siguiente (Quintana, 2015):

1. Se busca el máximo del vector
2. Se normalizan los datos según la relación:

$$Datos_{norm(i)} = \frac{DATOS(i)}{MAX} \quad (2.1)$$

Los datos normalizados caen dentro del intervalo $[0,1]$ en el caso de que los datos originales sean positivos; si también son negativos caerán dentro del intervalo $[-1,1]$.

2.1.5. Comparación entre topologías

Uno de los criterios principales que se utilizaron en la selección de la topología fue el error cuadrático medio (*root mean square*). Resultó necesaria la comparación entre errores cuadráticos medios de las distintas topologías obtenidas debido a la similitud de los resultados. De esta forma se justificó la selección entre una u otra teniendo en cuenta dicho criterio.

Se comprobó si existían diferencias estadísticamente significativas entre el comportamiento (error cuadrático medio) de las diferentes topologías creadas en Matlab a partir de la prueba de Friedman en la herramienta *Statgraphics Plus 5.0*. Esta prueba es apropiada cuando se analiza un experimento en bloques, es decir, cuando los datos en cada fila corresponden a la misma unidad o bloque experimental. Es una prueba no paramétrica de comparación de muestras. En

caso de que el valor-P fuera mayor que el valor de probabilidad establecido (0,05) se acepta la hipótesis nula de que no existen diferencias significativas entre las muestras comparadas por lo que se puede seleccionar cualquiera de las topologías obtenidas. Es posible examinar otros parámetros estadísticos propios de las topologías. En caso de obtener un valor-P menor se concluiría que existen diferencias significativas, sin identificar cuáles son las topologías significativamente diferentes.

En caso de que entre las muestras analizadas no existan diferencias significativas se deben analizar otros parámetros como la complejidad de la topología, el coeficiente de correlación entre los valores estimados por la red y los valores reales de las variables de salida en la validación y la desviación estándar del error cuadrático medio. Si existen diferencias significativas se aplica la prueba de comparación de medianas en el mismo *software Statgraphics Plus 5.0*. Esta es una opción de tabulación que compara las medianas de dos poblaciones usando la prueba *Mann-Whitney* (de *Wilcoxon*). Esta prueba es útil en casos donde el supuesto de normalidad es cuestionable y no se encuentra una transformación adecuada y en casos donde una o más observaciones son sospechosas de poseer valores diferentes (Llanes, 2016).

En caso de que el valor-P fuera menor que el valor de probabilidad establecido (0,05) se rechaza la hipótesis nula que plantea esta prueba estadística y por tanto se concluiría que existen diferencias significativas entre las dos topologías. En caso contrario se acepta la hipótesis nula y se concluye que no existen diferencias significativas (Llanes, 2016).

CAPÍTULO 3. Análisis de resultados

Con el fin de resolver el problema planteado en este trabajo, se decidió modelar empleando redes neuronales mediante la herramienta que brinda el software Matlab, empleando el perceptrón multicapa.

3.1. Resultados del modelado en Matlab

Para la creación del modelo se utilizó la caja de herramientas *Neural Network Toolbox* de Matlab. En todos los casos las redes son unidireccionales o *feed-forward* (comando *newff*) y se realizó el entrenamiento con el algoritmo Levenberg-Marquardt de propagación hacia atrás o *backpropagation* (comando *trainlm*). Como funciones de transferencia se utilizaron la sigmoidea (*tansig*) en la capa oculta y la función lineal (*purelin*) para la capa de salida. Las variables se normalizaron en un intervalo entre 0 y 1 y se agruparon en dos libros de Excel, las variables de entrada y las variables de salida.

Las arquitecturas se crearon basadas en el criterio de prueba y error, es decir, se variaron las neuronas de la capa oculta desde 2 hasta 10. En la selección de la mejor topología se compararon las medianas del error cuadrático medio (MECM), así como la desviación estándar del error cuadrático medio (DEECM) y el coeficiente de correlación (R). Los resultados del modelado en Matlab se muestran en la tabla 3.1.

Como se observa en la tabla 3.1, los resultados de la comparación de topologías calculados por el modelo son muy similares entre sí en cuanto al orden, por lo que se aplica la prueba de Friedman para determinar si existen diferencias estadísticamente significativas entre los errores cuadráticos medios (ECM) de las diferentes topologías.

Tabla 3.1 Comparación entre las topologías en la predicción en Matlab

Topología	MECM	DEECM	R
7-2-1	1,16*10 ⁻⁴	1,05*10 ⁻⁴	0,9802
7-3-1	1,26*10 ⁻⁴	1,30*10 ⁻⁴	0,9796
7-4-1	1,19*10 ⁻⁴	1,05*10 ⁻⁴	0,9862
7-5-1	2,03*10 ⁻⁴	1,99*10 ⁻⁴	0,9764
7-6-1	1,01*10 ⁻⁴	1,05*10 ⁻⁴	0,9925
7-7-1	1,15*10 ⁻⁴	1,19*10 ⁻⁴	0,9876
7-8-1	1,69*10 ⁻⁴	1,23*10 ⁻⁴	0,9858
7-9-1	2,23*10 ⁻⁴	1,41*10 ⁻⁴	0,9799
7-10-1	2,65*10 ⁻⁴	1,92*10 ⁻⁴	0,9704

El resultado de la comparación de medianas para los ECM aportó el valor-P de 0,049, que al ser comparado con el valor de comparación α (0,05) resultó ser menor como se muestra en la figura 3.1. De acuerdo al resultado obtenido se rechaza la hipótesis nula y se concluye que existen diferencias estadísticamente significativas entre las topologías de redes seleccionadas.

Friedman Test		
	Sample Size	Average Rank
Col_1	3	1,0
Col_2	3	3,0
Col_3	3	2,0
Test statistic = 6,0 P-Value = 0,0397871		

Figura 3.1. Resultados de la prueba de Friedman en Statgraphics 5.0

Para identificar cuáles son las topologías estadísticamente significativas, se realizó la prueba de comparación de medianas o prueba de Wilcoxon. Se realizó

la prueba a todos los pares posibles. En la tabla 3.2 se muestran los resultados obtenidos para la comparación entre todas las topologías seleccionadas.

Tabla 3.2. Comparación entre las topologías mediante la prueba de Wilcoxon

Topologías	7-2-1	7-3-1	7-4-1	7-5-1	7-6-1	7-7-1	7-8-1	7-9-1	7-10-1
	Valor-P								
7-2-1		0,960	0,884	0,982	0,506	0,956	0,860	0,947	0,957
7-3-1	0,884		0,884	0,949	0,501	0,994	0,867	0,988	0,990
7-4-1	0,884	0,884		0,884	0,873	0,883	0,949	0,885	0,871
7-5-1	0,949	0,949	0,884		0,506	0,99	0,860	0,920	0,930
7-6-1	0,501	0,501	0,873	0,506		0,560	0,810	0,506	0,530
7-7-1	0,994	0,994	0,883	0,560	0,560		0,866	0,97	0,990
7-8-1	0,867	0,867	0,949	0,810	0,860	0,866		0,997	0,861
7-9-1	0,988	0,988	0,885	0,506	0,970	0,861	0,997		0,997
7-10-1	0,998	0,998	0,871	0,530	0,990	0,861	0,991	0,997	

Como se observa en la tabla 3.2, los valores del valor-P para todas las topologías comparadas es mayor al valor α (0,05). Por lo tanto, se acepta la hipótesis nula y se concluye que, para la selección de la mejor topología de red, es necesario recurrir a la comparación de otros parámetros estadísticos, ya que la prueba arrojó que no existen diferencias significativas entre las medianas de las topologías.

Al revisar los parámetros estadísticos se concluye que la arquitectura 7-6-1 es la que presenta el mejor comportamiento, ya que posee el menor valor de DEECM entre las nueve topologías, y por lo tanto tiene mayor capacidad de generalizar. Se analizó además el valor del coeficiente de correlación, arrojando la topología 7-6-1 el mayor valor, por lo que se le atribuyó una buena correlación entre los valores de eficiencia de calculados por los métodos tradicionales y los valores calculados por la red neuronal.

3.2. Comparación del modelo obtenido con otros modelos

Los resultados obtenidos a partir del modelo neuronal de siete neuronas en la capa de entrada, 6 neuronas en la capa oculta y 1 neurona en la capa de salida, se compararon con los resultados reportados en la literatura por Tapanes (2008) y Bueno (2009) bajo condiciones similares de operación en la caldera de la División Territorial de Comercialización de combustibles de Matanzas. En la figura 3.2 se muestran los resultados obtenidos para las 150 condiciones de operación recogidas en las bases de datos a partir del modelo neuronal, así como los resultados arrojados por el método indirecto de cálculo de eficiencia del generador vapor.

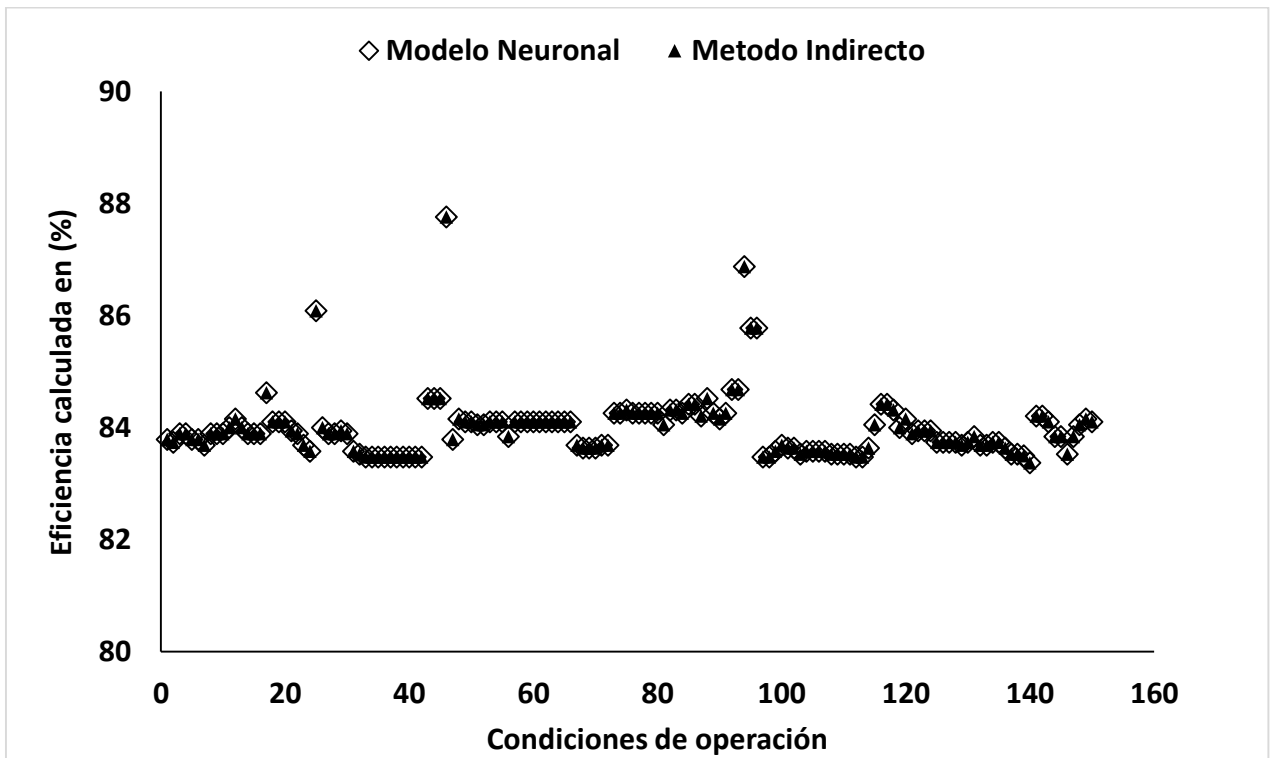


Figura 3.2. Comparación de los resultados arrojados por el modelo neuronal con el método indirecto de cálculo de eficiencia del generador de vapor

Como se observa en la figura los resultados de eficiencia del generador de vapor arrojados por la topología 7-6-1 del modelo neuronal se comportan de forma similar a los calculados por el método indirecto. El valor del coeficiente de correlación entre los valores de eficiencia reportados por Tapanes (2008) y los calculados por la red neuronal es de 0,9925.

3.3. Evaluación del comportamiento del modelo ante variaciones en las condiciones de operación

Teniendo en cuenta que las condiciones de operación del proceso de generación de vapor se pueden comportar de manera variable, fuera de los intervalos utilizados para el entrenamiento de la red, se realizó un análisis de sensibilidad para determinar la influencia de las condiciones de operación sobre la eficiencia del proceso.

3.3.1. Influencia de la temperatura de salida de los gases de combustión sobre la eficiencia del proceso

El modelo neuronal obtenido se utilizó para evaluar la incidencia de la variación de la temperatura de salida de los gases de combustión en el comportamiento de la eficiencia de generación de vapor. Se realizó un análisis de sensibilidad variando la temperatura de salida de los gases en el intervalo de 140 a 250 °C. Los resultados arrojados por el modelo se muestran en la figura 3.3.

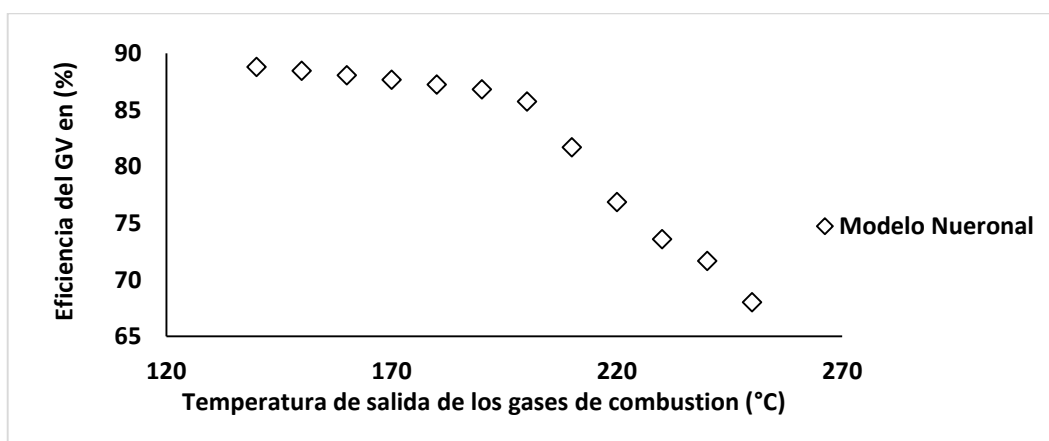


Figura 3.3. Comportamiento de la eficiencia del generador de vapor ante la variación de la temperatura de salida de los gases de combustión.

El valor de la eficiencia del generador de vapor está en relación inversa con la temperatura de salida de los gases como se muestra en la figura 3.3, pues a mayor temperatura de salida de los gases de combustión, menor es el calor aprovechado en el proceso, disminuyendo la eficiencia de generación. La temperatura depende del área de transferencia de calor instalada en sobrecalentadores, calentadores de aire, economizadores y/o combinaciones de estos. El hecho de obtener temperaturas de salida de los gases de chimenea bajas, trae como consecuencia el incremento excesivo de los costos de las superficies recuperativas a instalar.

3.3.2. Influencia de la temperatura del agua de alimentación sobre la eficiencia del proceso

El modelo neuronal obtenido se utilizó para evaluar la incidencia de la variación de la temperatura del agua de alimentación en el comportamiento de la eficiencia de generación de vapor. Se realizó un análisis de sensibilidad variando la temperatura del agua en el intervalo de 20 a 90 °C. Los resultados arrojados por el modelo se muestran en la figura 3.4.

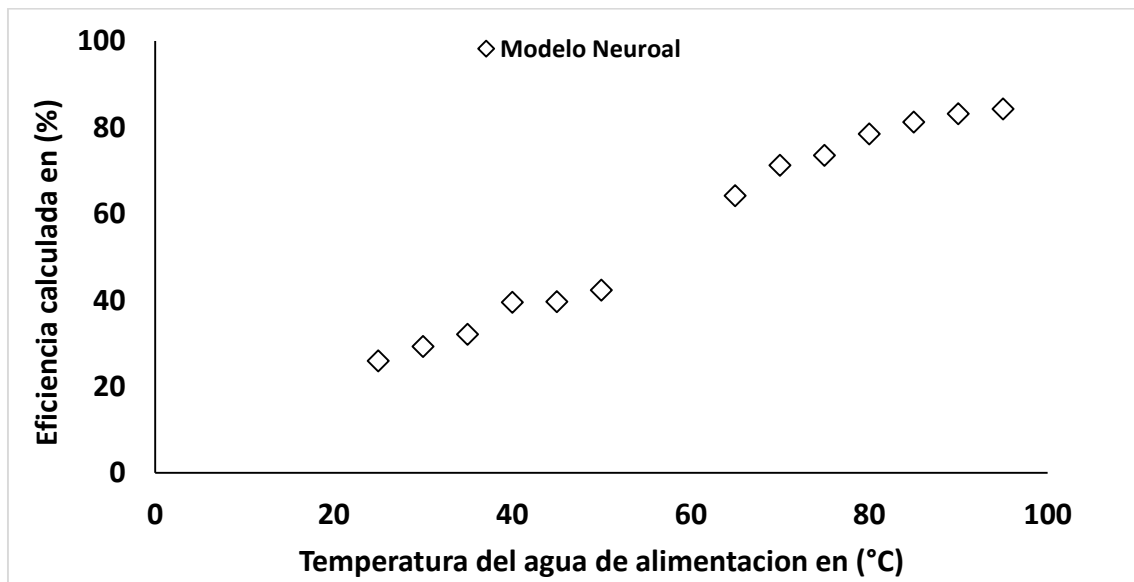


Figura 3.4. Comportamiento de la eficiencia del generador de vapor ante la variación de la temperatura del agua de alimentación.

Como se muestra en la figura 3.4, la eficiencia del generador de vapor aumenta con el aumento de la temperatura del agua de alimentación. Esto se debe a la relación inversamente proporcional entre la temperatura del agua de alimentación y el consumo de combustible del generador de vapor. Lo que se traduce en disminución de costos por conceptos de combustible, así como en la reducción de la emisión de gases contaminantes a la atmosfera.

CONCLUSIONES

1. Se obtuvo un modelo a partir de técnicas de inteligencia artificial mediante una red neuronal con topología 7-6-1, con un error cuadrático medio de $1,01 \cdot 10^{-4}$, una desviación estándar del error cuadrático medio de $1,05 \cdot 10^{-4}$.
2. El modelo obtenido presenta un buen grado de generalización ante otros modelos reportados en la literatura con un coeficiente de correlación de 0,9925.
3. Se modeló el comportamiento de la eficiencia de generación de vapor ante la variación de la temperatura del agua de alimentación, así como la temperatura de salida de los gases de combustión a partir del modelo de redes neuronales artificiales.

REFERENCIAS BIBLIOGRAFICAS

- Abroshan, H. (2020). An integrated model to study the effects of operational parameters on the performance and pollutant emissions in a utility boiler. *Journal of Thermal Engineering*, 6(4), 474-498.
- Andrade, R. S., Magalhaes, R., & Iglesias, M. (2016). Artificial neural network model to predict thermodynamic properties of low molar mass protic ionic liquid. *World Wide Journal of Multidisciplinary Research and Development*, 2(2), 1-6.
- Arencibia, E. (2010). *Predicción de Parámetros Meteorológicos en la zona del ISPJAE utilizando Redes Neuronales*. (Tesis de grado), Instituto Superior Politécnico "José Antonio Echeverría", La Habana.
- Arrieta, A., Andrés Adolfo, & Vélez, L. (2003). Análisis comparativo de eficiencia de combustión en un generador de vapor cuando se utiliza gas natural y diesel de caldera.
- Astocondor, J. (2010). Diseño e implementación de un neurocontrolador aplicado a una planta de posición y velocidad. *Facultad de Ingeniería Eléctrica y Electrónica: Universidad Nacional del Callao*, 27.
- Azari, A., Atashrouz, S., & Mirshekar, H. (2013). Prediction the vapor-liquid equilibria of CO₂-containing binary refrigerant mixtures using artificial neural networks. *International Scholarly Research Notices*, 2013.
- Barma, M., Saidur, R., Rahman, S., Allouhi, A., Akash, B., & Sait, S. M. (2017). A review on boilers energy use, energy savings, and emissions reductions. *Renewable and Sustainable Energy Reviews*, 79, 970-983.
- Behbahaninia, A., Ramezani, S., & Hejrandoost, M. L. (2017). A loss method for exergy auditing of steam boilers. *Energy*, 140, 253-260.
- Bueno, M. L. (2009). *Evaluación del Sistema de Generación de Vapor de la Caldera, en la Empresa Comercializadora de Combustibles Matanzas*. (Tesis presentada en opción al título de ingeniero químico), Universidad de Matanzas, Matanzas.
- Bujak, J. (2008). Mathematical modelling of a steam boiler room to research thermal efficiency. *Energy*, 33(12), 1779-1787.
- Demuth, H., Beale, M., & Hagan, M. (2008). *Neural network toolbox*: Mathworks.

- Dhanuskodi, R., Kaliappan, R., Suresh, S., Anantharaman, N., Arunagiri, A., & Krishnaiah, J. (2015). Artificial Neural Networks model for predicting wall temperature of supercritical boilers. *Applied Thermal Engineering*, 90, 749-753.
- Díez, L. I., Cortés, C., & Campo, A. (2005). Modelling of pulverized coal boilers: review and validation of on-line simulation techniques. *Applied Thermal Engineering*, 25(10), 1516-1533.
- Dorotić, H., Pukšec, T., & Duić, N. (2020). Analysis of displacing natural gas boiler units in district heating systems by using multi-objective optimization and different taxing approaches. *Energy Conversion and Management*, 205, 112411.
- Fast, M., Assadi, M., & De, S. (2008). *Application of artificial neural network to the condition monitoring and diagnosis of a CHP plant*. Paper presented at the ECOS 2008. 21st International Conference on Efficiency, Cost, Optimization, Simulation and Environmental Impact of Energy Systems.
- Ghaemi, A., Shahhoseini, S., Ghannadi Marageh, M., & Farrokhi, M. (2008). Prediction of vapor-liquid equilibrium for aqueous solutions of electrolytes using artificial neural networks. *Journal of Applied Sciences*, 8(4), 615-621.
- Hasini, H., Yusoff, M. Z., Shuaib, N. H., Boosroh, M. H., & Haniff, M. A. (2009). *Analysis of flow and temperature distribution in a full scale utility boiler using CFD*. Paper presented at the 2009 3rd International Conference on Energy and Environment (ICEE).
- Hernández, F. (2017). *Estimación de datos del equilibrio líquido-vapor utilizando redes neuronales artificiales para la mezcla binaria etanol-agua*. (Tesis de grado), Universidad Tecnológica de La Habana, La Habana.
- Hernández, J., Ferri, C., & Ramírez, M. (2004). *Introducción a la Minería de Datos*.
- Irwin, G., Brown, M., Hogg, B., & Swidenbank, E. (1995). Neural network modelling of a 200 MW boiler system. *IEE proceedings-Control theory and Applications*, 142(6), 529-536.
- Kaewboonsong, W., Kuprianov, V. I., & Chovichien, N. (2006). Minimizing fuel and environmental costs for a variable-load power plant (co-) firing fuel oil

and natural gas: Part 1. Modeling of gaseous emissions from boiler units. *Fuel processing technology*, 87(12), 1085-1094.

Kalogirou, S. A. (2000). Applications of artificial neural-networks for energy systems. *Applied energy*, 67(1-2), 17-35.

Karunnanithi, B., SHRINIWASAN, S., & BOGESHWARAN, K. (2014). Modeling of Vapor Liquid Equilibrium by Artificial Neural Networks. *International Journal of Computational Engineering Research*, 4(6).

Kljajić, M., Gvozdenac, D., & Vukmirović, S. (2012). Use of Neural Networks for modeling and predicting boiler's operating performance. *Energy*, 45(1), 304-311.

Lang, F. D. (2009). *Errors in boiler efficiency standards*. Paper presented at the ASME Power Conference.

Llanes, O. (2016). Pruebas no parametricas para hacer comparaciones en el diseno de experimentos en inteligencia computacional y minería de datos. *Paper presented at the Conferencia 2, Dpto. de Automatica y Computación, Universidad Tecnologica de La Habana "José Antonio Echeverría" (CUJAE)*.

Lopez, L. (2017). *Obtención de un modelo neuronal para la predicción de la concentración de etanol*. (Tesis de diploma), Universidad Tecnológica de La Habana, La Habana.

Lozano, M. A., Valero, A., & Serra, L. (1993). *Theory of exergetic cost and thermoeconomic optimization*. Paper presented at the Proceedings of the International Symposium ENSEC.

Masters, T. (1993). *Practical neural network recipes in C++*: Morgan Kaufmann.

Matich, D. J. (2001). *Redes Neuronales: Conceptos básicos y aplicaciones*. *Universidad Tecnológica Nacional, México*, 41.

Modliński, N., Szczepanek, K., Nabagło, D., Madejski, P., & Modliński, Z. (2019). Mathematical procedure for predicting tube metal temperature in the second stage reheater of the operating flexibly steam boiler. *Applied Thermal Engineering*, 146, 854-865.

- Moghadassi, A., Parvizian, F., Hosseini, S., & Fazlali, A. (2009). A new approach for estimation of PVT properties of pure gases based on artificial neural network model. *Brazilian Journal of Chemical Engineering*, 26, 199-206.
- Mojica, C., García, L., & Silva, R. (2020). Theoretical approach to Boiler's Efficiency and Performance Modeling. *MET&FLU*, 5.
- Morvay, Z., & Gvozdenac, D. (2008). *Applied industrial energy and environmental management* (Vol. 2): John Wiley & Sons.
- Nordelo, A. B., & González, A. R. (2010). *Combustión y generación de vapor*. Editorial Félix Varela.
- Ochoa, G. V. (2019). Energy optimization of industrial steam boiler using energy performance indicator. 670216917.
- Olabe, X. B. (1998). *Redes neuronales artificiales y sus aplicaciones*. Publicaciones de la Escuela de Ingenieros.
- Pose, M. (2009). *Introducción a las Redes de Neuronas Artificiales*. Departamento de Tecnologías de la Información y las Comunicaciones. Universidad da Coruña.
- Prieto, M., Montanes, E., & Menendez, O. (2011). Power plant condenser performance forecasting using a non-fully connected artificial neural network. *Energy*, 26(1), 65-79.
- Quintana, A. (2015). Implementación de un sistema de redes neuronales en matlab para la predicción del equilibrio líquido-vapor de mezclas binarias selectas. *Cartagena, Colombia: Universidad de San Buenaventura, Seccional Cartagena*.
- Romeo, L. M. (2006). Neural network for evaluating boiler behaviour. *Applied Thermal Engineering*, 26(14-15), 1530-1536.
- Rusinowski, H. (2007). Neural modelling of steam boilers. *Energy Conversion and Management*, 48(11), 2802-2809.
- Rusinowski, H. (2010). Hybrid model of steam boiler. *Energy*, 35(2), 1107-1113.

- Saha, P., Shoib, M., & Kamruzzaman, J. (1998). Development of a neural network based integrated control system of 120 ton/h capacity boiler. *Computers & electrical engineering*, 24(6), 423-440.
- Savargave, S. B., & Lengare, M. J. (2018). Modeling and optimizing boiler design using neural network and firefly algorithm. *Journal of Intelligent Systems*, 27(3), 393-412.
- Shojaee, S. A., Hezave, Z. A., Lashkarbolooki, M., & Shafipour, Z. S. (2014). Prediction of the binary density of the ILs+ water using back-propagated feed forward artificial neural network. *Chemical Industry and Chemical Engineering Quarterly*, 20(3), 325-338.
- Smrekar, J., Assadi, M., Fast, M., Kuštrin, I., & De, S. (2009). Development of artificial neural network model for a coal-fired boiler using real plant data. *Energy*, 34(2), 144-152.
- Tang, Z., Li, Y., & Kusiak, A. (2020). A deep learning model for measuring oxygen content of boiler flue gas. *IEEE Access*, 8, 12268-12278.
- Tapanes, Y. (2008). *Estudio de los parámetros operacionales en la generación de vapor en la Empresa Comercializadora de Combustibles de Matanzas*. (Tesis presentada en opción al Título de Master en Termoenergética Industrial.), Universidad de Matanzas.
- Teixeira, C. (2014). *Uma aplicação de redes neurais na instrumentação virtual do grau alcoólico no processo industrial de produção do etanol*. Tesis de Maestría, Universidade de São Paulo, São Carlos. Brasil.
- Terhan, M., & Comakli, K. (2017). Energy and exergy analyses of natural gas-fired boilers in a district heating system. *Applied Thermal Engineering*, 121, 380-387.
- Tognoli, M., Najafi, B., & Rinaldi, F. (2018). Dynamic modelling and optimal sizing of industrial fire-tube boilers for various demand profiles. *Applied Thermal Engineering*, 132, 341-351.
- Trojan, M. (2019). Modeling of a steam boiler operation using the boiler nonlinear mathematical model. *Energy*, 175, 1194-1208.
- Valderrama, J. O., Reategui, A., & Rojas, R. E. (2009). Density of ionic liquids using group contribution and artificial neural networks. *Industrial & engineering chemistry research*, 48(6), 3254-3259.

- Villanueva, M. d. (2002). Las redes neuronales artificiales y su importancia como herramienta en la toma de decisiones. *Trabajo de Investigacin-Universidad Nacional Mayor de San Marcos. Facultad de Ciencias Matematicas.*
- Ye, N. (2003). *The handbook of data mining*: CRC Press.
- Zhang, R., Yang, H., Hu, N., Lu, J., & Wu, Y. (2013). Experimental investigation and model validation of the heat flux profile in a 300 MW CFB boiler. *Powder technology, 246*, 31-40.
- Zhao, J., Duan, Y., & Liu, X. (2019). Study on the policy of replacing coal-fired boilers with gas-fired boilers for central heating based on the 3E system and the TOPSIS method: A case in Tianjin, China. *Energy, 189*, 116206.
- Zhou, J., Deng, S., Turner, W., Claridge, D., & Haberl, J. (2002). Improving boiler efficiency modeling based on ambient air temperature.