

EXPLORACIÓN EN EL DIMENSIONAMIENTO DE SISTEMAS DE ENERGÍA SOLAR TÉRMICA PARA ACS USANDO REDES NEURONALES ARTIFICIALES.

Sánchez, Luisa Fernanda^{1} y González-Salcedo, Luis Octavio^{1*}*

¹Universidad Nacional de Colombia Sede Palmira, Facultad de Ingeniería y Administración, Grupo de Investigación en Eficiencia Energética y Energías Alternativas – GEAL, Palmira, Colombia.

Recibido noviembre 2020; aceptado diciembre 2020

Abstract

Thermal systems that include the use of solar collectors are used for heating water with solar energy. The most common collector for this type of application is the flat plate collector. The thermal system design process involves, among other aspects, the dimensioning of the collector surface area, which is determined from environmental conditions, available solar energy conditions, geographical location, collector placement conditions, the water demand, and manufacturing characteristics of the collector; as well as design protocols that are standardized. In the present work the use of artificial neural networks as a technological tool in the dimensioning of the collecting area is explored. To evaluate the reliability of the estimation, the linear correlation factor R was used as a performance indicator. The results show that the estimation using the elaborated technique is reliable and can be used in a generalized way.

Resumen

Para el calentamiento de agua con energía solar, se usan sistemas térmicos que incluyen el uso de colectores solares siendo los más comunes para este tipo de aplicación, los colectores de placa plana. El proceso de diseño del sistema térmico involucra entre otros aspectos, el dimensionamiento del área de la superficie colector, la cual se determina a partir de las condiciones ambientales, condiciones de energía solar disponible, ubicación geográfica, condiciones de colocación del colector, demanda de agua, y características de fabricación del colector; y protocolos de diseño que están estandarizados. En el presente trabajo se explora el uso de redes neuronales artificiales como herramienta tecnológica en el dimensionamiento del área colector. Para evaluar la confiabilidad en la estimación se usó como indicador de desempeño, el factor de correlación lineal R. Los resultados muestran que la estimación usando la técnica elaborada es confiable y puede ser usada de manera generalizada.

Key words: Solar Energy, Photothermic Use, Domestic Hot Water (DHW), Flat Plate Collector (fpc), Artificial Neural Networks, Artificial Intelligence.

Palabras clave: Energía Solar, Aprovechamiento fototérmico, Agua Caliente Santitaria (ACS), Colector de Placa Plana (cpp), Redes Neuronales Artificiales, Inteligencia Artificial.

I. INTRODUCCIÓN

Las energías alternativas o no convencionales corresponden a aquellas que no se derivan de los hidrocarburos, siendo estas solar, eólica, biomasa, geotérmica, maremotriz, hidráulica y nuclear (Castillo *et al.*, 2015). La energía solar se puede aprovechar de manera directa o indirecta, y de forma directa dos aplicaciones se derivan, el aprovechamiento fototérmico y el aprovechamiento fotovoltaico. En el primero, la energía por radiación es convertida en energía calorífica y las aplicaciones más conocidas corresponden al calentamiento de agua para usos domésticos, lo cual es conocido como agua caliente solar (Lavorde y Williams, 2016).

El agua caliente solar o agua calentada por sistemas solares, se refiere al calentamiento del agua caliente sanitaria – ACS, utilizando la energía solar por diversos métodos. Para tal fin, se utilizan dispositivos diseñados para colectar la energía recibida por el sol, que elevan la temperatura del fluido que circula dentro de este dispositivo. Estos dispositivos se denominan colectores solares, y se disponen de tal forma que su orientación se realiza hacia la dirección del eje ecuatorial, es decir en el hemisferio norte se orientarán hacia el sur, y en el hemisferio sur hacia el norte. En las aplicaciones más comunes, de uso doméstico, de más fácil instalación y menor costo, utilizan colectores que consisten en superficies planas por la que discurre una tubería

* Autor para correspondencia: lufsanchez@unal.edu.co, logonzalezsa@unal.edu.co

por la que discurre el agua que se ha de calentar; este conjunto superficie – tubería son o están pintados de color negro, que absorbe la radiación solar. Este colector se denomina colector de placa plana – cpp (Moreno, 2013).

El rendimiento de los colectores de placa plana depende de varios factores (Ávila *et al.*, 2010): 1. La insolación, horas del sol y situación geográfica; 2. La adecuada colocación del colector, orientación, inclinación y ausencia de elementos que les de sombra; 3. Las pérdidas hacia el ambiente exterior, debidas por las diferencias de temperatura entre el exterior (ambiente) y el interior (dentro del colector); entre otras. Un cpp no es tecnológicamente complejo y aunque su margen de evolución es muy limitado, consiguen en la actualidad captar más del 95% de la energía recibida del sol, superando el rendimiento de los dispositivos de aprovechamiento fotovoltaico, los paneles solares fotovoltaicos, que convierten directamente la energía por radiación en energía eléctrica, y que comúnmente está entre 15-20%. Así mismo, se estima que el 80% del consumo energético de una vivienda se produce en forma de agua caliente a baja temperatura, con aplicaciones en calefacción y ACS.

El diseño de sistemas de energía solar térmica para ACS, incluye el dimensionamiento de la superficie colectora usando cpp; para lo cual dependiendo del consumo de agua caliente, las condiciones de temperatura ambiente y del agua en la red, las condiciones de ubicación geográfica (latitud, calidad del aire, factores de corrección por latitud e inclinación), las propiedades características del colector expresadas en su ecuación de rendimiento, y la determinación mensual de las necesidades energéticas que serán suplidas por la energía solar disponible, conlleva al cálculo del área de la superficie colectora representada en unidades de cpp seleccionados (Vásquez, 2011). Este procedimiento que puede ser sistematizado, incluso en hojas electrónicas, incorpora entonces variables que dependen de la tipología del colector (propiedades de los materiales, dimensiones), de las condiciones externas (condiciones medioambientales, fluido caloportador) y de las variables medibles (pérdida de energía térmica, factores de eficiencia, eficiencia global), requiriendo la disponibilidad de la información, su conocimiento y posterior aplicación en el procedimiento de diseño.

El proceso de diseño de sistemas de energía solar térmica para ACS y su automatización, particularmente usando software para tal fin, crean la necesidad de estrategias que permitan recurrir a las variables mencionadas, conllevando a la herramienta computacional a un costo informático relacionado con operaciones de programación, codificación, memoria y tiempo de utilización – resolución del problema, planteando entonces la búsqueda de aplicaciones relacionadas con el aprendizaje de máquinas que faciliten la operación final de calcular el área de la superficie colectora. Este problema que se plantea crea un campo fértil de aplicación de la Inteligencia Artificial, a partir de técnicas de estimación basadas en redes neuronales artificiales.

Por su parte, la Inteligencia Artificial, término acuñado en 1956, es la rama científica que combina las matemáticas y la computación para crear “máquinas inteligentes” capaces de resolver problemas que el ser humano resuelve tanto de manera cotidiana como de manera especializada, a partir de la incorporación en estas máquinas de diversas técnicas que “las conviertan en inteligentes” (Ponce, 2010). Una de sus técnicas son las redes neuronales artificiales, que corresponden a sistemas conexionistas en los cuales un modelo computacional se inspira en el aprendizaje de las neuronas biológicas del cerebro humano (Figura 1), y son definidas como excelentes reconocedores de patrones que pueden resolver problemas puntuales y adaptarse a situaciones según su entrenamiento, generando excelentes resultados (Tabarquino *et al.*, 2016). Diversas aplicaciones de redes neuronales artificiales han sido desarrolladas para explorar el dimensionamiento de áreas colectoras en sistemas de ACS, siendo algunas simples en la consideración de las variables a reconocer, pero que limitan su uso para condiciones generales, y algunas más complejas que consideran todas las variables de diseño, pero que requieren de la información de dichas variables (Sánchez, 2020).

En el presente estudio, se explora el uso de redes neuronales artificiales con arquitectura multicapa, alimentación de información hacia adelante y metodología de aprendizaje/ajuste del error hacia atrás, denominadas como Perceptrón Multicapa feedforward – backpropagation, en el dimensionamiento de sistemas de energía solar térmica para ACS. Estas herramientas de inteligencia artificial fueron entrenadas para predecir el área de la superficie colectora basado en colectores de placa plana, dispositivo que es identificado a partir de su curva de rendimiento. El desempeño de las redes neuronales basado en el coeficiente de correlación lineal ($R > 0.97$) muestra una herramienta confiable en la resolución del problema planteado del área de la superficie colectora requerida y potencia su uso como componente informático del software para el dimensionamiento de sistemas de energía térmica para ACS.

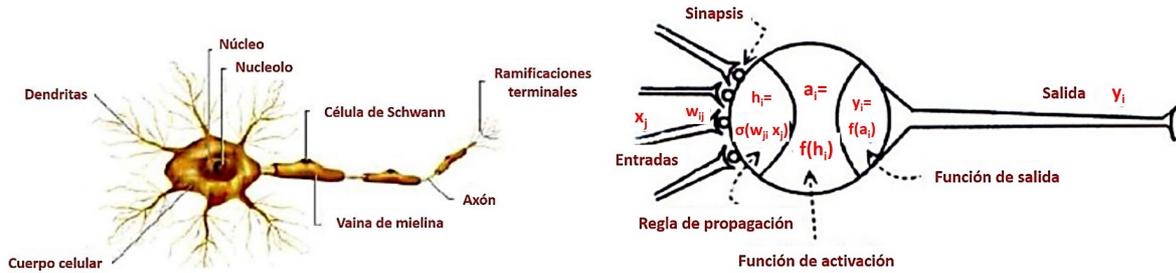


Figura 1. Neurona artificial (derecha) emulada a partir de la neurona biológica

II. MATERIALES Y MÉTODOS

Condiciones experimentales

Ubicación geográfica del campo de exploración

El estudio se realizó para ubicaciones geográficas localizadas en el hemisferio norte, considerando como referencia de dicha ubicación la latitud, expresada como la distancia angular entre la línea ecuatorial y un punto determinado de la Tierra, en dirección norte, medida a lo largo del meridiano en el que se encuentra el punto, expresándose en medidas angulares que varían desde los 0° del Ecuador hasta los 90°N del polo norte.

Construcción del conjunto de entrenamiento de las redes neuronales artificiales

Para el entrenamiento de las redes neuronales artificiales se prepara una base de datos conformada por patrones o vectores de información, que le permiten al modelo de predicción hacer el reconocimiento de las relaciones que existen entre las neuronas (variables) de entrada que conllevan al resultado de la neurona a predecir (variable de salida). Para tal fin, de acuerdo con el protocolo de diseño de sistemas de energía solar térmica para ACS propuesto por CENSOLAR (Castro, 2008), se hace una selección de variables de entrada relevantes en el problema de dimensionamiento (determinación del área) de la superficie colectora en sistemas de aprovechamiento de la energía solar para calentamiento de agua.

Estas son las siguientes: Latitud en grados [LAT], consumo anual promedio en m³ [Q], temperatura del agua en la red en °C [Ta], Irradiación solar horizontal promedio en MJ/m²/día [H], término independiente de la curva de eficiencia del colector solar a usar [b], pendiente de la curva de eficiencia del colector solar a usar [m], factor de corrección de H acorde al entorno [fk], siendo 1.05 para ambientes libres de polución, 0.95 para ambientes urbanos, y la inclinación de la superficie colectora en grados [I]. Como variable de salida se asocia a esta información para cada patrón, el área de la superficie colectora en m² [A].

Posterior a la determinación de las variables de entrada y de salida, se realiza la elaboración de la base de datos general con la cual se determina el conjunto de entrenamiento, conformado por 100 vectores de información (variables de entrada y de salida), usando el protocolo de diseño propuesto por CENSOLAR (Castro, 2008).

Elaboración y entrenamiento de las redes neuronales artificiales para la estimación del área colectora en sistemas de energía solar térmica para ACS

Se usa el conjunto de entrenamiento mencionado en la sección 3.2, en el cual se relacionan las variables de entrada con la variable de salida, se elabora una propuesta de red neuronal artificial y se plantea una arquitectura neuronal artificial multicapa alimentada hacia adelante y con metodología de entrenamiento/aprendizaje hacia atrás (Figura 2), denominada Perceptrón Multicapa de feedforward – backpropagation y cuyas características han sido definidas en la literatura (Hinton, 1988). La arquitectura multicapa se propone con una capa de entrada, una capa oculta y una capa de salida, y se fija el límite superior del número S de neuronas de la capa oculta usando la ecuación 1 (González *et al.*, 2017):

$$S < (N_{\text{data}} - 1)/(n + 3) \quad (1)$$

Donde, S es el límite superior del número de neuronas de la capa oculta, N_{data} es el número de patrones de entrenamiento (900), n es el número de variables consideradas en el problema a resolver (entradas y salida, 9). De acuerdo con la ecuación 1, se fija el límite S , como 75 neuronas en la capa oculta.

Las conexiones entre neuronas de las capas se representan mediante funciones de activación. Así, la conexión entre neuronas de la capa de entrada a la capa oculta se realiza por medio de la función sigmoidea. Por su parte, la conexión entre la capa oculta y la neurona a estimar, ubicada en la capa de salida, se hace usando la función lineal, de tal manera que se permita la comparación de la estimación y el resultado verdadero, como se describe en el entrenamiento supervisado.

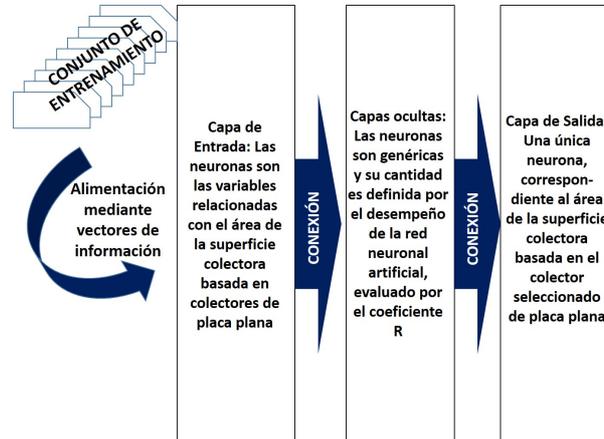


Figura 2. Propuesta de red neuronal artificial para la estimación del área de la superficie colectora basada en un colector de placa plana seleccionado

El procedimiento de entrenamiento para el conjunto respectivo se realizó, de acuerdo con lo descrito por Sánchez (2020), con 84 conformaciones de topologías de redes neuronales artificiales, obtenidas del producto entre 12 métodos entrenamiento de backpropagation y 7 arquitecturas de neuronas en la capa oculta. Dichas conformaciones se evaluaron a partir del coeficiente de correlación lineal R , obtenido en la ecuación 2 (Tabarquino *et al.*, 2016), estadístico usado para evaluar la calidad del desempeño de las redes neuronales artificiales supervisadas. Para el funcionamiento computacional del procedimiento de entrenamiento se codificó un algoritmo usando el lenguaje de programación M , propio de la herramienta del software MATLAB® para plataforma Windows®. El código usa la librería contenida en el Neural Networks Toolbox del mismo software, lo cual permite implementar los modelos del tipo de red que se ha descrito.

$$R = \sqrt{1 - ((\sum_{i=1, n} (A_{real, i} - A_{estimado, i})^2) / (\sum_{i=1, n} (A_{real, i})^2))} \quad (2)$$

Donde, $A_{real, i}$ es el área de la superficie colectora obtenida mediante el protocolo de diseño propuesto por CENSOLAR (Castro, 2008), $A_{estimado, i}$ es el área de la superficie colectora estimada por la red neuronal artificial, i corresponde a la posición del par de datos correlacionados y, n corresponde al total de datos en cada subconjunto que se describen a continuación. Los 100 vectores de información del conjunto de entrenamiento se categorizaron en tres subconjuntos que conformaron igual número de fases en el entrenamiento de la red neuronal: 1.- de aprendizaje, en donde se configuran los pesos sinápticos en las conexiones entre las neuronas; 2.- de prueba, con lo cual se determinó en el que debe dejar de entrenar y optimizar la estructura de la red neuronal y las especificaciones del modelo interno, de acuerdo con el método de aprendizaje que usa el algoritmo de backpropagation; y 3.- de validación, se dónde se probó la capacidad de generalizar el modelo para el rango de información que se utilizó para la calibración.

A partir del indicador de desempeño se evaluaron las estimaciones de las redes neuronales y las salidas reales de la base de datos, en los subconjuntos de cada fase de entrenamiento (aprendizaje, prueba, validación, y adicionalmente de simulación con el total de datos, para lo cual se consideraron el 60, 20, 20 y 100% de los datos, respectivamente, y agrupados por división aleatoria de los datos).

Los resultados de este proceso mostraron que para este caso de estudio, la arquitectura con una capa oculta de 70 neuronas, y con el método de aprendizaje de Levenberg-Marquardt obtuvo mejor, adecuado y confiable desempeño ($R > 0.97$) que los demás métodos de entrenamiento usados (Regularización Bayesiana, Cuasi-Newton de Algoritmo BFGS (Broyden-Fletcher-Goldfarb-Shanno), Retro-propagación Resiliente, Gradiente Conjugado Escalonado, Gradiente Conjugado con Reinicio de Powell-Beale, Gradiente Conjugado

de Fletcher-Powell, Gradiente Conjugado de Pollak-Ribière, Secante de un Paso, Gradiente Descendiente con Tasa de Aprendizaje Variable, Gradiente Descendiente con Momento, y Gradiente Descendiente). De esta manera, arquitectura de la mejor red neuronal se configuró entonces con una capa de entrada con ocho variables de entrada, una capa oculta con 70 variables, y una capa de salida con una variable de respuesta, y algoritmo de aprendizaje backpropagation de Levenberg-Marquardt (Figura 3).

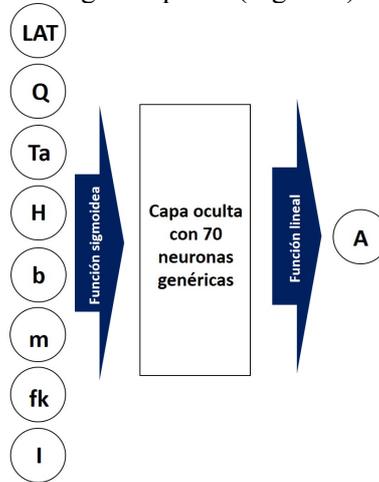


Figura 3. Red neuronal artificial seleccionada para la estimación del área de la superficie colectora basada en un colector de placa plana seleccionado

III. RESULTADOS Y DISCUSIÓN

A partir del paradigma de la Inteligencia Artificial basado en redes neuronales, se elabora una red neuronal artificial supervisada del tipo Perceptrón Multicapa, con alimentación hacia adelante y entrenamiento/aprendizaje para la propagación del error hacia atrás, se realizó la estimación del área de la superficie colectora, usando colectores de placa plana, en el dimensionamiento de sistemas de energía solar térmica para ACS. La red neuronal artificial consistió en una red conformada con una capa de entrada con 8 variables de entrada, una capa oculta con 70 neuronas, una capa de salida con una variable de respuesta correspondiente a la estimación del área de la superficie colectora y algoritmo de aprendizaje de Levenberg-Marquardt.

La Figura 4 muestra los resultados de desempeño de la red neuronal artificial seleccionada para resolver el caso de estudio y para cada una de las etapas de entrenamiento (entrenamiento, prueba, validación computacional y, simulación con todo el conjunto de entrenamiento). Para las etapas donde la red seleccionada estima el área de la superficie colectora, se hace una comparación entre el resultado obtenido por la red neuronal artificial (output) y el valor obtenido usando el protocolo de diseño (target), para lo cual se asocia a dicha comparación el factor de correlación lineal R.

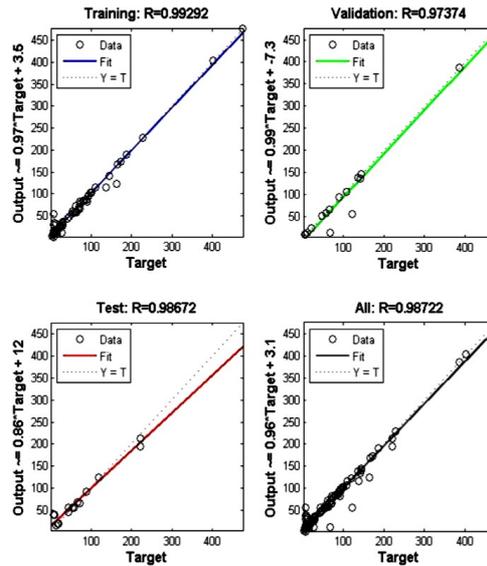


Figura 4. Resultados de desempeño para la red neuronal artificial entrenada para estimar el área de la superficie colectora basada en un colector de placa plana seleccionado, usando el coeficiente de correlación lineal R entre el área de la superficie colectora obtenida con el protocolo de diseño y el estimado por la red neuronal para cada fase de entrenamiento (entrenamiento, prueba, validación y simulación con todos los datos)

Este desempeño basado en el factor de correlación lineal R ($R > 0.97$) muestra una relación lineal positiva fuerte entre el valor del área de la superficie colectora obtenida a partir del protocolo de diseño y el obtenido mediante la predicción de la red neuronal seleccionada (Castro, 2008), lo cual permite inferir que la herramienta computacional es adecuada y confiable para hacer dichas estimaciones. El valor del coeficiente de correlación lineal R muestra que hay una aproximación del resultado obtenido por predicción, lo cual verifica la bondad en el ajuste de dicha predicción (Figura 5), permitiéndose inferir que el modelo computacional basado en la red neuronal artificial puede ser usado como metodología para el dimensionamiento de sistemas de energía solar térmica para ACS, para el caso de estimación del área de la superficie colectora basada en colectores de placa plana (Castro, 2008).

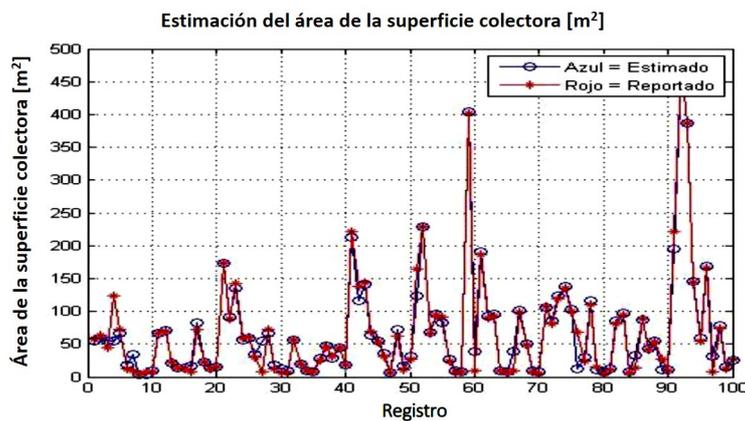


Figura 5. Comparación gráfica de los resultados entregados por la red neuronal artificial y los obtenidos por el protocolo de diseño

La literatura reporta diversos trabajos sobre diseño de sistemas de energía solar térmica y en particular su aprovechamiento para calentamiento de agua, mediante el desarrollo de modelos matemáticos, el uso de software para modelado de procesos, la metodología de superficies de respuesta y las redes neuronales artificiales. En dichos reportes se busca, en algunos casos, comprender el proceso de intercambio de calor, la resistencia de diversos materiales y como operan en diferentes latitudes.

Con respecto al uso de redes neuronales artificiales, Cáceres (2015) realiza el diseño y optimización de colectores solares para ACS a utilizar en zonas del Ecuador, a partir de uso de redes neuronales de

backpropagation del software Neurosolution, para estimar el coeficiente global de pérdidas térmicas, $R = 0.977$ (considerando 15 variables de entrada), el factor de eficiencia de la sección, $R = 0.995$, y el factor de remoción de calor, $R = 0.996$ (considerando 9 variables de entrada), y la temperatura de salida del fluido, $R = 0.972$, el calor útil, $R = 0.987$, y la eficiencia global del colector, $R = 0.989$ (considerando 10 variables de entrada). Valle (2009) estudia el comportamiento dinámico de un sistema de calentamiento solar de aire usando redes neuronales artificiales, para lo cual considera 7 variables de entrada las cuales correlaciona con la estimación la temperatura de aire a la salida del colector, obteniendo un coeficiente de correlación lineal $R = 0.97$. Díez & Falagán (2013a, 2013b), reportan el modelado de un captador solar usando redes neuronales artificiales, con las cuales estiman la temperatura del agua a la salida del colector considerando cuatro variables de entrada (Irradiación solar, temperatura ambiente, temperatura del agua a la entrada del colector y caudal de agua bombeado), sin especificar el coeficiente de correlación lineal.

Para la red neuronal artificial elaborada en el presente estudio y entrenada para estimar la superficie colectora de un sistema de energía solar térmica para ACS, su resultado de desempeño evaluado a partir del coeficiente de correlación lineal R , muestra que esta estimación es concordante con diversos trabajos mencionados y desarrollados para la temática del uso de redes neuronales artificiales y estimaciones relacionadas con parámetros del calentamiento de agua con energía solar; esto permite inferir que la red neuronal artificial propuesta puede ser usada confiablemente como herramienta de predicción en el dimensionamiento de sistemas de energía solar térmica para ACS y, en particular, en la determinación del área de la superficie colectora basada en colectores de placa plana. Sin embargo, para la temática de redes neuronales artificiales, no se evidencian trabajos para el dimensionamiento del área colectora en aplicaciones de aprovechamiento de energía solar para ACS.

IV. CONCLUSIONES

El trabajo permite mostrar el entrenamiento de una red neuronal artificial, que corresponde a una red multicapa feedforward-backpropagation, para ser usada en el dimensionamiento de sistemas de energía solar térmica para ACS, en este caso para la estimación del área de la superficie colectora basada en colectores de placa plana; la red neuronal artificial generaliza adecuadamente los resultados que se obtienen en los protocolos convencionales de diseño. Los resultados obtenidos permiten trazar las siguientes conclusiones y recomendaciones para futuras agendas:

- El indicador de desempeño considerado, el factor de correlación lineal R , muestra que la red neuronal artificial es confiable para la estimación del área de la superficie colectora basada en colectores de placa plana, para el problema de dimensionamiento de sistemas de energía solar térmica para ACS, acorde a los resultados que se obtendrían con los métodos convencionales de diseño.
- La consideración en la red neuronal artificial de variables que identifican la ubicación geográfica del proyecto (latitud) y las condiciones de disposición del colector (inclinación del colector), en conjunto con el resultado del indicador de desempeño, muestran la capacidad de la red de relacionar estas variables con la influencia que tienen sobre el valor de la energía por radiación disponible, como se establece en los protocolos de diseño. Esto evidencia lo reportado en la literatura, sobre la capacidad como reconocedora de patrones la tecnología neuronal artificial, generando así una herramienta de predicción universal en el problema abordado.
- La exploración realizada permite potenciar el uso de la red neuronal artificial para su uso como herramienta computacional para procesos de sistematización del protocolo de diseño, por ejemplo, como componente lógico en el aprendizaje de máquinas para tal fin.
- Se abre una agenda futura de investigación y desarrollo informático, al extender el uso de redes neuronales artificiales en el dimensionamiento de sistemas de energía solar térmica para ubicaciones generales (hemisferio norte y hemisferio sur), y de otras tipologías de colectores.

V. REFERENCIAS

Ávila, A. E., Mendoza, J. M., & Beltrán, J. F. (2010). Evaluación energética de un colector solar de placa plana de doble cubierta. *Ingeniería & Desarrollo*, 27, 93-112.

- Cáceres, M.A. (2015). Modelamiento basado en tecnologías de redes neuronales artificiales para el diseño y optimización de colectores solare utilizados para el calentamiento de agua sanitaria en zonas del Ecuador. Escuela Politécnica Nacional.
- Castillo, Y., Castrillón, M., Vanegas-Chamorro, M., Valencia, G., & Villicaña, E. (2015). Rol de las fuentes no convencionales de energía en el sector eléctrico colombiano. *Prospect*, 13(1), 39-51.
- Castro, M., & Colmenar, A. (2008). Energía solar térmica de baja temperatura. CENSOLAR.
- Díez, F.J. & Falagán, J.L. (2013a). Sistemas solares térmicos. Modelado del captador mediante redes neuronales artificiales (I). *Era Solar*, 176: 26-34.
- Díez, F.J. & Falagán, J.L. (2013b). Sistemas solares térmicos. Modelado del captador mediante redes neuronales artificiales (II). *Era Solar*, 177: 42-54.
- González-Salcedo, L. O., Gotay-Sardinas, J., Roodschild, M., Will, A. L., & Rodríguez, S. (2017). Optimización en la elaboración de redes neuronales artificiales usando una metodología de algoritmo de poda. *Ingenio Magno*, 44-56.
- Hinton G. (1988). Connectionist learning procedures. *Artificial Intelligence*, 40(1-3), 185-234.
- Lavorde, M. A., & Williams, R. J. (2016). Energía Solar. Academia Nacional de Ciencias Exactas, Físicas y Naturales.
- Moreno, A. M. (2013). Proyecto de una instalación de energía solar para la producción de agua caliente sanitaria en un edificio de viviendas. Universidad de Sevilla.
- Ponce, P. (2010). Inteligencia Artificial con aplicaciones a la ingeniería. Alfaomega Grupo Editor.
- Sánchez, L. F. (2020). Elaboración de un modelo neuronal artificial para el diseño de sistemas de calentamiento de agua con energía solar. Universidad Nacional de Colombia Sede Palmira.
- Tabarquino, V. H., González, L. O., & Will, A. L. (2016). Estimación del volumen de un biodigestor tipo balón usando redes neuronales artificiales. *Informador Técnico*, 80(1), 41-48.
- Valle, J.R. (2009). Modelación de un sistema de calentamiento solar de aire mediante redes neuronales. Universidad Autónoma de Baja California Sur.
- Vásquez, G. (2011). Manual de instalaciones de fontanería, evacuación y saneamiento y energía solar en edificación. Universidad Politécnica de Cartagena.