



UNIVERSIDAD AUTÓNOMA DE YUCATÁN

FACULTAD DE INGENIERÍA

UNIDAD DE POSGRADO E INVESTIGACIÓN

**MODELACIÓN DE UN SISTEMA DE
CONCENTRADORES SOLARES DE CANAL
PARABÓLICO EMPLEANDO REDES NEURONALES
ARTIFICIALES**

TESIS

PRESENTADA POR:

I.F. OSCAR DE JESÚS MAY TZUC

EN OPCIÓN AL GRADO DE:

MAESTRO EN INGENIERÍA

OPCIÓN ENERGÍAS RENOVABLES

MÉRIDA, YUCATÁN, MÉXICO

2016

Aunque este trabajo hubiere servido para el Examen Profesional y hubiere sido aprobado por el sínodo, sólo el autor es responsable de las doctrinas emitidas en él.

AGRADECIMIENTOS

A la Facultad de Ingeniería de la Universidad Autónoma de Yucatán por haber facilitado las instalaciones para el desarrollo de este trabajo.

Al Instituto de Energías Renovables de la Universidad Autónoma de Yucatán por haber proporcionado los datos experimentales mediante los cuales se desarrolló este proyecto.

Al Consejo Nacional de Ciencia y Tecnología (CONACYT) por su apoyo y patrocinio para la realización de este trabajo de titulación de posgrado.

RESUMEN

El presente trabajo se centra en el desarrollo de un modelo matemático capaz de predecir la eficiencia térmica correspondiente a un arreglo de Concentradores Solares de Canal Parabólico (CCPs). Para la generación del modelo matemático se empleó un esquema basado en Redes Neuronales Artificiales (RNAs) utilizando el software de cálculo matemático MATLAB a través de su herramienta ANN (Artificial Neural Network). Los datos para llevar a cabo el entrenamiento de la Red Neuronal Artificial (RNA) fueron proporcionados por el Instituto de Energías Renovables de la Universidad Nacional Autónoma de México (IER-UNAM), correspondientes a una planta generadora de calor de baja entalpía. Para tal propósito, una metodología computacional fue desarrollada e implementada para la obtención del modelo matemático óptimo para la predicción de la eficiencia térmica. Como resultado de lo anterior un modelo RNA de tres capas fue exitosamente entrenado a partir de las mediciones experimentales. El ángulo de borde (φ_r), la temperatura de entrada del fluido a los CCPs (T_{ent}), la temperatura de salida (T_{sal}), la temperatura ambiente (T_{amb}), el flujo de agua (F_w), la radiación solar directa (G_b) y la velocidad del viento (V_w) fueron empleadas como las principales variables de entrada para el proceso de entrenamiento de la RNA en la estimación de la eficiencia térmica. Para el proceso de optimización de la RNA fueron empleados el algoritmo de aprendizaje Levenberg-Marquardt (LM) y las funciones de transferencia Sigmoidea Tangente-Hiperbólica y la función lineal. El mejor ajuste de regresión lineal fue obtenido utilizando ocho neuronas en la capa oculta con lo cual fue posible predecir la eficiencia térmica con rango de aproximación satisfactoria ($R^2 = 0.99998$). Una exactitud adecuada del modelo de RNA se obtuvo con Error Porcentual Medio Absoluto (MAPE) de 0.3%. De igual manera, todas las estimaciones

de eficiencia térmicas con el nuevo modelo de red fueron analizadas estadísticamente y comparadas con los valores de eficiencia calculados de manera experimental. Posteriormente un conjunto de datos imparciales fueron empleados para realizar el proceso de validación del modelo RNA obtenido con el fin de evitar sesgos. Las estimaciones de eficiencia térmica inferidas a partir del proceso de validación RNA se encuentra en concordancia ($R^2 = 0.99998$) con los datos experimentales reportados, sugiriendo así que el nuevo modelo por RNA podría ser utilizado como una herramienta para la predicción fiable de la eficiencia térmica en CCPs.

ABSTRACT

The present work focusses in the development of a mathematical model able to predict the thermal efficiency of a Parabolic Trough Solar Concentrator (PTC) array. To realize the mathematical model generation a system based on Artificial Neural Network (ANN) will be used employing the mathematical software MATLAB and its toolbox ANN. The data to carry out the training by ANN will be provided the Renewable Energy Institute from Autonomus National University of Mexico (IER-UNAM), corresponding to a low enthalpy steam generation plant. a computational methodology was developed and implemented for the obtention of optimal thermal efficiency prediction mathematical model. As a result a three-layer ANN architecture was trained using experimental database obtained during the PTCs operations process. Rim angle (φ_r), inlet (T_{ent}) and outlet (T_{sal}) fluid temperatures of PTCs, ambient temperature (T_{amb}), water flow (F_w), direct solar radiation (G_b) and the wind velocity (V_w) were used as main input variables for the ANN training process to estimate the efficiency. For the ANN optimization process, the Levenberg-Marquardt (LM) learning algorithm, the hyperbolic tangent sigmoid transfer-function and the linear transfer-function were used. The best fitting training data set was obtained with an ANN architecture composed by eight neurons in the hidden layer, which made possible to predict the thermal efficiency with a satisfactory efficiency ($R_2 = 0.99998$). A suitable accuracy of the ANN model was achieved with a mean absolute percentage error (MAPE) of 0.3%. All the thermal efficiency estimates predicted with the new ANN model were statistically analysed and compared with experimental thermal efficiency calculated in the experiments. An unbiased experimental data sets were employed to validate the new ANN model and for avoiding bias. The thermal efficiency estimates inferred from the ANN validation process were in good

agreement ($R_2 = 0.99998$) with the experiments data reported, thus suggesting that the new model for ANN could be used as a tool for reliable prediction of the thermal efficiency PTCs.

Índice General

AGRADECIMIENTOS	II
RESUMEN	III
ABSTRACT	V
ÍNDICE GENERAL	VII
ÍNDICE DE FIGURAS	IX
ÍNDICE DE TABLAS	XI
INTRODUCCIÓN	1
Antecedentes	2
Planteamiento del problema	5
Objetivo general	6
Objetivos específicos	7
Contenido	7
1. REDES NEURONALES ARTIFICIALES (RNAs)	9
1.1. Fundamentos de redes neuronales artificiales	10
1.1.1. Descripción de la neurona artificial	11
1.1.2. Funciones de transferencia de la red neuronal artificial	14
1.1.3. Arquitecturas neuronales	16
1.1.4. El proceso de aprendizaje	17
1.1.5. Algoritmos de aprendizaje <i>Back-propagation</i>	19
1.2. Aplicaciones en energías renovables	20
2. CONCENTRADORES SOLARES DE CANAL PARABÓLICO (CCPs)	22
2.1. Principios de operación de los CCPs	23
2.1.1. Parámetros de diseño óptico de los CCPs	26
2.1.2. Eficiencia óptica	30

<i>ÍNDICE GENERAL</i>	VIII
2.1.3. Eficiencia térmica	33
2.2. Evaluación térmica para CCPs	38
2.2.1. Estándar ANSI/ASHRAE 93:2003	38
2.2.2. Constantes de tiempo	40
3. MODELACIÓN MATEMÁTICA DE LA EFICIENCIA TÉRMICA	41
3.1. Equipo experimental	41
3.2. Desarrollo del modelo matemático	43
3.2.1. Creación de la base de datos	45
3.2.2. Desarrollo y evaluación del modelo de RNA	46
3.2.3. Comparación bajo criterios estadísticos	48
3.3. Determinación del modelo matemático óptimo	49
4. ANÁLISIS DE RESULTADOS	54
4.1. Validación del modelo matemático para predicción de eficiencia térmica	54
4.2. Análisis de sensibilidad	58
4.2.1. El algoritmo de Garson	59
4.2.2. Producto de pesos de Tchaban	59
4.2.3. Método de derivadas parciales	60
4.3. Determinación de la importancia de las variables de entrada	61
CONCLUSIONES	66
RECOMENDACIONES	68
REFERENCIAS	69
ANEXO 1	76
ANEXO 2	83
ANEXO 3	91

Índice de Figuras

1.1. Esquema de una neurona biológica (Kalogirou, 2009).	12
1.2. Modelo simplificado de una neruona artificial (Kalogirou, 2001).	13
1.3. Neuronal artificial básica con R entradas.	13
1.4. Diagrama esquemático de una red neuronal multicapa (Kalogirou, 2001).	16
1.5. Aprendizaje supervisado (Isasi Viñuela y Galván León, 2003).	18
1.6. Aprendizaje no supervisado (Isasi Viñuela y Galván León, 2003).	18
1.7. Aprendizaje por refuerzo.	19
2.1. Clasificación de las tecnologías de aprovechamiento de energía solar (Carta González et al., 2009).	22
2.2. Esquema de los componentes de un concentrador solar de canal parabólico (Kalogirou, 2004).	24
2.3. Esquema de un tubo absorbente típico de un CCP (Carta González et al., 2009).	24
2.4. Sistema de orientación norte-sur de un CCP (Carta González et al., 2009).	25
2.5. Sección transversal de un CCP con receptor circular (Kalogirou, 2009).	26
2.6. Longitud focal y curvatura de un CCP (Kalogirou, 2009).	29
2.7. Efectos de perdidas ópticas en el reflector de un CCP (Kalogirou, 2004).	31
2.8. Curvas experimentales de eficiencia térmica en CCPs (Jaramillo et al., 2013).	37
3.1. Diagrama esquemático de operación del equipo experimental basado en una planta generadora de vapor de baja entalpía.	42
3.2. Metodología computacional para la obtención del modelo de predicción de eficiencia térmica.	44
3.3. Procedimiento numérico empleado para el proceso de aprendizaje de la RNA, y la arquitectura iterativa usada por el modelo para predecir la eficiencia térmica en un arreglo de CCPs.	47
3.4. Resultados obtenidos entre los 10 algoritmos de entrenamiento back-propagation. a) Error cuadrado medio. b) Porcentaje de error medio absoluto. c) Coeficiente de correlación.	50

3.5. Arquitectura óptima de RNA para la estimación de los valores de eficiencia térmica.	51
3.6. Comparación estadística entre datos de η_T simulados y experimentales.	52
4.1. Perfiles de mediciones experimentales de η_T no incluidas en el proceso de entrenamiento de la RNA. a) CCPs con $\varphi_r = 45^\circ$. b) CCPs con $\varphi_r = 90^\circ$.	55
4.2. Validación de los resultados del modelo matemático para $\varphi_r = 45^\circ$. a1) η_T experimental en función del flujo de agua y el parámetro de pérdida de calor. a2) Perfil de planta de η_T experimental en función del flujo de agua y el parámetro de pérdida de calor. b1) η_T simulada en función del flujo de agua y el parámetro de pérdida de calor. b2) Perfil de planta de η_T simulada en función del flujo de agua y el parámetro de pérdida de calor.	56
4.3. Validación de los resultados del modelo matemático para $\varphi_r = 90^\circ$. a1) η_T experimental en función del flujo de agua y el parámetro de pérdida de calor. a2) Perfil de planta de η_T experimental en función del flujo de agua y el parámetro de pérdida de calor. b1) η_T simulada en función del flujo de agua y el parámetro de pérdida de calor. b2) Perfil de planta de η_T simulada en función del flujo de agua y el parámetro de pérdida de calor.	57
4.4. Representación del análisis de sensibilidad.	58
4.5. Impacto porcentual de las variables de entrada sobre η_T	62
4.6. Derivadas parciales de las variables del modelo de red neuronal.	64

Índice de Tablas

1.1. Funciones de transferencias empleadas en RNAs.	15
1.2. Algoritmos de entrenamientos <i>Back-propagation</i>	20
2.1. Ecuaciones para la obtención de S en función de f para diversos valores de ángulo de borde.	29
2.2. Constantes para la ecuación de Zhukauskas (Incropera y De Witt, 1999).	34
3.1. Parámetros empleados en la estimación del modelo de RNA.	46
3.2. Evaluación de diversas arquitecturas para el algoritmo Levenberg - Marquardt.	51
3.3. Pesos y bias óptimos del modelo matemático desarrollado para la estimación de η_T	53
4.1. Resultados del análisis de sensibilidad.	63

INTRODUCCIÓN

El Sol representa la principal fuente energética de nuestro planeta. Su energía es la causante de diversos fenómenos como la generación de vientos, la evaporación de las aguas superficiales, la formación de nubes, las lluvias y, por consiguiente, de los saltos de agua. Su calor y su luz son la base de numerosas reacciones químicas indispensables para el desarrollo de los vegetales y de los animales que con el paso de los siglos han originado combustibles fósiles como el carbón o el petróleo. Además, básicamente todas las formas de energías renovables existentes como lo son la eólica, biomasa, mareomotriz, hidráulica, fotovoltaica, fotoquímica, solar térmica entre otras, provienen directa o indirectamente de la energía solar (Quaschnig, 2005; Carta González et al., 2009).

Desde tiempos antiguos diversas civilizaciones como la egipcia, china, mesopotámica, griega, romana y las antiguas culturas mesoamericanas reconocieron en el Sol la importancia de una fuerza motriz por la cual se originaba cada uno de los fenómenos naturales, y mediante la cual fueron capaces de aprovechar y hacer buen uso de los beneficios brindados por este tipo de energía (Kalogirou, 2004). Hasta el siglo XVIII la totalidad de las necesidades energéticas de la humanidad era completamente abastecida por la energía del Sol y sus derivados como la biomasa, la energía eólica e hidráulica (Quaschnig, 2005); sin embargo con la introducción de la máquina de vapor y el motor de combustión interna, el carbón y posteriormente el petróleo pasaron a ser las principales fuentes energéticas de la humanidad.

En la actualidad el 80% de la energía consumida en el mundo proviene de los combustibles fósiles, siendo el sector industrial quien domina dicha demanda con más del 50% de la energía total consumida. Sin embargo, el empleo de derivados de hi-

drocarburos ha generado grandes impactos medio ambientales como lo son el cambio climático y el calentamiento global, producto de la emisión de gases de efecto invernadero a la atmósfera (Mekhilef et al., 2011). Lo anterior aunado a la disminución de existencias de los combustibles fósiles ha orillado a la necesidad de modificar el modelo energético actual, el cual es insostenible, empleando fuentes energéticas alternativas y nuevas tecnologías capaces de ser aplicadas para el desarrollo de la industria, con el objetivo de no comprometer el medio ambiente.

De las energías renovables existentes, la energía solar, principalmente la energía solar térmica, es una de las formas de energía más prometedoras a futuro para aplicaciones a nivel industrial, debido a que es abundante, limpia, gratis, no genera ningún ruido o algún otro tipo de contaminación ambiental (Solangi et al., 2011). En la actualidad casi todos los procesos en la industria requieren la aplicación de energía térmica con temperaturas en un rango entre los 80°C y 240°C en alguna de sus etapas (Ramos et al., 2014); industrias como la lechera, la producción de plásticos, el enlatado de alimentos, la producción de papel, entre otras requieren energía térmica para procesos como el secado, esterilizado, limpieza, evaporación, producción de vapor así como el acondicionamiento de naves industriales tanto para calefacción como refrigeración; misma energía que puede ser fácilmente suministrada mediante captadores solares de conversión fototérmica, principalmente Concentradores Solares de Canal Parabólico (CCPs), los cuales resultan una opción viable tanto técnica como económica para la sustitución de las tecnologías convencionales para la generación de calor de procesos industriales (Venegas Reyes, 2014).

Antecedentes

La tecnología de concentradores solares de canal parabólico es una de las más maduras en el área de la energía solar fototérmica debido a la gran cantidad y tiempo de investigación desarrollado a su alrededor. La primera experiencia práctica que se tiene con los concentradores parabólicos fue en 1870, referente a una máquina productora de vapor desarrollada por John Ericsson. Quince años mas tarde en 1885, el ingeniero francés Charles Tellier, sería una de las primeras personas en desarrollar

colectores solares de baja temperatura para impulsar máquinas . Posteriormente a inicios del siglo XX el ingeniero estadounidense Frank Shuman, llevó a cabo la primera planta solar a gran escala, la cual a pesar del éxito obtenido fue cerrada debido al inicio de la Primera Guerra Mundial y la disminución en el precio de los combustibles fósiles. (Vidrales Escobar, 2007; Fernández-García et al., 2010).

Es hasta la década de 1970 que se retoma el verdadero interés en la tecnología de concentración parabólica como una clara respuesta a la crisis petrolera por el incremento disparado de los precios de los hidrocarburos. Para 1976, Norton Pierce (Pierce, 1976) presentó un trabajo sobre la posibilidad de construir un colector solar eficiente y de bajo costo. Determinó que la precisión óptica y los mecanismos de seguimiento del sol son los factores que aumentan el costo de la tecnología de CCPs. También determinó que si se lograra ubicar al tubo absorbedor en el punto focal de manera más o menos constante, con un error aproximado de 6° , podría usarse un mecanismo mucho más barato para el seguimiento solar.

Hablando específicamente del área de producción de vapor para calor de procesos, en 1992 Thomas (Thomas, 1992) desarrolló un sistema solar de generación de vapor con aplicación directa en una fábrica de manufactura de seda en Mysore, India; cuatro años más tarde el mismo Thomas(Thomas, 1996) realiza una publicación sobre los aspectos relacionados con la producción de vapor a base de concentradores cilíndrico parabólicos, reportando las diversas configuraciones de los sistemas de generación de vapor, los diversos problemas que se pueden presentar en ellos y las posibles soluciones a dichas problemáticas.

Entre 1996 y 1997 Kalogirou (Kalogirou, 1996, 1997) diseñó, construyó, describió el comportamiento, puso en operación y optimizó un conjunto de concentradores solares de canal parabólico en la República de Chipre; obteniendo diferencias de aproximadamente 0.8% en relación a los cálculos teóricos llevados a cabo para el sistema. Para el 2002 el mismo Kalogirou (Kalogirou, 2002) lleva a cabo un estudio sobre la viabilidad, tanto térmica como económica, para Chipre, del empleo de los concentradores solares de canal parabólico para aplicaciones en la industria; dicho trabajo se convier-

te en pieza elemental para la evaluación de estos sistemas a nivel global. En el 2004 (Kalogirou, 2004) realiza un estudio sobre los diversos tipos de colectores solares, su aplicación y beneficios; y para el 2009 (Kalogirou, 2009) lleva a cabo la publicación de el libro titulado *Solar Energy Engeineering Processes and Systems* el cual describe los procesos, ecuaciones y consideraciones relevantes para la fabricación, evaluación y modelación de los sistemas solares tanto fotovoltaicos como de concentración solar térmica, poniendo gran énfasis en estos últimos.

En relación a las Redes Neuronales Artificiales (RNAs), en 2001 Kalogirou (Kalogirou, 2001) publica una recopilación donde menciona la importancia de las redes neuronales en la investigación contemporánea de modelado matemático de sistemas basados en energías renovables, citando los componentes esenciales de las redes neuronales artificiales, así como trabajos realizados por él mismo en materia de concentración solar, reportando resultados superiores a los obtenidos mediante métodos estadísticos convencionales. Posteriormente en la publicación de su libro en 2009 (Kalogirou, 2009) asigna un capítulo destinado a los procesos de modelado y simulación de sistemas energéticos solares poniendo énfasis en la utilización de las actuales herramientas de inteligencia artificial entre las que destacan las redes neuronales artificiales aplicados a sistemas solares. Para el 2013 Azadeh (Azadeh et al., 2013), desarrolla una revisión sobre la importancia y beneficios de las redes neuronales artificiales en la predicción de variables ambientales y estimación de algunos sistemas energéticos no convencionales, así como una descripción de las principales metodologías y modelos neuronales empleados hasta la actualidad. Por último, en el 2015 Raza (Raza y Khosravi, 2015) presenta un trabajo enfocado a la descripción de las diversas técnicas de Inteligencia Artificial (IA) empleadas en energías renovables para su predicción y optimización haciendo mención de diversas técnicas de hibridación entre redes neuronales artificiales, algoritmos genéticos y lógica difusa.

A nivel nacional se han realizado diversos estudios sobre el empleo de energía fototérmica para la aplicación de calor de procesos. En 2007 Vidrales (Vidrales Escobar, 2007) con apoyo del Instituto de Energías Renovables de la Universidad Nacional Autónoma de México, diseña, construye, pone en operación y evaluá un sistema de

concentración solar para aplicaciones de pasteurización, los resultados de dicho trabajo concluyeron que la relación costo beneficio obtenida por el concentrador no era viable, detectando las fallas en el proceso las cuales produjeron una baja eficiencia del sistema. Para 2014 Venegas (Venegas Reyes, 2014) y Jaramillo (Jaramillo et al., 2013), desarrollaron una planta generadora de baja entalpía para generación de calor de procesos tomando como punto de partida la información generada por Vidrales. Dicho sistema alcanzó eficiencias térmicas superiores comparado con aquellos reportados en la literatura, además de ser llevado a cabo con un coste más económico que estos últimos. Por otro lado, en los últimos años se han realizado estudios que indican la viabilidad e importancia del empleo de este tipo de tecnologías para la industria nacional (Alemán-Nava et al., 2014; Villicaña-Ortiz et al., 2015), basándose en sus requerimientos y los niveles de radiación existentes en el país, lo cuales reportan niveles superiores a los presentes en los países líderes en energía fototérmica como Alemania, Japón y España.

Planteamiento del problema

En la actualidad casi toda la energía transmitida por la red eléctrica y consumida por sistemas industriales es parcial o totalmente dependiente de la quema de combustibles fósiles para la producción de energía térmica, generando emisiones de gases de efecto invernadero lo cual ha ocasionado fuertes impactos al medio ambiente como lo son el cambio climático y el calentamiento global. En el sector industrial mexicano más del 68 % de la energía total consumida es destinada a la generación de calor de procesos, los cuales operan en un rango de temperaturas entre los 80°C y 250°C (Ramos et al., 2014); no obstante esta misma energía puede ser suministrada mediante captadores solares de conversión fototérmica, más específicamente Concentradores Solares de Canal Parabólico (CCPs) (Mekhilef et al., 2011; Venegas Reyes, 2014). En este contexto se han llevado a cabo una gran cantidad de investigaciones sobre la inclusión de sistemas energéticos basados en fuentes de energía alternativas para emplearse en la generación de calor de procesos a nivel industrial (Férrandez-García et al., 2010; Mekhilef et al., 2011).

Los CCPs resultan una solución tanto tecnológica como económicamente idónea para la sustitución de los combustibles fósiles en la generación de calor de procesos industriales, no obstante como todos los sistemas basados en el empleo de energías alternativas, los CCPs se encuentran vinculados a una gran cantidad de variables y expuestos a diversas fluctuaciones ambientales, lo cual vuelve sumamente complicado su estudio. Por lo tanto, para su comprensión es necesario el empleo de complejas ecuaciones no lineales, sin embargo, esto trae consigo dificultad para optimizar su funcionamiento al momento de buscar el mejor costo-beneficio durante su operación (Kalogirou, 2002; Venegas Reyes, 2014). Debido a lo anterior, una parte esencial en la investigación para la incorporación de estos sistemas a la industria se basa en la obtención de modelos matemáticos capaces de describirlos con la mayor exactitud posible, considerando la mayor cantidad de parámetros involucrados.

Por otro lado, en los últimos años se ha ido incrementando el uso de las redes neuronales artificiales como una herramienta adecuada en el modelado de fenómenos relacionados con las energías renovables, principalmente debido a que toda la información proveniente de este tipo de energías es muy fluctuante, posee demasiado ruido y además el comportamiento no presenta una tendencia lineal; mismas características para las cuales se encuentran diseñada estas herramientas computacionales (Azadeh et al., 2013; Raza y Khosravi, 2015).

Por tales motivos, el propósito del presente trabajo consiste en el desarrollo de un modelo computacional para la estimación de la eficiencia térmica η_T de un arreglo de concentradores solares cilíndrico parabólicos, empleando como herramienta RNAs, a partir de una base de datos experimental correspondiente a una planta de generación de vapor de baja entalpía.

Objetivo general

Desarrollar un modelo matemático mediante el uso de redes neuronales artificiales para la descripción de la relación entre las variables de operación de un arreglo concentradores solares cilíndrico parabólicos y su eficiencia térmica, así como identificar

la relevancia de cada una de las variables implicadas en el modelo sobre la eficiencia del sistema, aplicando un análisis estadístico de sensibilidad.

Objetivos específicos

- Desarrollar una arquitectura de red neuronal capaz de describir la relación entre las variables que afectan al sistemas y la eficiencia de este.
- Modelar matemáticamente la relación existente entre cada una de las variables que afectan al sistema y la eficiencia térmica del mismo.
- Validar el modelo matemático realizando una comparación con datos experimentales.
- Identificar el grado de importancia de cada una de las variables en la eficiencia térmica del sistema.

Contenido

El presente trabajo de tesis se encuentra integrado por un total de cuatro capítulos los cuales se describen brevemente a continuación:

Capítulo 1.- REDES NEURONALES ARTIFICIALES (RNAs)

Realiza una descripción de las redes neuronales artificiales para la solución de problemas de modelo, la manera en que operan y los elementos que las componen, así como la importancia que han cobrado en la actualidad entorno a los sistemas de energías renovables.

Capítulo 2.- CONCENTRADORES SOLARES DE CANAL PARABÓLICO (CCPs)

Presenta los parámetros de diseño y operación de los CCPs. Se describe también el análisis de la eficiencia térmica y óptica así como los estándares para su evaluación térmica.

Capítulo 3.- MODELACIÓN MATEMÁTICA DE LA EFICIENCIA TÉRMICA

Describe el equipo experimental a partir del cual se obtuvieron los datos para la modelación. Presenta la metodología realizada para la generación del modelo matemático, los diversos entrenamientos de red y la arquitectura de red neuronal que presenta mayor adaptación respecto a los datos experimentales.

Capítulo 4.- ANÁLISIS DE RESULTADOS

Presenta los resultados obtenidos en los capítulos anteriores llevando a cabo comparativas con datos no incorporados al entrenamiento de la Red Neuronal Artificial (RNA) y así verificar la efectividad del modelo matemático obtenido. De la misma forma muestra el desarrollo un análisis de sensibilidad para determinar los parámetros que mayor influyen sobre la eficiencia térmica de los CCPs.

Capítulo 1

REDES NEURONALES ARTIFICIALES (RNAs)

Las RNAs son un concepto generado por Warren McCulloch y Walter Pitts en 1943 (McCulloch y Pitts, 1943) en el cual propusieron el desarrollo de un sistema constituido por elementos que se comportaran de forma similar a la neurona biológicas en sus funciones básicas.

El interés por un sistema computacional que se comporte de manera similar al sistema nervioso se da esencialmente por la forma de operación del cerebro, la cual es completamente distinta al funcionamiento de una computadora convencional, ya que el cerebro humano corresponde al de un sistema altamente complejo, no lineal y paralelo. Lo anterior equivale a decir que el cerebro puede realizar múltiples operaciones simultáneamente a diferencia de las computadoras quienes solo realizan una operación a la vez. Sin embargo, las RNAs al margen de parecerse al cerebro, presentan únicamente una serie de características propias de éste como lo son el hecho de poder aprender de la experiencia, generalizar ejemplos previos a ejemplos nuevos, así como abstraer características principales de una serie de datos (Basogain Olabe, 2005).

1.1. Fundamentos de redes neuronales artificiales

Según Haykin (Haykin, 1990) una red neuronal es un procesador distribuido masivamente paralelo que tiene una propensión natural para almacenar conocimiento experimental y ponerlo a disposición para su uso. Su principal similitud con el cerebro humano se debe a que a través de un proceso de aprendizaje la red es capaz de adquirir conocimiento mismo que almacena en los denominados pesos sinápticos. Algunas de las ventajas de las RNAs que las distinguen de los métodos computacionales convencionales son (Nannariello y Fricke, 2001):

- La manera directa en la cual las RNAs adquieren información y conocimiento acerca del problema planteada mediante la fase de entrenamiento.
- La capacidad para trabajar con datos tanto analógicos como discretos, lo que podría resultar complicado mediante otros medios.
- Su capacidad de trabajar como una caja negra a la cual unicamente se le ingresa una base de datos compuesta por una serie de valores de entrada y salida, sin la necesidad de requerir información específica del comportamiento físico del sistema ni los detalles matemáticos.
- La forma compacta en la cual la información y el conocimiento adquirido son almacenados durante el entrenamiento de la red, y la facilidad de acceso a ésta para su posterior uso.
- La robustez que presenta, lo cual permite que aunque fallen algunos elementos de procesamiento la red continúe trabajando.
- Su tendencia a tener un comportamiento altamente no lineal, lo que le permite procesar información de fenómenos no lineales.

Sin embargo, aunque las RNAs pueden ser empleadas para solución de problemas complejos, también presentan ciertas desventajas, de las cuales las más importantes son (Ponce Cruz, 2010):

- Las RNAs se deben entrenar para cada problema siendo necesario realizar múltiples pruebas para determinar la arquitectura adecuada. El entrenamiento es largo y puede consumir varias horas de proceso de computo.
- Debido a que las redes se entrenan en lugar de programarlas, éstas requieren de muchos datos.
- Las RNAs representan un aspecto complejo para un observador externo que desee realizar cambios. Para añadir nuevo conocimiento es necesario cambiar las interacciones entre muchas unidades para que su efecto unificado sintetice este conocimiento. Para un problema de tamaño considerable es imposible hacer esto manualmente, por lo tanto una red con representación distribuida debe emplear algún algoritmo de aprendizaje.

Es necesario considerar que el desempeño del entrenamiento de una red neuronal depende del algoritmo de aprendizaje utilizado, del número de capas ocultas, del número de neuronas en cada capa oculta, de la conectividad o arquitectura de la red y también del tipo de función de activación que se seleccione para cada neurona.

1.1.1. Descripción de la neurona artificial

El objetivo principal de un modelo de Red Neuronal Artificial (RNA) es el de imitar la sinapsis generada en las neuronas animales, las cuales son la unidad fundamental del sistema nervioso y se encuentran conformadas por un núcleo y un sistema de entradas y salidas denominadas dendritas y axones, respectivamente (Basogain Olabe, 2005). La Figura 1.1 muestra los elementos que componen a una neurona biológica.

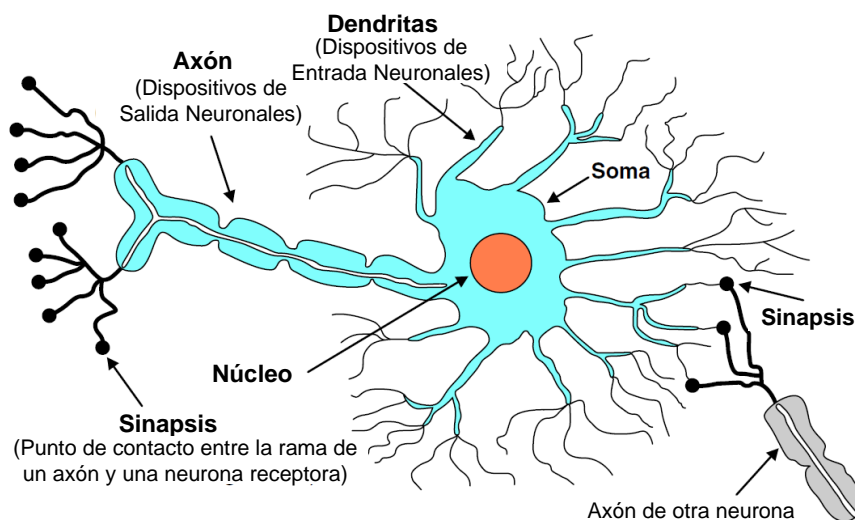


Figura 1.1: Esquema de una neurona biológica (Kalogirou, 2009).

Cada neurona es una simple unidad procesadora que recibe y combina señales desde y hacia otras neuronas. Para llevar a cabo esto, en la neurona ocurren dos procesos importantes (Izautireta y Saavedra, 2000):

- El impulso que llega a la interconexión entre dos neuronas (sinapsis), y el que sale de la neurona no son iguales en general. *Una sinapsis modifica el pulso ya sea reforzándolo o debilitándolo.*
- En el soma se suman las entradas de todas las dendritas. Si estas entradas sobrepasan un cierto umbral se transmitirá un pulso a lo largo del axón en caso contrario no.

Ambas características constituyen la base de los sistemas neuronales artificiales.

En las RNAs la unidad análoga a la neurona biológica es la neurona artificial también conocida como el Elemento Procesador (EP). La Figura 1.2 muestra un modelo altamente simplificado de una neurona artificial y su similitud respecto a la neurona biológica (Basogain Olabe, 2005).

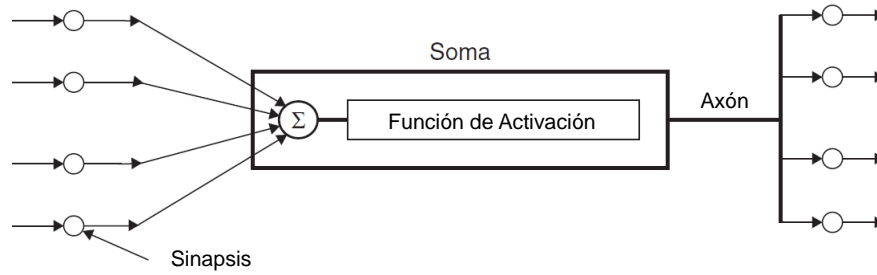


Figura 1.2: Modelo simplificado de una neruona artificial (Kalogirou, 2001).

Al igual que la neurona biológica, el EP posee varias entradas, las cuales pueden provenir del exterior o de neuronas adyacentes, que son combinadas normalmente mediante una suma básica. La suma de las entradas es modificada por una función de transferencia, y el valor de salida de esta función se pasa directamente a la salida del elemento procesador (Basogain Olabe, 2005). La Figura 1.3 detalla el proceso descrito anteriormente, en ella se observa un grupo de elementos p_1, p_2, \dots, p_R pertenecientes a un vector \mathbf{p} de elementos de entrada, donde cada uno de estos elementos es multiplicado por un valor de ponderación asociado, denominado *peso* (\mathbf{W}), antes de ser aplicado a la sumatoria, la cual es únicamente el producto punto de la matriz de los pesos \mathbf{W} por el vector \mathbf{p} (Isasi Viñuela y Galván León, 2003; Demuth y Beale, 2014).

$$\mathbf{W}\mathbf{p} = p_1w_1 + p_2w_2 + \dots + p_Rw_R \tag{1.1}$$

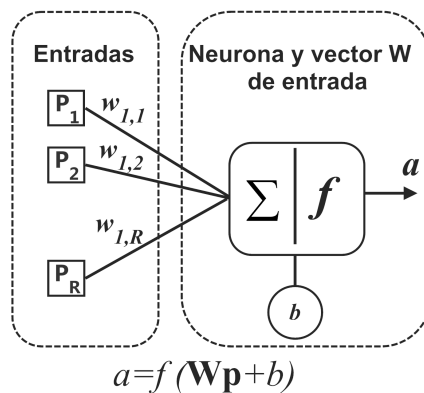


Figura 1.3: Neuronal artificial básica con R entradas.

En algunos casos es necesario agregar un valor de ajuste o *bias* (b), el cual es sumado junto con las entradas ponderadas para formar la entrada neta n (Demuth y Beale, 2014):

$$n = \mathbf{W}\mathbf{p} + b = p_1w_1 + p_2w_2 + \dots + p_Rw_R + b \quad (1.2)$$

Esta entrada neta es ingresada a una función de transferencia f para así obtener la salida a de la neurona (Demuth y Beale, 2014).

$$a = f(n) = f(\mathbf{W}\mathbf{p} + b) \quad (1.3)$$

Es importante considerar que dependiendo del tipo de función de transferencia habrá distintos modelos de neuronas artificiales.

1.1.2. Funciones de transferencia de la red neuronal artificial

La función de transferencia o función de activación es un componente esencial de las neuronas artificiales, su objetivo es limitar el rango de salida de la neurona a partir de los valores que recibe (Isasi Viñuela y Galván León, 2003). Una buena función de activación debe cumplir en primera instancia con que ella misma y su derivada sean de fácil computo, además de que debe tener una amplia parte lineal para lograr velocidad de entrenamiento y de convergencia en pocos ciclos (LLano et al., 2007).

Existe una gran variedad de funciones de activación por lo cual la selección de la función adecuada se realiza de acuerdo al tipo problema y al propio criterio del investigador, esto se da generalmente mediante un proceso de ensayo y error, dado que la selección depende de la precisión, velocidad requerida y del algoritmo de aprendizaje escogido (Piekniewski y Rybicki, 2004). La Tabla 1.1 muestra una descripción detallada de las principales funciones de transferencia empleadas en el entrenamiento de redes neuronales.

Tabla 1.1: Funciones de transferencias empleadas en RNAs.

Función	Ecuación	Símbolo	Descripción
Limitador fuerte	$a = \begin{cases} 1 & \text{si } n \geq 0, \\ 0 & \text{si } n < 0 \end{cases}$		Permite a la neurona clasificar las entradas en dos categorías diferentes, Cierto (1) o Falso (0).
Limitador fuerte simétrico	$a = \begin{cases} 1 & \text{si } n \geq 0, \\ -1 & \text{si } n < 0 \end{cases}$		Al igual que el limitador fuerte, fuerza a la neurona para generar una salida binaria, ahora entre 1 y -1 con lo cual abarca un mayor rango de valores.
Lineal	$a = n$		La salida de esta función de transferencia es idéntica al valor de la entrada neta.
Lineal saturada	$a = \begin{cases} 0 & \text{si } n < 0, \\ n & \text{si } 0 \leq n \leq 1 \\ 1 & \text{si } n > 1 \end{cases}$		La función toma los valores de entrada netas y reduce la salida en un rango de 0 a 1. Se emplea cuando se poseen variaciones suaves de valores positivos.
Lineal saturada simétrica	$a = \begin{cases} -1 & \text{si } n < 0, \\ n & \text{si } 0 \leq n \leq 1 \\ 1 & \text{si } n > 1 \end{cases}$		La función toma los valores de entrada netas y reduce la salida en un rango de -1 a 1. Se emplea cuando se poseen variaciones suaves de valores positivos y negativos.
Logarítmica sigmoidea	$a = \frac{1}{1 + e^{-n}}$		Esta función de transferencia presenta una rápida convergencia. La función toma los valores de entrada netas y reduce la salida en un rango de 0 a 1.
Tangente hiperbólica sigmoidea	$a = \frac{2}{1 + e^{-2n}} - 1$		Similar a la anterior, cubre un mayor rango de valores (-1 a 1). Se emplea cuando la velocidad es más importante que la forma de la función de transferencia.

De las funciones anteriores las más utilizadas para problemas de predicción, en las capas ocultas, debido a su rápida convergencia y sus características de derivación son las funciones sigmoideas (logarítmica y tangente hiperbólica). Las funciones limitador son comúnmente empleadas para problemas de clasificación; y la función lineal es frecuentemente empleada en múltiples modelos de redes neuronales para el ajuste de los datos de la capa de salida (LLano et al., 2007; Dorofki et al., 2012).

1.1.3. Arquitecturas neuronales

La forma en la cual se organizan los EP en la red neuronal se le denomina arquitectura, y está estrechamente ligada al algoritmo de aprendizaje empleado para entrenar la red. En la actualidad la arquitectura de RNA más empleada es la conocida como arquitectura multicapa, Figura 1.4. La primera capa de esta arquitectura es conocida como capa de entrada y se caracteriza por ser la que recibe las variables o vectores procedentes del exterior; sirve como puntos distribuidores y no realizan ninguna operación de calculo. La siguiente capa es conocida como capa oculta, la cual casi siempre es no lineal y puede estar conformada así misma por varias capas. Por último la capa final es conocida como capa de salida y es en donde se presentas las respuestas de la red (Izautireta y Saavedra, 2000; Basogain Olabe, 2005).




Figura 1.4: Diagrama esquemático de una red neuronal multicapa (Kalogirou, 2001).

1.1.4. El proceso de aprendizaje

La parte más importante de una RNA es el aprendizaje o entrenamiento. El esquema de aprendizaje de una red es lo que determina el tipo de problema que será capaz de resolver y está ligado de forma fundamental al tipo de ejemplos que dispone en el proceso de aprendizaje. Desde el punto de vista de los ejemplos, el conjunto de aprendizaje debe poseer las siguientes características (Isasi Viñuela y Galván León, 2003):

- **Ser significativo.** Debe haber un número suficiente de ejemplos. Si el conjunto de aprendizaje es reducido, la red no será capaz de adaptar sus pesos de forma eficaz.
- **Ser representativo.** Los componentes del conjunto de aprendizaje deberán ser diversos. Si un conjunto de aprendizaje tiene muchos más ejemplos de un tipo que del resto, la red se especializará en dicho subconjunto de datos y no será de aplicación general.

El proceso de aprendizaje consiste en la aplicación secuencial de diferentes conjuntos o vectores de entrada para que se ajusten los pesos de las interconexiones según un procedimiento determinado. Durante la sesión de aprendizaje los pesos convergen gradualmente hacia los valores que hacen que cada entrada produzca el valor de salida deseado (Basogain Olabe, 2005). El criterio de convergencia empleado depende del tipo de red utilizada o del tipo de problema a resolver. La finalización del periodo de aprendizaje se puede determinar por tres factores: mediante un número fijo de ciclos; cuando el error desciende por debajo de una cantidad preestablecida; y cuando las modificaciones de los pesos lleguen a ser irrelevantes. Por otro lado, según las características del problema se pueden distinguir tres tipos de esquemas de aprendizaje (Isasi Viñuela y Galván León, 2003; Basogain Olabe, 2005):

Aprendizaje supervisado. Consiste en presentar un vector de entrada a la red, calcular la salida de la red, compararla con la salida deseada, y el error o diferencia resultante se utiliza para realimentar y cambiar los pesos de acuerdo con algoritmo que tiende a minimizar el error. Una descripción gráfica de este esquema se observa en la Figura 1.5.




Figura 1.5: Aprendizaje supervisado (Isasi Viñuela y Galván León, 2003).

Aprendizaje no supervisado. En este esquema el conjunto de vectores de entrenamiento consiste únicamente en vectores de entrada. El algoritmo modifica los pesos de red de forma que produzca vectores de salida consistentes (Figura 1.6).




Figura 1.6: Aprendizaje no supervisado (Isasi Viñuela y Galván León, 2003).

Aprendizaje por refuerzo. Es una variante del aprendizaje supervisado, consiste en modificar los pesos de la red hasta que para todos los ejemplos del conjunto de entrenamiento, la salida producida sea lo más parecida posible a la deseada. Lo importante no es que el sistema dé buenas salidas si no que tan capaz es de predecir salidas que desconoce. Para poder determinar si la red produce salidas adecuadas, el conjunto de aprendizaje se divide en dos subconjunto uno de entrenamiento y otro de validación. La diferencia respecto al aprendizaje supervisado es que con el propósito de medir la eficacia de la red en la resolución de problemas, el error es medido con datos que no han sido utilizados durante el aprendizaje.(Figura 1.7).

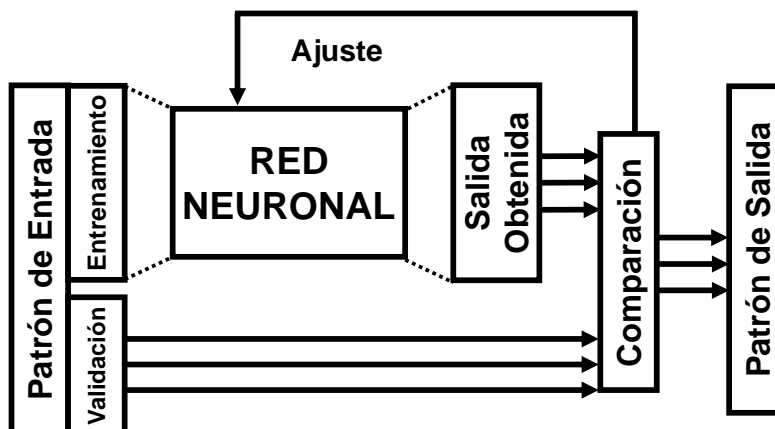


Figura 1.7: Aprendizaje por refuerzo.

1.1.5. Algoritmos de aprendizaje *Back-propagation*

A partir de los esquemas planteados se han desarrollado diversos métodos de aprendizaje para RNA de entre los cuales el más popular es el algoritmo conocido como *Back-propagation*, debido a que es uno de los más poderosos en este aspecto. Este algoritmo utiliza una arquitectura multicapa, y al ser del tipo gradiente descendente, busca minimizar el error a través de la aplicación de dos fases, una hacia delante y otra hacia atrás. Durante la primera fase el patrón de entrada es presentado a la red y propagado a través de las capas hasta llegar a la capa de salida. Obtenidos los valores de salida de la red, se inicia la segunda fase, comparándose éstos valores con la salida esperada para así obtener el error. Se ajustan los pesos de la última capa proporcionalmente al error. Se pasa a la capa anterior con una retropropagación del error, ajustando los pesos y bias, y continuando con este proceso hasta llegar a la primera capa. Proceso que repite hasta reducir el Error Medio Cuadrático (RMS por sus siglas en inglés) a un valor muy cercano a cero (Kalogirou, 2001; Valencia et al., 2006). Esta técnica requiere el uso de neuronas cuya función de activación sea continua, y por lo tanto, diferenciable, generalmente la función utilizada será del tipo sigmoideal.

Por otro lado este algoritmo de aprendizaje emplea a su vez, diversos algoritmos de entrenamiento los cuales dependiendo de varios factores como la complejidad de problema, el número de datos o el número de pesos y bias. La tabla 1.2 lista dichos

algoritmos:

Tabla 1.2: Algoritmos de entrenamientos *Back-propagation*.

Acrónimo	Algoritmo	Descripción	Referencia
LM	trainlm	Levenberg-Marquardt	(Hagan y Menhaj, 1994)
GD	traingd	Batch gradient descent	(Baldi, 1995)
GDM	traingdm	Batch gradient descent with momentum	(Baldi, 1995)
CGP	traingcp	Polak-Ribiere conjugate gradient	(Polak y Ribiere, 1969)
SCG	traingcsg	Scaled conjugate gradient	(Moller, 1993)
BFG	trainbfg	BFGS Quasi-Newton	(Dennis y Schnabel, 1983)
CGB	traingcb	Powell-Beale conjugate gradient	(Johansson et al., 1991)
OSS	trainoss	One step secant	(Battiti, 1992)
CGF	traingcf	Fletcher-Reeves conjugate gradient	(Fletcher y Reeves, 1964)
GDX	traingdx	Variable learning rate	(Bowling y Veloso, 2001)

1.2. Aplicaciones en energías renovables

Aunque el concepto de RNA fue concebido desde los años 50, ha sido en los últimos 20 años que ha existido un interés substancial en la aplicación de estos sistemas para problemas prácticos. En la actualidad las RNAs son ampliamente aceptadas como una tecnología que ofrece una forma alternativa para hacer frente a problemas complejos y mal definidos (Kalogirou, 2001).

En los sistemas basados en energías renovables uno de los principales problemas que presenta está relacionado con el modelado de los mismos, debido a que se encuentran vinculados a una gran cantidad de variables y expuestos a las diversas fluctuaciones climatológicas del medio, ocasionando que la información proveniente de este tipo de sistemas sea fluctuante, posea demasiado ruido además de presentar una tendencia no lineal (Azadeh et al., 2013). Estas características han hecho que en la actualidad las RNAs sean reconocidas como herramientas adecuadas para el modelado y solución en problemas de ingeniería asociados con el desarrollo de proyectos de energías renovables. Entre las diversas aplicaciones que se le ha dado a las RNAs en esta área se encuentran: a) la predicción de la velocidad del viento en proyectos de energía eólica (Bilgili et al., 2012; Philippopoulos y Deligiorgi, 2007); b) predicción y estimación de la radiación solar y la temperatura ambiente (Almonacid et

al., 2013; Yadav y Chandel, 2014); c) para la estimación en la producción de potencia, eficiencia y temperatura en módulos fotovoltaicos (Mellit et al., 2013; Ceylan, Gedik, et al., 2014; Ceylan, Erkaymaz, et al., 2014); d) en la formación de mapas y estabilización de temperaturas para pozos geotérmicos (Bassam et al., 2010; Kalogirou et al., 2012); e) y para el cálculo del coeficiente óptimo de operación (COP) en sistemas de refrigeración, bombas y transformadores de calor (Ertunc y Hosoz, 2006; Hernández et al., 2012, 2009), entre otros.

Específicamente en el área de la energía solar fototérmica las RNAs han sido empleadas en diversos trabajos como: a) la predicción de temperaturas de agua para sistemas de colectores solares (Kalogirou et al., 1999); b) para la estimación del factor de intercepción y la razón de concentración en CCP (Kalogirou, 1999a,b); c) así como predicción del comportamiento de los sistemas basados en energía solar térmica (Caner et al., 2011; Yaici y Entchev, 2014). Los errores reportados en cada uno de estos trabajos indican límites aceptables, sugiriendo buenas adaptaciones de los datos experimentales a los modelos matemáticos realizados con RNAs sobre los modelos estadísticos convencionales.

Capítulo 2

CONCENTRADORES SOLARES DE CANAL PARABÓLICO (CCPs)

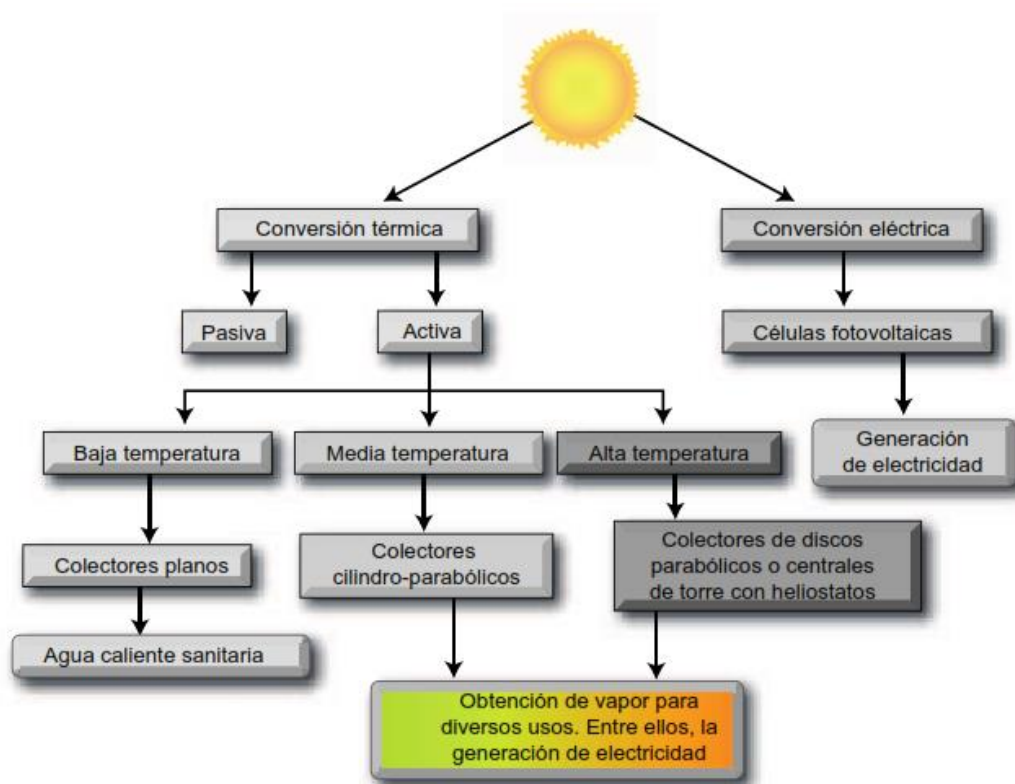


Figura 2.1: Clasificación de las tecnologías de aprovechamiento de energía solar (Carta González et al., 2009).

Los sistemas de conversión solar térmica son un tipo especial de intercambiadores de calor, los cuales capturan la energía presente en la radiación solar y la transforman en energía térmica de fluido de trabajo (Duffie y Beckman, 2013). De entre las diversas tecnologías desarrolladas para el aprovechamiento de la energía solar térmica (Figura 2.1) una de las tecnologías más implementadas en la actualidad han sido los Concentradores Solares de Canal Parabólico (CCPs), los cuales son sistemas fototérmicos de mediana temperatura, capaces de operar en el rango de los 50°C hasta los 450°C (Kalogirou, 2004), motivo por el cual sus aplicaciones pueden ser divididas en dos grupos principales. El primero y más desarrollado son las denominadas Plantas de Concentración Solar (PCS) las cuales operan con rangos de temperatura entre los 300°C y 400°C y se encuentran destinadas a la generación de energía eléctrica (Férrandez-García et al., 2010). El segundo grupo está conformado por CCPs cuya temperatura de operación se encuentra entre los 80°C y 250°C, y son empleados para la generación de calor de procesos, demanda de calor de baja temperatura con altas tasas de consumo y así como procesos de enfriamiento y refrigeración (Jaramillo et al., 2013). Sin embargo, a pesar que los sistemas para PCS son tecnologías lo suficiente maduras en la actualidad (Kumar, 2012), uno de los principales objetivos de los ingenieros en energía solar térmica es el desarrollo de colectores que sean aptos para su aplicación en la generación de calor de procesos industrial (85°C y 250°C) (Jaramillo et al., 2013).

2.1. Principios de operación de los CCPs

Los CCPs son una tecnología termosolar la cual convierte la radiación solar directa en energía térmica empleando un espejo reflector con apertura cilíndrica el cual al concentrar la radiación solar directa que incide en él, la redireccional sobre una línea denominada línea focal en la cual se hace circular un fluido que se desea sea calentado. Los elementos importantes que conforman un CCP son la superficie reflectora (reflector), el tubo a través del cual circula el fluido de trabajo (receptor) y el sistema de seguimiento solar (Figura 2.2).

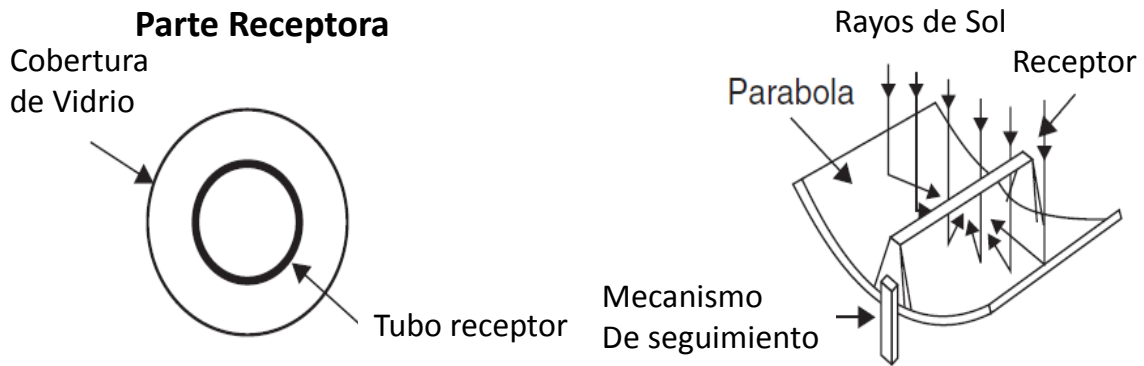


Figura 2.2: Esquema de los componentes de un concentrador solar de canal parabólico (Kalogirou, 2004).

El sistema de reflexión de un CCP se encuentra conformado por una lamina o película (de alta reflectividad $\rho > 90\%$) de aluminio, dado que posee una alta resistencia a la corrosión y menor absorción de calor que otros materiales; sobrepuesta sobre una superficie parabólica (Kalogirou, 2009).

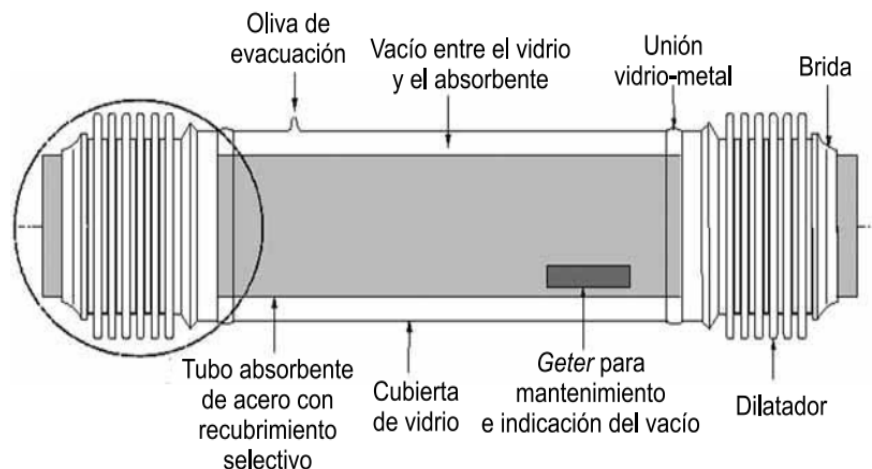


Figura 2.3: Esquema de un tubo absorbente típico de un CCP (Carta González et al., 2009).

El elemento receptor consta de un tubo o más frecuentemente dos tubos concéntricos 2.3, en los cuales el tubo interior por el cual circula el fluido que se calienta es

metálico y presenta un recubrimiento selectivo de alta absorptividad ($\alpha > 90\%$) y baja emisividad respecto al espectro infrarrojo ($\epsilon < 30\%$). Por otra parte el tubo exterior, el cual es de vidrio es empleado para reducir las perdidas por convección en el tubo metálico así como proteger de la intemperie el recubrimiento selectivo (Carta González et al., 2009). No obstante, para aplicaciones que no requieran temperaturas superiores a los 200°C el tubo exterior puede ser omitido, disminuyendo así los costos de construcción (Brooks et al., 2005; Jaramillo et al., 2013).

Los CCPs puede orientarse respecto al Sol mediante dos configuraciones: este-oeste, la cual sigue al Sol de norte a sur o bien el otro modo de orientación es norte-sur (Figura 2.4) donde el CCP sigue al Sol de este a oeste. El primer modo de seguimiento requiere un menor ajuste durante el día y la abertura siempre está frente al Sol a mediodía pero el rendimiento del colector durante la mañana y la tarde se ve reducido significativamente debido a los ángulos de incidencia pronunciados. El segundo modo de seguimiento tiene su mayor pérdida al medio día solar. Por lo tanto, un CCP orientado de norte-sur colecta más energía que un CPP este-oeste. Sin embargo, el sistema norte-sur colecta mucha energía en verano y muy poca en invierno, contrario a lo que sucede con un sistema de este-oeste el cual colecta mayor energía en invierno que en verano, por lo cual la elección de la orientación depende de aplicación y las necesidades energéticas durante el año (Kalogirou, 2009; Vidrales Escobar, 2007).

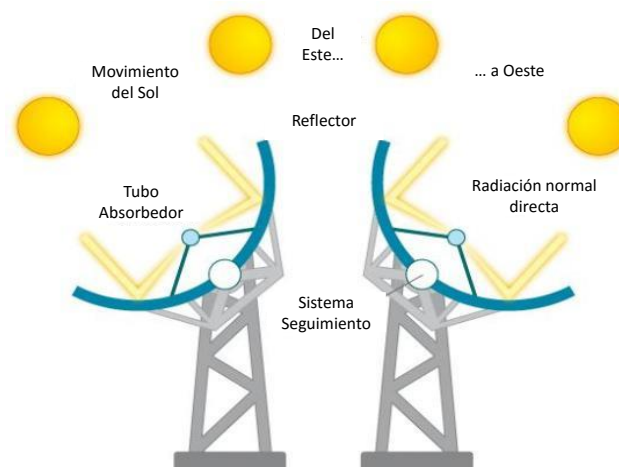


Figura 2.4: Sistema de orientación norte-sur de un CCP (Carta González et al., 2009).

2.1.1. Parámetros de diseño óptico de los CCPs

Los parámetros para el diseño óptico de un CCP se realizan a partir del estudio de la sección transversal de un Concentrador de Canal Parabólico como se observa en la Figura 2.5. La radiación incidente en el borde del reflector, denominado el radio máximo del CCP r_r , forma un ángulo con la línea central del colector el cual recibe el nombre de ángulo de borde φ_r (Duffie y Beckman, 2013). En un concentrador ideal, la imagen formada en el centro del receptor depende únicamente de estos dos parámetros así como del tamaño del ángulo que sustenta el Sol visto desde la Tierra (Venegas Reyes, 2014).




Figura 2.5: Sección transversal de un CCP con receptor circular (Kalogirou, 2009).

Considerando la ecuación de la parábola en términos de un sistemas de ejes coordenados esta se encuentra dada por:

$$y^2 = 4fx \tag{2.1}$$

en la cual f es la distancia focal de la parábola en metros (m).

Para un CCP ideal especular que esté perfectamente alineado a la radiación directa incidente, el tamaño del diámetro D del receptor que intercepta toda la imagen solar que se forma en el foco del concentrador está dado por:

$$D = 2r_r \text{sen}(\theta_m) \quad (2.2)$$

donde θ_m es conocido como el ángulo medio de aceptación cuyo valor ideal estimado propuesto por Duffie y Beckman (Duffie y Beckman, 2013) es de 0.267° .

Por otra parte para un reflector con forma parabólica el radio r mostrado en la Figura 2.5 se encuentra dado por:

$$r = \frac{2f}{1 + \cos(\varphi)} \quad (2.3)$$

donde φ es el ángulo entre el eje del colector y el rayo reflejado hacia el foco. Como se observa en la Figura 2.5, conforme varía φ de 0 hasta φ_r , r sufre un incremento desde f hasta r_r y el tamaño de la imagen teorica se incrementa desde $2f \text{sen}(\theta_m)$ hasta $2r_r \text{sen}(\theta_m) / \cos(\varphi_r + \theta_m)$. Por lo tanto, hay una imagen real formada en el plano normal al eje de la parábola. De esta forma, en el ángulo φ_r , la ecuación 2.3 queda expresada como:

$$r_r = \frac{2f}{1 + \cos(\varphi_r)} \quad (2.4)$$

Otro parámetro importante relacionado con el ángulo de borde es la apertura de la parábola W_a , la cual en su expresión simplificada se encuentra expresada en función de f y φ_r , y está dada por:

$$W_a = 4f \tan \frac{\varphi_r}{2} \quad (2.5)$$

Por otra parte, para realizar el cálculo de la razón de concentración geométrica de un CCP se obtiene que (Duffie y Beckman, 2013):

$$C = \frac{W_a}{\pi D} = \frac{\text{sen}(\varphi_r)}{\pi \text{sen}(\theta_m)} \quad (2.6)$$

De dicha ecuación es fácilmente apreciable que la razón de concentración máxima

ocurre cuando φ_r es igual a 90° , es decir $\text{sen}(\varphi_r = 1)$. Por tal motivo, reemplazando $\text{sen}(\varphi_r = 1)$ en la ecuación 2.6 el máximo valor obtenido de C está dado por (Kalogirou, 2004):

$$C_{max} = \frac{1}{\pi \text{sen}(\theta_m)} \quad (2.7)$$

Por otro lado, la magnitud del ángulo de borde determina el material requerido para la construcción de la superficie parabólica. La longitud S de la curva de la superficie reflectora está dada por (Kalogirou, 2009):

$$S = \frac{H_p}{2} \left\{ \sec\left(\frac{\varphi_r}{2}\right) \tan\left(\frac{\varphi_r}{2}\right) + \ln \left[\sec\left(\frac{\varphi_r}{2}\right) + \tan\left(\frac{\varphi_r}{2}\right) \right] \right\} \quad (2.8)$$

donde H_p es el lado recto de la parábola en metros (m) y puede ser calculado empleando la ecuación 2.5 considerando $\varphi_r = 90^\circ$.

Sin embargo, en la mayoría de los casos resulta complicado el proponer medidas específicas del material con el cual se construirá la superficie reflectora debido a que este se encuentra limitado por las dimensiones del fabricante y la pérdida de propiedades ópticas del mismo al ser cortado. Debido a esto, al sustituir la derivada de la ecuación 2.1 en la ecuación para la obtención de la longitud en curvas planas (Thomas, 2006):

$$S = \int_a^b \sqrt{1 + \left(\frac{dy}{dx}\right)^2} dx \quad (2.9)$$

es posible obtener una expresión matemática que relacione la longitud de material (S) y el foco de la parábola para un valor de φ_r conocido:

$$S = \frac{1}{2f} \int_0^{\frac{2f}{1+\cos(\varphi_r)}} \sqrt{4f^2 + x^2} dx \quad (2.10)$$

La tabla 2.1 muestra la solución de dicha ecuación integral para diversos valores de φ_r , donde se puede observar que la solución se encuentra únicamente en función de f , por lo tanto empleando una superficie reflector con un valor S conocido es posible hallar el valor del foco y de los demás parámetros ópticos a través de métodos numéricos.

Tabla 2.1: Ecuaciones para la obtención de S en función de f para diversos valores de ángulo de borde.

Ángulo de borde φ_r	Longitud de material (S)
40°	$S = \frac{f}{2}(1.579577 - \ln[f^2] + 2\ln[1.492739f])$
50°	$S = \frac{f}{2}(1.740452 - \ln[f^2] + 2\ln[1.51996f])$
60°	$S = \frac{f}{18}(4\sqrt{13} - 9\ln[9f^2] + 18\ln[f(2 + \sqrt{13})])$
70°	$S = \frac{f}{2}(2.3 - \ln[f^2] + 2\ln[1.597497f])$
80°	$S = \frac{f}{2}(2.78469 - \ln[f^2] + 2\ln[1.648563f])$
90°	$S = \frac{f}{2}(2\sqrt{2} - \ln[f^2] + 2\ln[f(1 + \sqrt{2})])$

De igual forma es importante tener en consideración, como se observa en la Figura 2.6, la influencia que presentan distintos ángulos de borde para el mismo valor de apertura ya que esto ocasiona cambios tanto en el foco como el en radio del CCP.

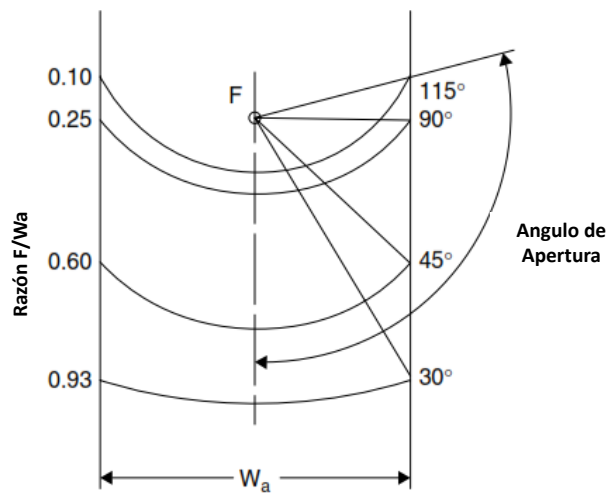


Figura 2.6: Longitud focal y curvatura de un CCP (Kalogirou, 2009).

2.1.2. Eficiencia óptica

La eficiencia óptica está definida como la razón entre la energía absorbida por el receptor y la energía incidente en el área de apertura del colector. La eficiencia óptica depende de las propiedades ópticas de los materiales empleados así como de la geometría y de los efectos implícitos en la manufactura del concentrador solar. La eficiencia óptica está dada por (Tiwari, 2002):

$$\eta_o = \rho\tau\alpha\gamma[(1 - A_f \tan(\theta))\cos(\theta)] \quad (2.11)$$

donde ρ es la reflectancia del concentrador, τ es la transmitancia de la cubierta de vidrio, α es la absortancia del receptor, γ es el factor de intercepción, A_f es el factor geométrico y θ es el ángulo de incidencia. El factor geométrico A_f es determinado por la geometría del concentrador y es una medida de la reducción efectiva del área de abertura debido a efectos de incidencia anormales como obstrucciones, sombras y los rayos incidentes más allá del final del receptor conocidos como efectos de borde. La cantidad de área de apertura perdida por efectos de borde se observa en la Figura 2.7 y esta dada por (Kalogirou, 2004):

$$A_e = fW_a \tan(\theta) \left[1 + \frac{W_a^2}{48f^2} \right] \quad (2.12)$$

Por otra parte, generalmente en los extremos de los CCPs se colocan láminas opacas para evitar que la luz concentrada que no alcance al receptor causen algún daño. Estas láminas bloquean una parte de la luz que incide en el reflector reduciendo así el área de abertura. El área generada por estas pérdidas se muestra en la Figura 2.7 y está dado por (Kalogirou, 2004):

$$A_b = \frac{2}{3}W_a h_p \tan(\theta) \quad (2.13)$$

donde h_p es la altura de la parábola.

Se debe notar que el término $\tan(\theta)$ incluido en la ecuación 2.12 y 2.13 es el mismo que en la ecuación 2.11, por lo que debe ser empleado dos veces. Por lo tanto para encontrar las pérdidas totales en el área de apertura (A_l) las dos áreas A_e y A_b deben ser sumadas sin incluir el término $\tan(\theta)$ (Jeter, 1983):

$$A_l = \frac{2}{3}W_a h_p + fW_a \left[1 + \frac{W_a^2}{48f^2} \right] \quad (2.14)$$

A partir de esto se obtiene finalmente así el factor geométrico el cual es la relación entre el área perdida y el área de apertura:

$$A_f = \frac{A_l}{A_a} \quad (2.15)$$




Figura 2.7: Efectos de pérdidas ópticas en el reflector de un CCP (Kalogirou, 2004).

El parámetro más complejo involucrado en la obtención de la eficiencia óptica de un CCP es el factor de intercepción (γ), el cual es definido como la razón entre la energía interceptada por el reflector y la reflejada por la parábola. Este parámetro depende del tamaño del receptor, los errores angulares del reflector parabólico y del ángulo que sustenta al Sol.

Los errores asociados con la superficie parabólica son de dos tipos: aleatorios y no aleatorios (Güven y Bannerot, 1985). Los errores aleatorios se pueden representar como una distribución probabilista normal. Estos errores pueden ser identificados como cambios aparentes en el tamaño del Sol, efectos de dispersión causados por errores aleatorios de pendiente (como distorsiones de la parábola debido a cargas de viento) y efectos de dispersión asociados a la superficie reflectiva. Por otra parte los errores no aleatorios son debido a errores de manufactura y de operación. Estos pueden ser identificados como imperfecciones en el perfil del reflector, errores de alineación y errores de ubicación del receptor. Los errores aleatorios son modelados estadísticamente

para la determinación de la desviación estándar de la distribución de la energía total reflejada con una incidencia normal. El error total se calcula mediante:

$$\sigma_{Tot} = \sqrt{\sigma_{Sol}^2 + 4\sigma_{Pend}^2 + \sigma_{Ref}^2} \quad (2.16)$$

donde σ_{Sol} es la desviación estándar de la distribución de la forma solar, σ_{Pend} es la desviación estándar de los errores de pendiente de la parábola y σ_{Ref} es la desviación estándar de la distribución de los errores de la superficie reflectiva.

Por otro lado, los errores no aleatorios se determinan conociendo el ángulo de error aleatorio (β) y el desplazamiento del receptor con respecto al foco de la parábola (dr). De acuerdo con (Güven y Bannerot, 1985) los errores aleatorios y no aleatorios pueden ser combinados con los parámetros geométricos del colector, así usando los parámetros de error universales y el factor de intercepción (γ), se estima por (Kalogirou, 2009):

$$\gamma = \frac{1 + \cos(\varphi_r)}{2\text{sen}(\varphi_r)} \int_0^{\varphi_r} \frac{\text{erf}(M) - \text{erf}(N)}{1 + \cos(\varphi)} d\varphi \quad (2.17)$$

donde $\text{erf}()$ es la función de M y N las cuales están dadas por:

$$M = \frac{\text{sen}(\varphi_r)(1 + \cos(\varphi))(1 - 2d^*\text{sen}(\varphi)) - \pi\beta^*(1 + \cos(\varphi_r))}{\sqrt{2}\pi\sigma^*(1 + \cos(\varphi))} \quad (2.18)$$

$$N = \frac{\text{sen}(\varphi_r)(1 + \cos(\varphi))(1 + 2d^*\text{sen}(\varphi)) + \pi\beta^*(1 + \cos(\varphi_r))}{\sqrt{2}\pi\sigma^*(1 + \cos(\varphi))} \quad (2.19)$$

donde d^* es el parámetro de error no aleatorio universal debido a la mala posición del receptor y los errores de perfil de reflector; β^* es el parámetro de error no aleatorio universal debido a los errores angulares, σ^* es el parámetro de error aleatorio universal, β es el error angular de desalineación y dr es el desplazamiento del receptor respecto al foco.

2.1.3. Eficiencia térmica

Para el análisis térmico de CCP con receptor sin cobertura de vidrio se consideran despreciables los gradientes de temperatura a lo largo del receptor, por lo que el coeficiente de pérdida de calor (U_L) se puede escribir como (Venegas Reyes, 2014):

$$U_L = h_r + h_v \quad (2.20)$$

donde h_r es el coeficiente de transferencia de calor por radiación y h_v es el coeficiente de transferencia de calor por viento.

El coeficiente de transferencia de calor por radiación se puede estimar de manera lineal mediante (Kalogirou, 2009):

$$h_r = 4\sigma\epsilon_r T_r^3 \quad (2.21)$$

donde σ es la constante de Stefan-Boltzman, ϵ y T_r^3 son la emisividad y temperatura en la superficie del receptor respectivamente.

Para estimar el coeficiente convectivo de transferencia de calor por acción del viento h_v se emplea la relación de Zhukauskas (Incropera y De Witt, 1999):

$$N\bar{u}_D = B(Re_D)^m (Pr)^n \left(\frac{Pr}{Pr_r} \right)^{1/4} \quad (2.22)$$

$$\left[\begin{array}{l} 0.7 < Pr < 500 \\ 1 < Re_D < 10^6 \end{array} \right]$$

donde Re_D es el número de Reynolds para un cilindro en flujo cruzado definido por:

$$Re_D = \frac{VD_o}{\nu} \quad (2.23)$$

donde V es la velocidad del viento y Pr es el número de Prandtl dado por:

$$Pr = \frac{\nu}{\alpha_T} \quad (2.24)$$

donde ν es la viscosidad cinemática y α_T la difusividad térmica.

Todas las variables de la ecuación 2.22, a excepción de Pr , son evaluadas a la temperatura del aire circundante que se puede aproximar a la temperatura ambiente, T_a . El valor de Pr_r es evaluado a la temperatura del tubo receptor. En la tabla 2.2 se pueden apreciar algunos valores de B y m en diferentes rangos del número de Reynolds.

Tabla 2.2: Constantes para la ecuación de Zhukauskas (Incropera y De Witt, 1999).

Re_D	B	m
0.4 - 4	0.989	0.330
4 - 40	0.911	0.385
40 - 4,000	0.683	0.466
4,000 - 40,000	0.193	0.618
40,000 - 400,000	0.027	0.805

Así la estimación del coeficiente de pérdida de calor por viento está dada por:

$$h_v = Nu_D \frac{k_v}{D_o} \tag{2.25}$$

donde k_v es la conductividad térmica del aire y D_o es el diámetro operativo del receptor. Sin embargo, para calcular Nu_D a partir de la ecuación 2.22, es necesario conocer la temperatura T_r , por lo cual es necesario llevar a cabo un balance de energía en el tubo receptor sin considerar las pérdidas con el fin de determinar la temperatura máxima T_r que puede alcanzar el receptor:

$$\dot{m}C_p(T_{m,o} - T_{m,i}) = \eta_o A_a G_b \tag{2.26}$$

donde \dot{m} y C_p son el flujo másico y el calor específico del fluido de trabajo respectivamente; $T_{m,i}$ y $T_{m,o}$ son las temperaturas de entrada y salida del flujo; η_o es la eficiencia óptica del CCP; y G_b la radiación solar directa. Así el flujo másico está dado como:

$$\dot{m} = \frac{\eta_o A_a G_b}{C_p(T_{m,o} - T_{m,i})} \tag{2.27}$$

Por lo tanto, considerando un receptor con alta difusividad térmica y paredes delgadas

a base de cobre; y suponiendo una temperatura idéntica tanto en la parte interna como externa de las paredes, es posible realizar un balance de energía:

$$h_w(T_r - T_{m,o}) = \eta_o C_o G_b \quad (2.28)$$

Con lo que es posible así estimar T_r al utilizar (Venegas Reyes, 2014):

$$T_r = \frac{\eta_o C_o G_b}{h_w} + T_{m,o} \quad (2.29)$$

donde h_w es el coeficiente convectivo de transferencia de calor en el interior del receptor el cual puede ser calculado a través de los números de Nusselt para flujo en el interior de tuberías (Incropera y De Witt, 1999):

$$h_w = \frac{kNu_D}{D_i} \quad (2.30)$$

$$Nu_D = 0.023Re^{0.8}Pr^{0.4} \quad (2.31)$$

$$\left[\begin{array}{ll} \textit{Laminar} & Re < 2,000 \\ \textit{Turbulente} & Re > 2,300 \end{array} \right]$$

es importante considerar que para flujos laminares Nu_D adquiere un valor constante de 4.364.

La eficiencia térmica en un CCP puede ser calculada realizando un balance de energía en el receptor. La energía útil (Q_u) entregada por el CCP puede ser estimada mediante:

$$Q_u = G_b \eta_o A_a - A_r U_L (T_r - T_a) \quad (2.32)$$

Partiendo de esta ecuación la ganancia de energía por unidad de tiempo y longitud queda dada en términos de la temperatura del receptor (T_r):

$$q'_u = \frac{Q_u}{L} = \frac{G_b \eta_o A_a}{L} - \frac{A_r U_L (T_r - T_a)}{L} \quad (2.33)$$

en términos de la energía transferida al fluido a la temperatura local del fluido T_f (Kalogirou, 2004):

$$q'_u = \frac{\frac{A_r}{L}(T_r - T_f)}{\frac{D_o}{h_w D_i} + \left(\frac{D_o}{2k} \ln \frac{D_o}{D_i}\right)} \quad (2.34)$$

Despejando T_r en ambas ecuaciones (2.33 y 2.34) e igualando se obtiene:

$$q'_u = F' \frac{A_a}{L} \left[\eta_o G_b - \frac{U_L}{C_o} (T_f - T_a) \right] \quad (2.35)$$

en el cual el término F' es conocido como factor de eficiencia del colector, el cual está dado por:

$$F' = \frac{1/U_L}{\frac{1}{U_L} + \frac{D_o}{h_w D_i} + \left(\frac{D_o}{2k} \ln \frac{D_o}{D_i}\right)} = \frac{U_o}{U_L} \quad (2.36)$$

donde U_o es el coeficiente global de transferencia de calor:

$$U_o = \left[\frac{1}{U_L} + \frac{D_o}{h_w D_i} + \frac{D_o \ln(D_o/D_i)}{2k} \right]^{-1} \quad (2.37)$$

La temperatura T_r de la ecuación 2.32 puede ser reemplazada por la temperatura $T_{m,i}$ mediante el uso de un factor de remoción por lo que dicha ecuación puede ser reescrita como:

$$Q_u = F_R [G_b \eta_o A_a - A_r U_L (T_{m,i} - T_a)] \quad (2.38)$$

donde dicho factor de remoción se encuentra expresado como:

$$F_R = \frac{\dot{m} C_p}{A_r U_L} \left[1 - \exp \left(-\frac{U_L F' A_r}{\dot{m} C_p} \right) \right] \quad (2.39)$$

Por otra parte, la eficiencia térmica del CCP, se encuentra en función de la razón entre la energía producida y la energía recibida:

$$\eta_T = \frac{Q_u}{G_b A_a} \quad (2.40)$$

por lo tanto la eficiencia térmica a través de la primera ley de la termodinámica en un

CCP se encuentra dada por la expresión matemática (Kalogirou, 2004):

$$\eta_T = F_R \left[\eta_o - U_L \left(\frac{\Delta T}{G_b C_o} \right) \right] \quad (2.41)$$

donde $\Delta T = T_{m,i} - T_a$. Esta ecuación resulta ser muy similar a la ecuación de una recta ($y = mx + b$), lo cual posibilita obtener experimentalmente el valor del factor de remoción F_R y el coeficiente total de pérdida de calor U_L (Jaramillo et al., 2013), siendo $F_R U_L / C_o$ la pendiente de la recta y $F_R \eta_o$ el valor de intercepción en y (Stine y Harrigan, 2008; Duffie y Beckman, 2013). Así la ecuación 2.41 se representa gráficamente como una línea recta en función del parámetro de pérdida de calor $\Delta T / G_b$, como se observa en la Figura 2.8.




Figura 2.8: Curvas experimentales de eficiencia térmica en CCPs (Jaramillo et al., 2013).

2.2. Evaluación térmica para CCPs

El desempeño térmico de un CCP puede ser determinado por el análisis detallado de las características térmicas y ópticas de los materiales empleados para su diseño. Sin embargo, la exactitud del análisis térmico depende de la incertidumbre de los coeficientes de transferencia de calor que son difíciles de obtener debido a las condiciones de frontera de temperatura no uniformes que existen en los CCPs. Por tal motivo, este tipo de análisis debe ser llevado a cabo mediante el desarrollo de prototipos, mismos que son probados bajo condiciones ambientales específicas y son indispensables para conocer el comportamiento térmico del colector (Kalogirou, 2009).

De entre los diversos estándares existentes para la evaluación térmica, los más conocidos son el ISO 9806-1:1994 (ISO 9806-1:1994, 1994) y el estándar ANSI/ASHRAE 93:2003 (ANSI/ASHRAE 93-2003, 2003). En ambos se indica que el comportamiento térmico del CCP se encuentra determinado parcialmente por el valor de la eficiencia térmica instantánea para diferentes combinaciones de radiación incidente, temperatura ambiente y temperatura de entrada del fluido de trabajo (Kalogirou, 2009). Esto requiere la medición experimental de la radiación que llega al colector así como la energía transferida al fluido.

Los estándares ISO 9806-1:1994 y ANSI/ASHRAE 93:2003 dan información sobre las pruebas de captadores de energía solar con líquidos de una sola fase. Los datos se pueden utilizar para predecir el rendimiento de los captadores en cualquier ubicación o bajo cualquier condición climática, donde la carga, el tiempo y la insolación son conocidos. (Kalogirou, 2004).

2.2.1. Estándar ANSI/ASHRAE 93:2003

Para llevar a cabo la evaluación térmica mediante este estándar es necesario cumplir las siguientes condiciones (ANSI/ASHRAE 93-2003, 2003):

- El módulo debe ser montado y operado de tal forma que se encuentre en condiciones normales de operación para poder determinar las pérdidas bajo tales

condiciones.

- El colector debe ser montado en un lugar donde no haya energía reflejada o reirradiada en el colector desde edificios o en la vecindad del colector.
- El flujo másico del fluido de trabajo debe ser constante durante las pruebas para determinar la eficiencia térmica, la constante de tiempo y el modificador del ángulo de incidencia.
- El fluido de trabajo debe tener una temperatura constante durante las pruebas.
- El ángulo de incidencia de la radiación directa debe estar en el rango de 2 % del valor de incidencia normal.

Por otra parte, para llevar a cabo las pruebas es necesario medir los siguientes parámetros (ANSI/ASHRAE 93-2003, 2003):

- Irradiación solar directa en la abertura del colector.
- Velocidad del viento sobre la abertura del colector.
- Temperatura ambiente.
- Temperatura del fluido a la entrada del colector.
- Temperatura del fluido a la salida del colector.
- Tasa de flujo másico.

El estándar ANSI/ASHRAE 93:2003 establece que las pruebas de eficiencia se ejecutan en un periodo de estado permanente o de 5 minutos. Además, el área de apertura del colector A_a debe ser medida con exactitud. A partir de ello el cálculo de la eficiencia térmica instantánea está dado por:

$$\eta_T = \frac{Q_u}{G_b A_a} \quad (2.42)$$

donde el calor útil Q_u puede obtenerse de manera experimental mediante la expresión:

$$Q_u = \dot{m} C_p (T_{salida} - T_{entrada}) \quad (2.43)$$

2.2.2. Constantes de tiempo

La constante de tiempo nos permite conocer el comportamiento transitorio del colector, esta representa el 63.2 % del valor de temperatura de salida en estado estacionario (Jaramillo et al., 2013). Para un CCP esta prueba consiste en circular agua por el colector a la misma tasa de flujo que en la prueba de eficiencia mientras está enfocado el colector y es entonces súbitamente desenfocado hasta que la temperatura a la salida del colector llega a un estado estacionario o cuasi-estacionario. La temperatura del agua que entra al colector debe ser muy cercana a la temperatura ambiente (Venegas Reyes, 2014). Para obtener de manera experimental la constante de tiempo la temperatura del agua a la entrada y a la salida del colector son constantemente monitoreadas hasta cumplir la relación (ANSI/ASHRAE 93-2003, 2003):

$$\frac{T_{ot} - T_i}{T_{oi} - T_i} = \frac{1}{e} = 0.368 \quad (2.44)$$

donde T_i es la temperatura del fluido a la entrada del CCP; T_{ot} es la temperatura del fluido a la salida en un tiempo t y T_{oi} es la temperatura de salida cuando el colector se desenfoca.

Capítulo 3

MODELACIÓN MATEMÁTICA DE LA EFICIENCIA TÉRMICA

Para la generación del modelo matemático destinado a la predicción de la eficiencia térmica del arreglo de CCPs, se empleó como herramienta de modelado las RNAs. Por tal motivo, en primera instancia es necesario contar con una base de datos experimental proveniente de un arreglo de concentradores de canal parabólico para llevar a cabo el proceso denominado como entrenamiento de la RNA. Los resultados de la base de datos fungirán como los parámetros de entrada de la red neuronal, para así, con la aplicación de determinados criterios estadísticos, cerciorar la precisión de los resultados y la exactitud del modelo matemático obtenido.

3.1. Equipo experimental

El equipo experimental del cual se obtuvo la base de datos para el entrenamiento de la red neuronal está basado en una planta generadora de vapor de baja entalpía desarrollada por Oscar Jaramillo y Eduardo Venegas (Jaramillo et al., 2013) en el Instituto de Energías Renovables de la Universidad Nacional Autónoma de México (IER-UNAM); la planta se encuentra compuesta por un arreglo de cinco CCPs, dos de ellos con ángulo de borde de 45° y tres con ángulo de 90° . Los concentradores poseen una longitud de $2.44m$, un área de apertura de aproximadamente $2.6m^2$ y una razón de concentración cercana a 14.

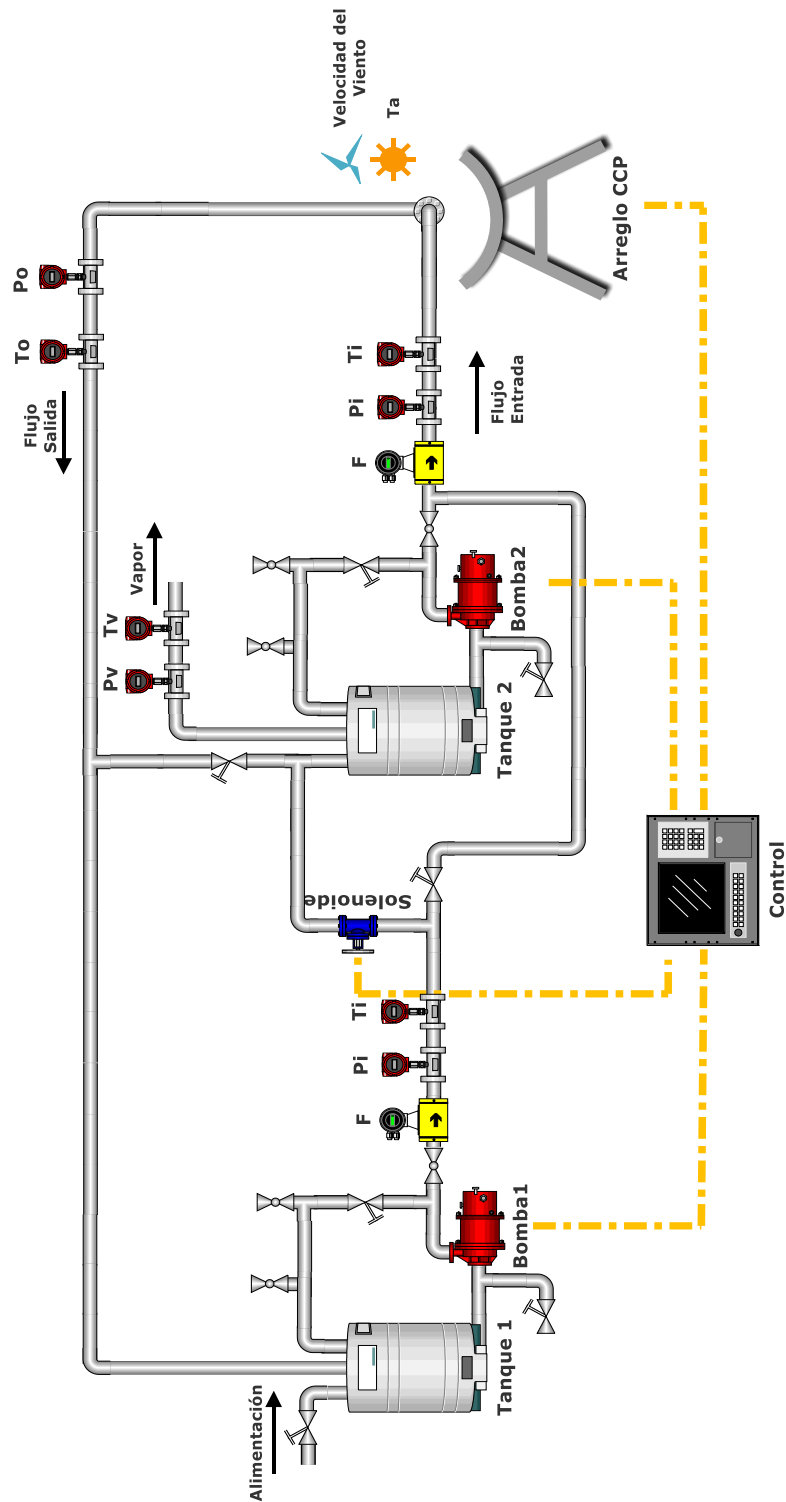


Figura 3.1: Diagrama esquemático de operación del equipo experimental basado en una planta generadora de vapor de baja entalpía.

El equipo fue construido para proporcionar agua precalentada para la caracterización de los CCPs, y al mismo tiempo actuar como almacenador de energía. Este se encuentra conformado por dos tanques de almacenamiento térmico con capacidad de 120 Litros, un sistema de calentamiento eléctrico (con controlador de temperatura automático), y un circuito hidráulico.

El sistema puede proporcionar agua caliente con temperaturas en un rango que va desde la temperatura ambiente hasta aproximadamente $90^{\circ}C$. El agua en los tanques de almacenamiento es calentada por resistencias eléctricas de $3kW$ y $6kW$ para el primer y segundo tanque respectivamente. La temperatura del agua es controlada por un sistema de control de temperatura que se retroalimenta mediante las mediciones de termopares localizados en el interior de los tanques. El agua precalentada es alimentada hacia el arreglo de CCPs por una bomba centrífuga de $1/2 hp$. El flujo de temperatura es controlado por una válvula de aguja y monitoreado por un flujómetro Hedland serie HB2800. Por otra parte, la temperatura y la presión son también monitoreadas a la salida del tanque de almacenamiento. Además el agua puede ser recirculada al tanque de almacenamiento con el propósito de incrementar la velocidad de calentamiento y generar una temperatura más uniforme. Con respecto a los parámetros ambientales, un pirheliómetro Eppley modelo NIP fue empleado para la medición de la radiación solar directa. Por último, la adquisición de datos es completada por un sistema Agilent 34970A el cual permite almacenar y visualizar la información en tiempo real. La Figura 3.1 muestra un diagrama esquemático del equipo experimental descrito.

3.2. Desarrollo del modelo matemático

Con el propósito de generar un modelo matemático que permita llevar a cabo una adecuada estimación de la eficiencia térmica del arreglo de CCPs, se diseñó la metodología descrita en el algoritmo de la Figura 3.2.

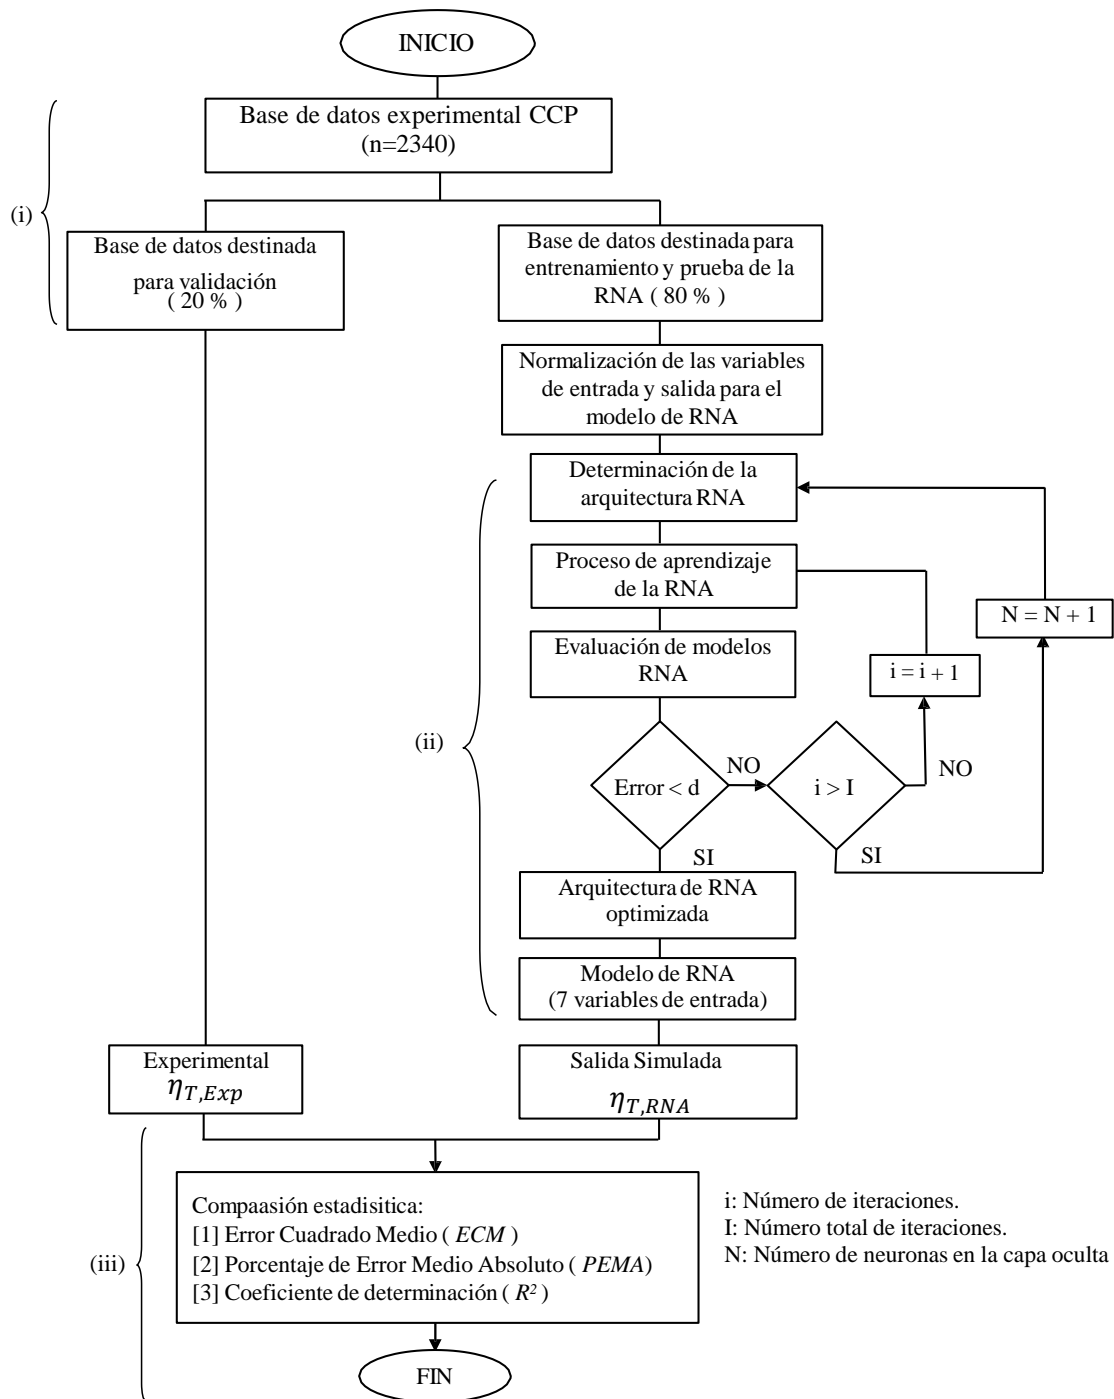


Figura 3.2: Metodología computacional para la obtención del modelo de predicción de eficiencia térmica.

Como se puede observar, dicha metodología computacional se encuentra conformada por tres procesos fundamentales: a) Creación de una base de datos con variables experimentales obtenidas durante la operación del sistema de concentración solar cilíndrico parabólico; b) Desarrollo y evaluación de diversos modelos de RNA para la predicción fiable de la eficiencia térmica (η_T) del arreglo de concentradores solares cilíndrico parabólico bajo estudio; c) Determinación de la eficiencia térmica (η_T) utilizando el Modelo RNA óptimo obtenido a través de comparación estadística.

3.2.1. Creación de la base de datos

Durante la operación de los CCPs se generó una base de datos conformada por diversos valores de eficiencia térmica (η_T), calculados a través de las ecuaciones para evaluación térmica en CCPs (Ec. 2.42 y Ec. 2.43). Del mismo modo, también se generó un conjunto de datos experimentales compuesto por múltiples parámetros divididos en dos categorías: Las variables operacionales, conformada por los valores del ángulo de borde (φ_r), las temperaturas de entrada (T_{ent}) y temperatura de salida (T_{sal}) del fluido de trabajo que circula a través de los CCPs, así como el flujo másico del fluido de trabajo (F_w); y las variables ambientales entre las que se encuentran la temperatura ambiente (T_{amb}), la radiación solar directa (G_b) y la velocidad del viento (V_w). Obteniendo así una base de datos conformada por 2340 muestras, las cuales fueron suficientes para el entrenamiento y prueba de la RNA. La Tabla 3.1, muestra los 8 parámetros que conforman esta base de datos así como los valores máximos y mínimos de cada uno.

Una vez obtenido dicho conjunto de datos, estos son divididos aleatoriamente en dos partes, en las cuales 80 % fue destinado al proceso de entrenamiento de la RNA y el 20 % restante fue empleado para las fases de validación y prueba, todo esto con el propósito de obtener un subconjunto representativo de la distribución de los datos. Por otra parte, debido a que la problemática que se plantea resolver se encuentra ligada a un problema altamente no lineal, se propone una función de activación sigmoidea (función Tansig) para su uso en la capa oculta de la RNA (Tabla 1.1), por lo cual, debido a la naturaleza de esta función, todas las muestras deben de ser normalizadas

en un rango de 0-1. Así, el total del conjunto de datos de entrada de la RNA X_i (destinados tanto al entrenamiento, como la validación y pruebas) es escalado en un valor normalizado x_N dado por (Bassam et al., 2014):

$$x_{i,N} = \frac{X_i}{1.1 \times X_{max}} \quad (3.1)$$

Tabla 3.1: Parámetros empleados en la estimación del modelo de RNA.

Parámetros		Mínimo	Máximo	Unidades
Parámetros de entrada				
<i>Parámetros operacionales:</i>				
Angulo de borde	(φ_r)	45.00	90.00	[°]
Temperatura de entrada	(T_{ent})	27.75	86.29	[°C]
Temperatura de salida	(T_{sal})	32.01	100.12	[°C]
Flujo del fluido de trabajo	(F_w)	1.00	6.00	[l/min]
<i>Parámetros ambientales:</i>				
Temperatura ambiente	(T_{amb})	24.62	36.60	[°C]
Radiación solar directa	(G_b)	653.8	1014.0	[W/m ²]
Velocidad del viento	(V_w)	0.93	3.98	[m/s]
Parámetro de salida				
Eficiencia térmica	(η_T)	0.17	0.74	[-]

3.2.2. Desarrollo y evaluación del modelo de RNA

Para la obtención del modelo matemático que mejor estime la η_T del arreglo de concentradores solares de canal parabólico fueron realizados diversos entrenamientos de RNA a partir de la base de datos experimental obtenida. Los entrenamientos llevados a cabo emplearon una red caracterizada por una capa de entrada con siete variables (ángulo de apertura (φ_r) , temperatura de entrada (T_{ent}) y salida (T_{sal}) del fluido de trabajo que ingresa a los CCPs, temperatura ambiente (T_{amb}) , radiación solar directa (G_b) , velocidad del viento (V_w) y flujo del fluido de trabajo (F_w)), una capa oculta y una capa de salida conformada por una sola variable (η_T) .

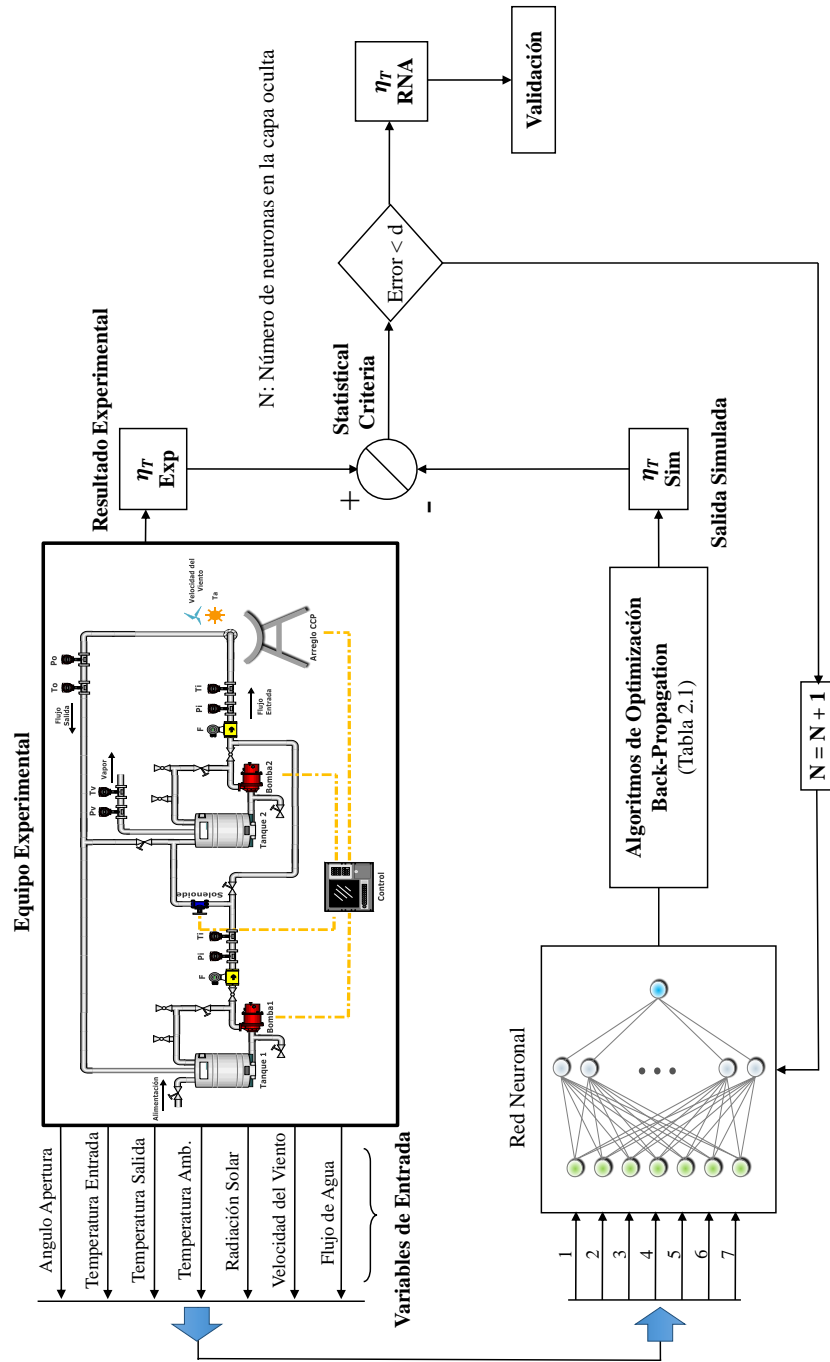


Figura 3.3: Procedimiento numérico empleado para el proceso de aprendizaje de la RNA, y la arquitectura iterativa usada por el modelo para predecir la eficiencia térmica en un arreglo de CCPs.

La Figura 3.3 muestra el algoritmo implementado para la obtención de la arquitectura neuronal del modelo matemático óptimo. Como se puede observar el proceso inicia con el ingreso de la base de datos normalizada a una arquitectura neuronal, la cual inicialmente posee una sola neurona en la capa oculta. Posteriormente comienza el proceso de entrenamiento empleando el algoritmo back-propagation con el objetivo de obtener los pesos y bias que mejor se ajusten al modelo de RNA. Una vez completado el entrenamiento una comparación estadística entre los datos de eficiencia térmica experimental y simulada es realizada, de no cumplir un determinado criterio estadístico la arquitectura de red es reestructurada añadiendo una nueva neurona en la capa oculta, proceso que se repite iterativamente hasta cumplir el criterio establecido. Así por último, una vez cumplida dicha condición se procede a la validación de los resultados obtenidos tras el entrenamiento de la RNA.

3.2.3. Comparación bajo criterios estadísticos

Los resultados numéricos obtenidos tras el entrenamiento de la RNA son comparados estadísticamente respecto a los datos experimentales. Con el fin de llevar a cabo este análisis los parámetros de prueba estadísticos empleados son el Error Cuadrado Medio (*ECM*), Porcentaje de Error Medio Absoluto (*PEMA*) y el Coeficiente de Determinación (R^2), los cuales están dados por:

$$ECM = \sqrt{\frac{\sum_{i=1}^n (\eta_{T,Exp(i)} - \eta_{T,RNA(i)})^2}{n}} \quad (3.2)$$

$$PEMA = \frac{\sum_{i=1}^n \left| \frac{\eta_{T,Exp(i)} - \eta_{T,RNA(i)}}{\eta_{T,Exp(i)}} \right|}{n} \times 100 \quad (3.3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (\eta_{T,Exp(i)} - \eta_{T,RNA(i)})^2}{\sum_{i=1}^n (\eta_{T,Exp(i)} - \bar{\eta}_{T,Exp})^2} \quad (3.4)$$

en donde $\bar{\eta}_{T,Exp} = \frac{1}{n} \sum_{i=1}^n \eta_{T,i}$; $\eta_{T,RNA(i)}$ es el valor estimado por la RNA y $\eta_{T,Exp(i)}$ es el valor experimental de la variable (η_T).

El *EMC* es frecuentemente usado para medir la diferencia entre valores estimados por un modelo matemático y los valores reales (Verma, 2005). El indicador *PEMA* computa el promedio de error porcentuales (%) por el cual las estimaciones predecidas de una variable difieren respecto de su valor real (Garson, 1999). Por último, la R^2 representa la fuerza de proporción lineal de viabilidad en un conjunto de datos, frecuentemente visualizado como un número entre 0 y 1, en el cual mientras más cercano se encuentre de 1 indica un mejor ajuste de la simulación a los datos experimentales.

3.3. Determinación del modelo matemático óptimo

Con el objetivo de determinar el mejor algoritmo para el entrenamiento de la RNA, diez algoritmos back-propagation (Tabla 1.2) fueron probados empleando el procedimiento numérico descrito en la Figura 3.3 utilizando un número máximo de 2100 iteraciones. La Figura 3.4, muestra la comparativa de los criterios estadísticos aplicados a los mejores resultados obtenidos en cada algoritmo back-propagation para cada neurona adicionada en la capa oculta.

Las Figuras 3.4(a) y 3.4(b), muestran los resultados del *ECM* y el *PEMA* respectivamente para los algoritmos de entrenamiento probados. Como se puede observar en ambas imágenes el algoritmo que presenta la menor diferencia existente entre los valores experimentales estimados, así como el mínimo porcentaje de error computado fue el algoritmo Levenberg-Marquardt (LM) (que es una versión modificada del método de Newton mediante el que se estima una aproximación de segundo orden (Hagan y Menhaj, 1994)), el cual presentan un comportamiento notable para la adaptación a los resultados experimentales conforme incrementa el número de neuronas de la capa oculta respecto a los demás algoritmos evaluados. De la misma forma en la Figura 3.4(c) es posible observar que el algoritmo que presenta los mejores resultados de correlación, respecto a los valores pertenecientes a la base de datos, resulta ser nuevamente el algoritmo Levenberg-Marquardt obteniendo valores de correlación extremadamente cercanos a la unidad. Por lo tanto a partir de los resultados obtenidos tras la aplicación de los tres criterios estadístico se determina que el algoritmo back-propagation a utilizar para el modelado matemática de la η_T es el algoritmo LM.

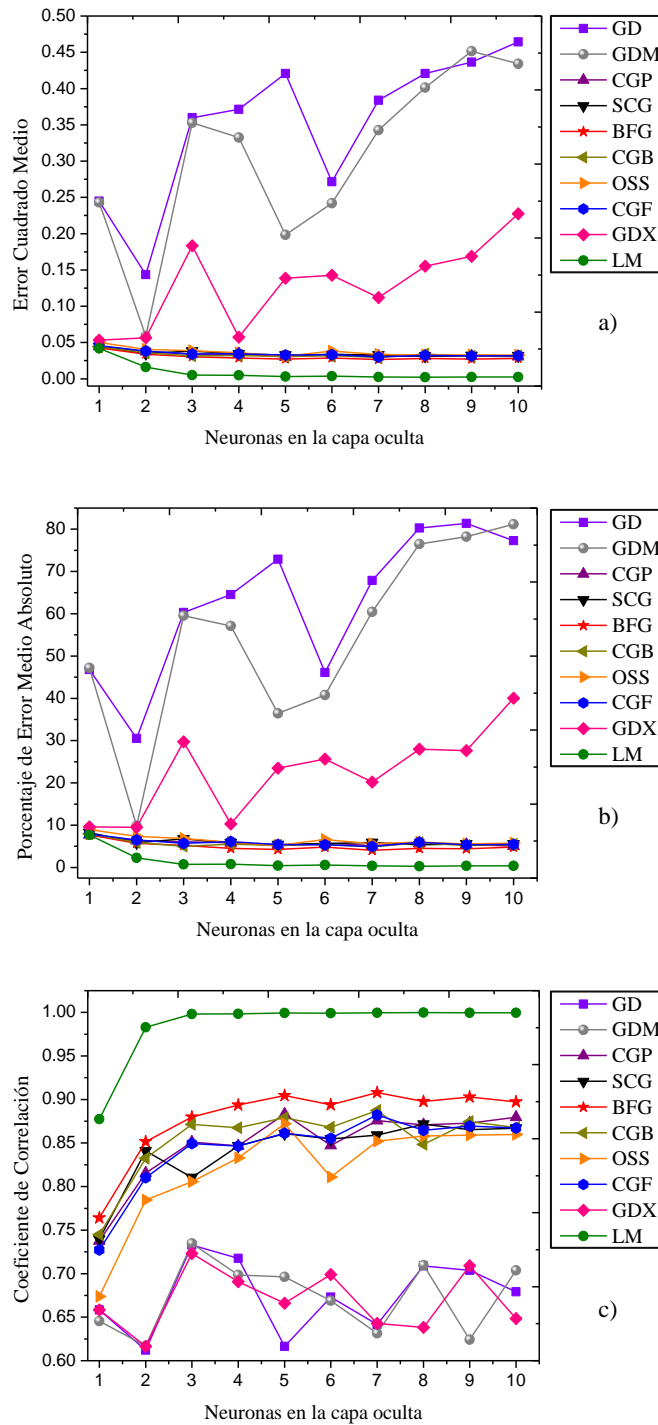


Figura 3.4: Resultados obtenidos entre los 10 algoritmos de entrenamiento back-propagation. a) Error cuadrado medio. b) Porcentaje de error medio absoluto. c) Coeficiente de correlación.

Tabla 3.2: Evaluación de diversas arquitecturas para el algoritmo Levenberg - Marquardt.

Arquitectura	Épocas	ECM	PEMA %	R^2	Ecuación Lineal
7-01-1	2100	0.04194	7.69973	0.77004	$y = 0.769x + 0.11340$
7-02-1	2100	0.01606	2.28141	0.96629	$y = 0.964x + 0.17400$
7-03-1	2100	0.00514	0.75312	0.99654	$y = 0.996x + 0.00210$
7-04-1	2100	0.00480	0.77315	0.99699	$y = 0.994x + 0.00280$
7-05-1	2100	0.00303	0.42537	0.99880	$y = 0.998x + 0.00110$
7-06-1	2100	0.00368	0.57427	0.99823	$y = 0.997x + 0.00130$
7-07-1	2100	0.00235	0.37063	0.99928	$y = 0.998x + 0.00073$
7-08-1	2100	0.00219	0.29361	0.99938	$y = 1.000x - 0.000045$
7-09-1	2100	0.00238	0.36487	0.99928	$y = 1.000x - 0.00043$
7-10-1	2100	0.00257	0.39765	0.99914	$y = 0.999x + 0.00370$

La Tabla 3.2, muestra los resultados de los tres criterios estadísticos aplicados a los entrenamientos con diverso número de neuronas en la capa oculta para el mejor algoritmo de entrenamiento empleado (LM). Como se puede observar a partir de dicha Tabla la mejor estimación de la eficiencia térmica (η_T) es obtenida utilizando ocho neuronas en la capa oculta, generando así una arquitectura de red 7-8-1 (Figura 3.5).

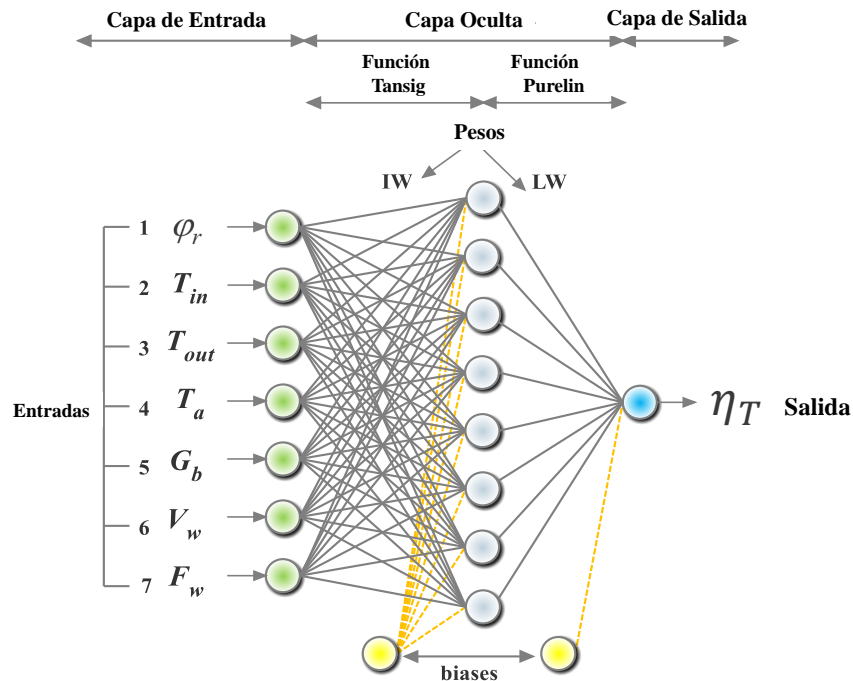


Figura 3.5: Arquitectura óptima de RNA para la estimación de los valores de eficiencia térmica.

De la misma manera, de acuerdo a los resultados obtenidos en la Tabla 3.2, esta arquitectura de red es la que presenta el menor *ECM* y *PEMA* en los procesos de entrenamiento y prueba de la RNA (0.00219 y 0.29361 % respectivamente); así como el coeficiente de determinación más alto ($R^2 = 0.99938$). La Figura 3.6 presenta una comparación entre los valores experimentales y simulados de la eficiencia térmica (η_T) empleando los datos tanto del proceso de entrenamiento como en el de prueba. Así la información experimental ($\eta_{T,Exp}$) y simulada ($\eta_{T,RNA}$) fue comparada satisfactoriamente a través del modelo de regresión lineal dado por:

$$\eta_{T,RNA} = 1.000\eta_{T,Exp} - 0.000045 \quad (3.5)$$

en donde se puede observar que la pendiente de la Ec. 3.5 es igual a la unidad, y la ordenada es muy cercana a cero, lo que indica un perfecto ajuste lineal descrito por el coeficiente de determinación.

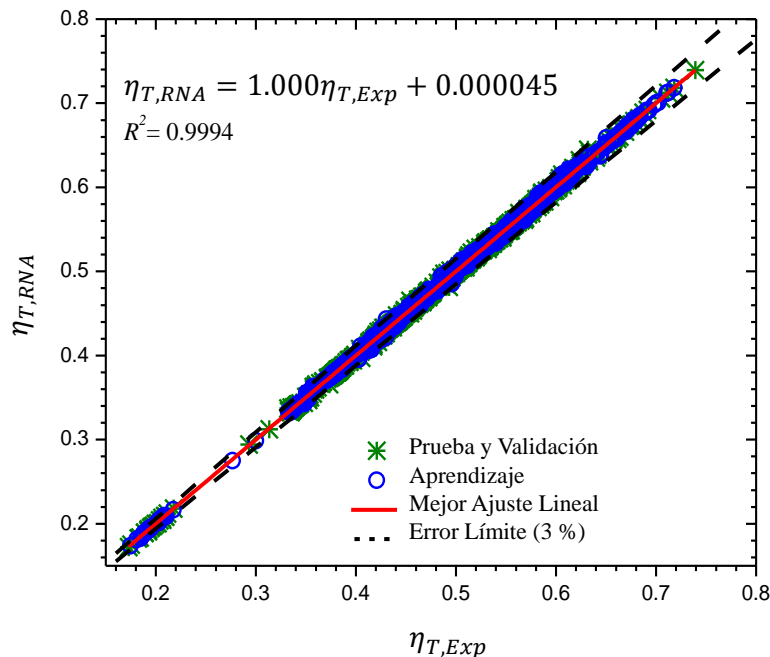


Figura 3.6: Comparación estadística entre datos de η_T simulados y experimentales.

En la Tabla 3.3 se encuentran resumidos los valores de los pesos y bias óptimos

computados durante el entrenamiento de la RNA, de los cuales IW representa los pesos de conexión de la capa de entrada a la capa oculta, LW son los pesos de conexión de la capa oculta a la capa de salida, N indica el número total de neuronas en la capa oculta ($N=8$), K el número total de variables de entrada ($K=7$), y $b1$ y $b2$ los factores de bias. Por lo tanto basado en la arquitectura de RNA desarrollada (Figura 3.5), las funciones Tangente Hiperbólica Sigmoidea para la capa oculta y la función Lineal para la capa salida (descritas en la Tabla 1.1) y los valores de la Tabla 3.3. El modelo matemático propuesto puede ser representado analíticamente por la siguiente ecuación:

$$\eta_T = \sum_{j=1}^S \left[LW(j) \left(\frac{2}{1 + \exp\left(-2 \left(\sum_{k=1}^K (IW(j, k) \cdot In(k)) + b1(j)\right)\right)} - 1 \right) \right] + b2 \quad (3.6)$$

en la cual LW , IW , $b1$, $b2$, K y S , se encuentran descritos en la Tabla 3.3 e In es el valor del parámetro de entrada correspondiente.

Tabla 3.3: Pesos y bias óptimos del modelo matemático desarrollado para la estimación de η_T .

Neuronas (N) [†]	Pesos							Capa de Salida LW (n, 1)	Bias	
	Capa Oculta (S = 8, K = 7) IW (s, k)								η (n, l)	b1 (n)
	φ_r (k=1)	T_{ent} (k=2)	T_{sal} (k=3)	T_{amb} (k=4)	F_w (k=5)	G_b (k=6)	V_w (k=7)			
1	7.1056	-4.1085	-2.1620	3.4797	-0.6476	3.5207	1.2528	-0.0545	-8.2425	-1.5771
2	-1.9429	3.1220	-3.6847	-0.5089	-1.4720	0.2909	0.0499	-2.4889	3.6552	
3	-3.7260	2.4274	0.0990	-0.2155	0.3268	6.3771	0.9715	-0.1325	-2.7555	
4	1.6812	3.9978	-4.6012	0.2657	1.0336	0.0746	-0.0672	-3.6837	-2.9277	
5	-0.6422	7.0992	-8.1307	1.7822	-2.3032	-0.6889	-0.5881	-0.1938	1.8988	
6	-1.0869	2.5007	-2.9266	-0.1740	1.4525	0.2752	0.0823	1.2936	1.2772	
7	0.2934	2.3683	-0.1420	3.9601	-0.8779	0.4908	-4.6866	0.0110	-1.9622	
8	-3.5454	2.8972	-3.3031	-0.5604	0.3693	1.7456	0.2405	-0.4480	0.9991	

[†] n es el número de neuronas en la capa oculta, k es el número de neuronas en la capa de entrada, l es el número de neuronas en la capa de salida (l = 1).

Capítulo 4

ANÁLISIS DE RESULTADOS

Una vez obtenido el modelo matemático que permita predecir la eficiencia térmica del arreglo de concentradores solares de canal parabólico (Ec. 3.6) es necesario llevar a cabo un proceso a través del cual sea posible validar bajo diversas condiciones la efectividad que presenta el modelo desarrollado. Por otra parte, mediante el uso de la base de datos experimental y los valores de los pesos y bias óptimos obtenidos tras el entrenamiento de la RNA (Tabla 3.2), es posible identificar la importancia relativa que posee cada una de las variables de entrada respecto a la eficiencia térmica mediante un proceso denominado análisis de sensibilidad.

4.1. Validación del modelo matemático para predicción de eficiencia térmica

Con el propósito de comprobar la efectividad de predicción del modelo matemático generado por la RNA, se realizó una comparación entre la eficiencia térmica experimental y la obtenida a través de la simulación, en la cual los datos experimentales empleados no formaron parte del entrenamiento de la RNA con el fin de evitar sesgos. La Figura 4.1 muestra una gráfica de los valores experimentales de eficiencia térmica empleados en la validación, para CCPs con ángulo de apertura de 45° (Figura 4.1(a)) y 90° (Figura 4.1(b)), en función del parámetro de pérdida de calor ($\Delta T/G_b$) y el flujo másico del agua (F_w).

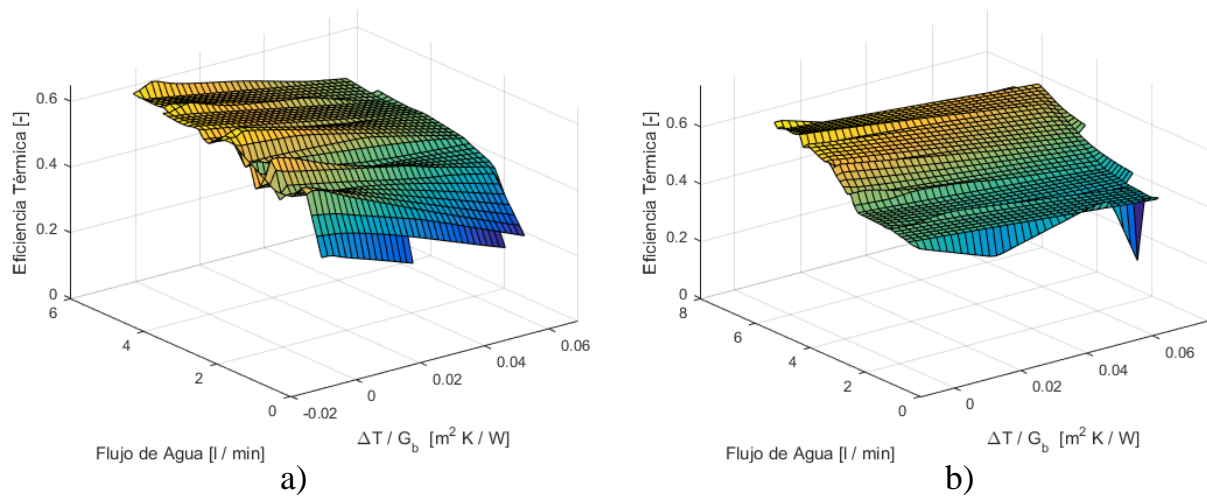


Figura 4.1: Perfiles de mediciones experimentales de η_T no incluidas en el proceso de entrenamiento de la RNA. a) CCPs con $\varphi_r = 45^\circ$. b) CCPs con $\varphi_r = 90^\circ$.

La Figura 4.1 permite visualizar el comportamiento no lineal de la η_T en el arreglo de CCPs para los ángulos de apertura de 45° y 90° . Además, como se puede apreciar en dicha figura los valores de eficiencia térmica mas altos, independientemente del ángulo de apertura, son obtenidos empleando los mayores valores de flujo de agua. Del mismo modo, también es posible observar que el incremento de la eficiencia térmica está relacionado con la disminución del parámetro de perdida de calor, alcanzando su valor óptimo cuando este tiende a cero, esto último equivale a que la temperatura del agua de entrada de los CCPs (T_{ent}) sea lo más cercana posible al valor de la temperatura ambiente (T_{amb}).

Por otra parte, la Figura 4.2 muestra la comparativa de gráficas entre los resultados simulados y experimentales de la eficiencia térmica para los CCPs con ángulo de apertura (φ_r) de 45° ; donde las imágenes de las Figuras 4.2(a1) y 4.2(a2) representan los valores de η_T experimental desde una vista en tres dimensiones y vista de planta respectivamente. Por otro lado, las Figuras 4.2(b1) y 4.2(b2) representan a sus respectivas contrapartes de eficiencia térmica simulada. De manera similar, la Figura 4.3, muestra la comparación entre los valores experimentales para los concentradores solares de canal parabólico con con ángulo de apertura (φ_r) de 90° (Figura 4.3(a1) y

4.3(a2)) y los valores simulados de eficiencia térmica generados por el modelo matemático (Figura 4.3(b1) y 4.3(b2)).

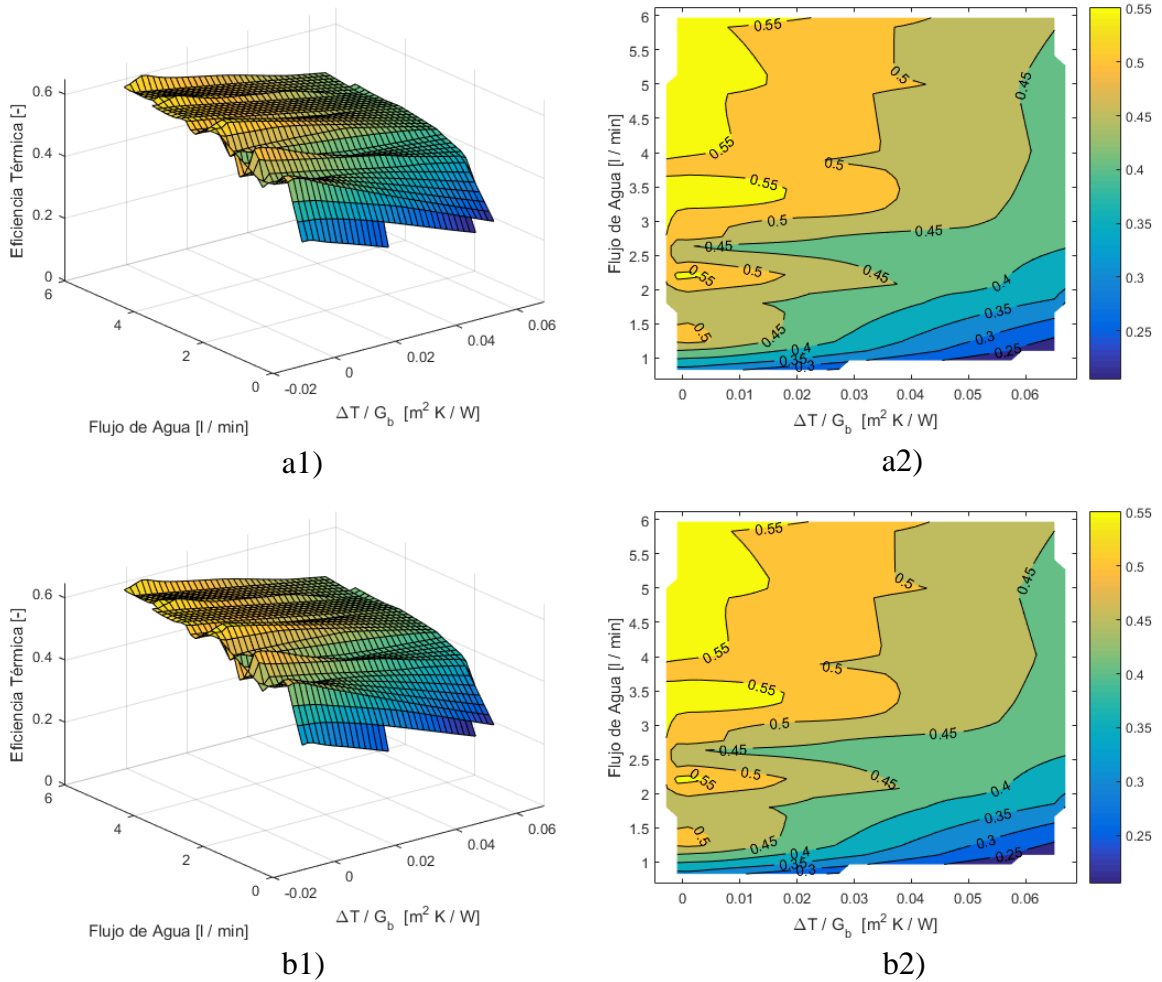


Figura 4.2: Validación de los resultados del modelo matemático para $\varphi_r = 45^\circ$. a1) η_T experimental en función del flujo de agua y el parámetro de pérdida de calor. a2) Perfil de planta de η_T experimental en función del flujo de agua y el parámetro de pérdida de calor. b1) η_T simulada en función del flujo de agua y el parámetro de pérdida de calor. b2) Perfil de planta de η_T simulada en función del flujo de agua y el parámetro de pérdida de calor.

Como se puede apreciar en ambas figuras (Figura 4.2 y Figura 4.3), el comportamiento descrito por las gráficas experimentales en tres dimensiones es prácticamente emulado por las reconstrucciones realizadas a través del modelo matemático tanto

para los CCPs con ángulo de apertura de 45° como los de 90° , lo cual indica que de manera general el modelo presenta una perfecta adaptación a las variaciones de los diversos parámetros de entrada. Por otra parte, en las imágenes de vista de planta (Figuras 4.2(a2) y 4.2(b2) para los CCPs con $\varphi_r = 45^\circ$; y 4.3(a2) y 4.3(b2) para los CCPs con $\varphi_r = 90^\circ$) se puede apreciar con mayor claridad la variación de la eficiencia térmica para los dos ángulos de borde.

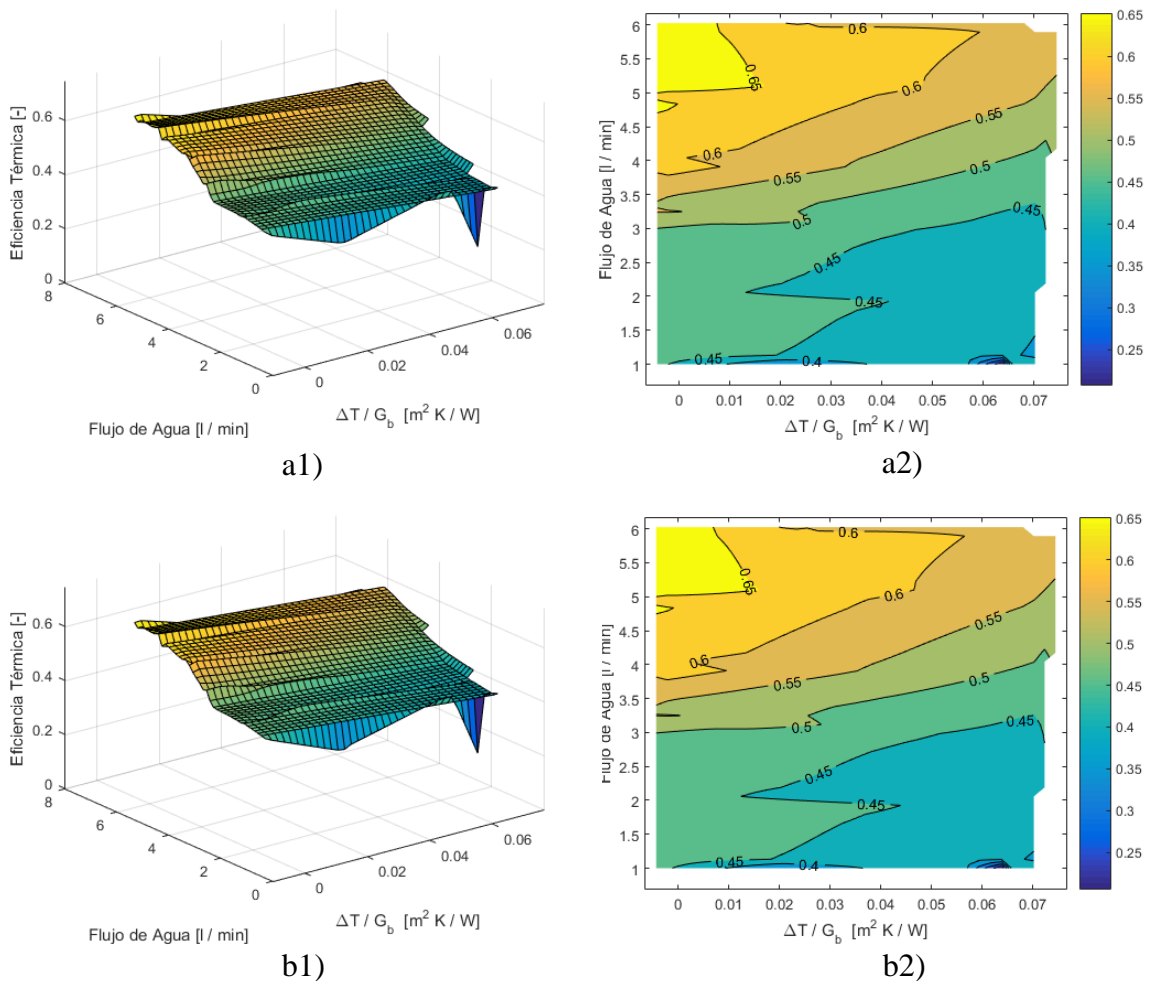


Figura 4.3: Validación de los resultados del modelo matemático para $\varphi_r = 90^\circ$. a1) η_T experimental en función del flujo de agua y el parámetro de pérdida de calor. a2) Perfil de planta de η_T experimental en función del flujo de agua y el parámetro de pérdida de calor. b1) η_T simulada en función del flujo de agua y el parámetro de pérdida de calor. b2) Perfil de planta de η_T simulada en función del flujo de agua y el parámetro de pérdida de calor.

En ambas comparaciones se puede observar que los resultados simulados generados por el modelo matemático se ajustan casi perfectamente a los valores descritos por las mediciones experimentales donde las diferencias presentes entre ambos resultan ser mínimas lo cual concuerda con el coeficiente de determinación obtenido ($R^2 = 0.99938$), y corrobora la información brindada por los otros dos parámetros estadísticos ($ECM = 0.00219$ y $PEMA = 0.29361$) descritos en la Tabla 3.2. De esta manera, mediante los resultados obtenidos por la comparación anterior, se determina que el modelo matemático generado mediante la arquitectura de RNA es viable para la predicción de la eficiencia térmica en CCPs, más aun dicho modelo es capaz de predecir η_T bajo las mejores condiciones de operación con lo cual posibilita el desarrollo de procesos de optimización utilizandolo como función objetivo para su solución mediante métodos heurísticos y numéricos.

4.2. Análisis de sensibilidad

El análisis de sensibilidad se encuentra enfocado a la medición del efecto que se observa en una salida y_k debido al cambio que se produce en una entrada x_i (Figura 4.4). Cuanto mayor efecto se observe sobre la salida, mayor sensibilidad se puede deducir que presenta respecto a la entrada (Montaño y Palmer, 2003).




Figura 4.4: Representación del análisis de sensibilidad.

Debido a que el producto de las RNAs son generalmente ecuaciones no lineales complejas, no resulta sencillo establecer la relaciones entre las variables dependientes e independientes, lo cual ha motivado desde 1980 a el desarrollo de diversos métodos destinados al análisis de sensibilidad entre los que destacan el algoritmo de Garson, el producto de pesos y el método de derivadas parciales; basados en la magnitud de los grupos de pesos producidos durante el entrenamiento de la red (Olden y Jackson, 2002; Montaña y Palmer, 2003).

4.2.1. El algoritmo de Garson

El algoritmo desarrollado por Daniel Garson (Garson, 1999) es una de las técnicas de análisis de sensibilidad más empleada en el desarrollo de trabajos relacionados con estudios ambientales y de energías renovables (Olden y Jackson, 2002; Bassam et al., 2012, 2014). Garson propuso una ecuación basada en el reparto del valor absoluto de los pesos de conexión dada por:

$$I_j = \frac{\sum_{m=1}^{Nh} \left(\left(|W_{jm}^{ih}| / \sum_{k=1}^{Ni} |W_{km}^{ih}| \right) \times |W_{mn}^{ho}| \right)}{\sum_{k=1}^{Ni} \left\{ \sum_{m=1}^{Nh} \left(|W_{jm}^{ih}| / \sum_{k=1}^{Ni} |W_{km}^{ih}| \right) \times |W_{mn}^{ho}| \right\}} \quad (4.1)$$

donde I_j es la importancia relativa de las j variables de entrada sobre las variables de salida, Ni y Nh son los números de neuronas de entrada y ocultas respectivamente y W son los pesos de conexión; los superfijos i, h y o hacen referencia a las capas de entrada, oculta y de salida respectivamente. Por último los subfijos k, m y n hacen alusión a las neuronas ubicadas en las capas de entrada, ocultas y de salida. De acuerdo a esta conexión la suma del porcentaje de importancia de relativa de las variables de entrada debe ser igual a 100%. Sin embargo, este no permite conocer si si la salida es impactada negativa o positivamente.

4.2.2. Producto de pesos de Tchaban

El producto de pesos de Tchaban (Tchaban et al., 1998) es la técnica más sencilla para la realización de un análisis de sensibilidad. Al igual que el Algoritmo de Garson

también está basada en la magnitud de los pesos de conexión. Este depende de la razón entre las variables de entrada x_i y las variables de salida y_k para estimar la influencia WP_{ik} mediante la siguiente ecuación:

$$WP_{ik} = \frac{x_i}{y_k} \sum_{m=1}^S IW_{i,m} LW_{m,k} \quad (4.2)$$

donde IW y LW representan los pesos de conexión entre la capa oculta y de entrada, y entre la capa de salida y oculta respectivamente; S es el número total de neuronas en la capa oculta; y los subfijos i, m y k hacen alusión a las neuronas ubicadas en la capa de entrada, oculta y de salida respectivamente. De acuerdo a la ecuación superior cada parámetro de entrada devuelve un producto de pesos distinto; razón por la cual la media aritmética y la desviación estándar son calculados para todos resultados de la base de datos entrenada para evaluar la influencia de las entradas (Vasilakos et al., 2008).

4.2.3. Método de derivadas parciales

Este método se basa en el hecho que mediante el cálculo de las derivadas parciales, la matriz Jacobiana puede ser evaluada para proporcionar la sensibilidad de las salidas (Bishop, 1995). La aplicación de este método permite obtener dos resultados. El primero proporciona un perfil de las variaciones de las salidas para pequeños cambios en cada variable de entrada; el segundo es una clasificación de la contribución relativa de cada variable a la entrada de la red (Gevrey et al., 2003).

Para obtener el perfil de las variaciones de salida para pequeños cambios de una variable de entrada S_{ik} , se computan las derivadas parciales de la salida de la RNA respecto a las entradas (Dimopoulos et al., 1999):

$$S_{ik} = \frac{\partial y_k}{\partial x_i} = f'(net_k) \sum_{m=1}^S LW_{m,k} f'(net_m) IW_{i,m} \quad (4.3)$$

donde $f'(net_k)$ y $f'(net_m)$ son las derivadas de la función de activación en la capa oculta y salida respectivamente. Como resultado de esta ecuación, un conjunto de gráficas

de las derivadas parciales respecto a sus valores de entrada pueden ser graficados y así conocer su influencia respecto de la salida. Si la derivada es negativa las salidas decrecerán conforme ésta incremente, por otro lado si la derivada parcial es positiva salida incrementará siempre que esta incremente.

Por otra parte, el segundo resultado está relacionado con la contribución relativa de la salida en la RNA respecto de la entrada. Esta se calcula mediante la sumatoria del cuadrado de cada una de las derivadas parciales obtenidas (Gevrey et al., 2003):

$$SSD_i = \sum_{m=1}^S (S_{ik})^2 \quad (4.4)$$

en el cual el valor más grande de SSD es la entrada que presenta la mayor contribución.

4.3. Determinación de la importancia de las variables de entrada

Con el propósito de determinar el nivel de impacto que presenta cada una de las siete variables de entrada consideradas para el cálculo de η_T en el modelo matemático generado mediante la RNA, se llevó a cabo un estudio de análisis de sensibilidad empleando los métodos de Garson, Tchaban y Derivadas Parciales, descritos en la Sección 4.2.

El primero de los tres métodos utilizados es el conocido como el algoritmo de Garson (Ec. 4.1), el cual fue empleado para conocer el porcentaje de impacto de las variables de entrada sobre η_T . La Figura 4.5 indica los resultados obtenidos tras la aplicación de este algoritmo. En dicha figura se puede observar que las variables que presentan los mayores impactos sobre la eficiencia térmica son la temperatura de salida y temperatura de entrada del flujo de agua en los CCPs (T_{sal} , 35% y T_{ent} , 31%); seguido por el ángulo de apertura de los concentradores (φ_r , 16%) y el flujo de agua en el sistema (F_w , 11%); finalmente, las contribuciones con menor impacto resultaron

ser la temperatura ambiente (T_{amb} , 3%), la radiación solar (G_b , 3%) y la velocidad del viento (V_w , 1%).

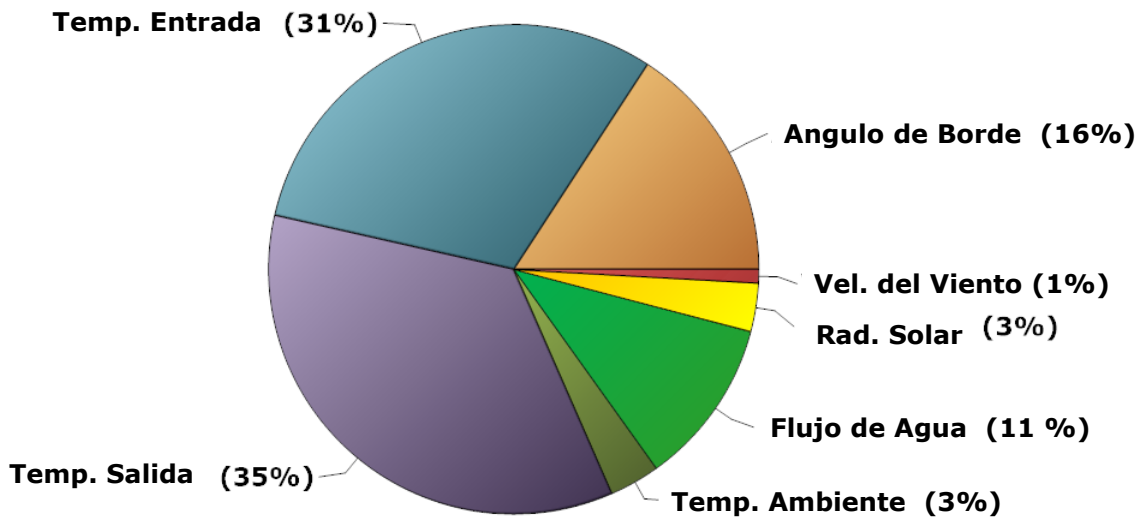


Figura 4.5: Impacto porcentual de las variables de entrada sobre η_T .

En adición la Tabla 4.1 muestra los resultados del análisis de sensibilidad obtenidos para los tres métodos (Garson, producto de pesos y derivadas parciales). Como se puede observar los valores generados mediante el método de productos de pesos (Ec. 4.2) indican que la relevancia de las variables de entrada guarda concordancia con los resultados obtenidos por el método de Garson; más aun, el signo que acompaña al valor promedio ayuda a determinar el tipo de impacto que posee cada variable sobre η_T . A partir de esto se concluye que mediante un incremento de la temperatura de salida del agua que circula a través de los CCPs (T_{sal}) o una variación en el flujo de agua es posible incrementar el valor la eficiencia térmica. Por otra parte, este mismo análisis indica que el aumento en los parámetros de ángulo de borde (φ_r), radiación solar (G_b), velocidad del viento (V_w), temperatura ambiente (T_{amb}) y temperatura de entrada del agua en los CCPs (T_{ent}) tiende a disminuir la η_T del sistema. Es importante señalar que aunque los resultados obtenidos por los métodos anteriores (Garson y producto de pesos) parecen contrastar la naturaleza de los sistemas fototérmicos debido a la baja influencia de la radiación solar; se debe considerar que la información experimental fue sensada en cortos periodos de tiempo con el fin de cumplir con la

norma ASHRAE 93-1986; por estos motivos para la obtención de los datos utilizados en el entrenamiento de la red neuronal, no hubo una variación significativa para las mediciones de radiación solar, velocidad del viento y temperatura ambiente.

Tabla 4.1: Resultados del análisis de sensibilidad.

Variables de Entrada	Algoritmo de Garson (%)	Producto de Pesos		Derivadas Parciales
		Promedio	DS	SSD
Angulo de Borde	15	-1.216	0.465	1,066.191
Temp. Entrada	31	-27.783	15.916	625,062.590
Temp. Salida	35	33.377	17.675	802,781.913
Temp. Ambiente	3	-0.237	0.064	18.946
Flujo de Agua	11	1.977	0.867	57601.308
Rad. Solar	3	-3.793	1.1.44	4428.594
Vel. Viento	1	-0.012	0.008	0.251

Por otra parte, se aprecia que los resultados obtenidos por el método de derivadas parciales varían poco con respecto a los dos métodos anteriores dando más importancia a la radiación solar como lo indica la Tabla 4.1. Sin embargo, el empleo del método de derivadas parciales permite realizar un estudio más detallado a partir de los valores obtenidos, mediante la aplicación de la Ec. 4.3, los cuales son mostrados, en función de sus respectivos parámetros de entrada normalizados, en las gráficas presentes en la Figura 4.6. La Figura 4.6(a) indica que la temperatura de entrada presenta un efecto negativo sobre la eficiencia térmica, el cual tiende ser muy fuerte debido a los valores indicados por las derivadas parciales. De la misma forma la Figura 4.6(b) indica que la T_{sal} del arreglo de CCPs posee también una fuerte influencia sobre el resultado de la RNA, pero al contrario de la T_{ent} esta contribuye al incremento de η_T . Respecto a la Figura 4.6(c) se observa que la T_{amb} presenta un efecto negativo sobre la eficiencia térmica, sin embargo considerando la escala de la gráfica se puede apreciar que dicho efecto es mínimo, concordando con lo obtenido mediante los métodos de Garson y Tchaban.

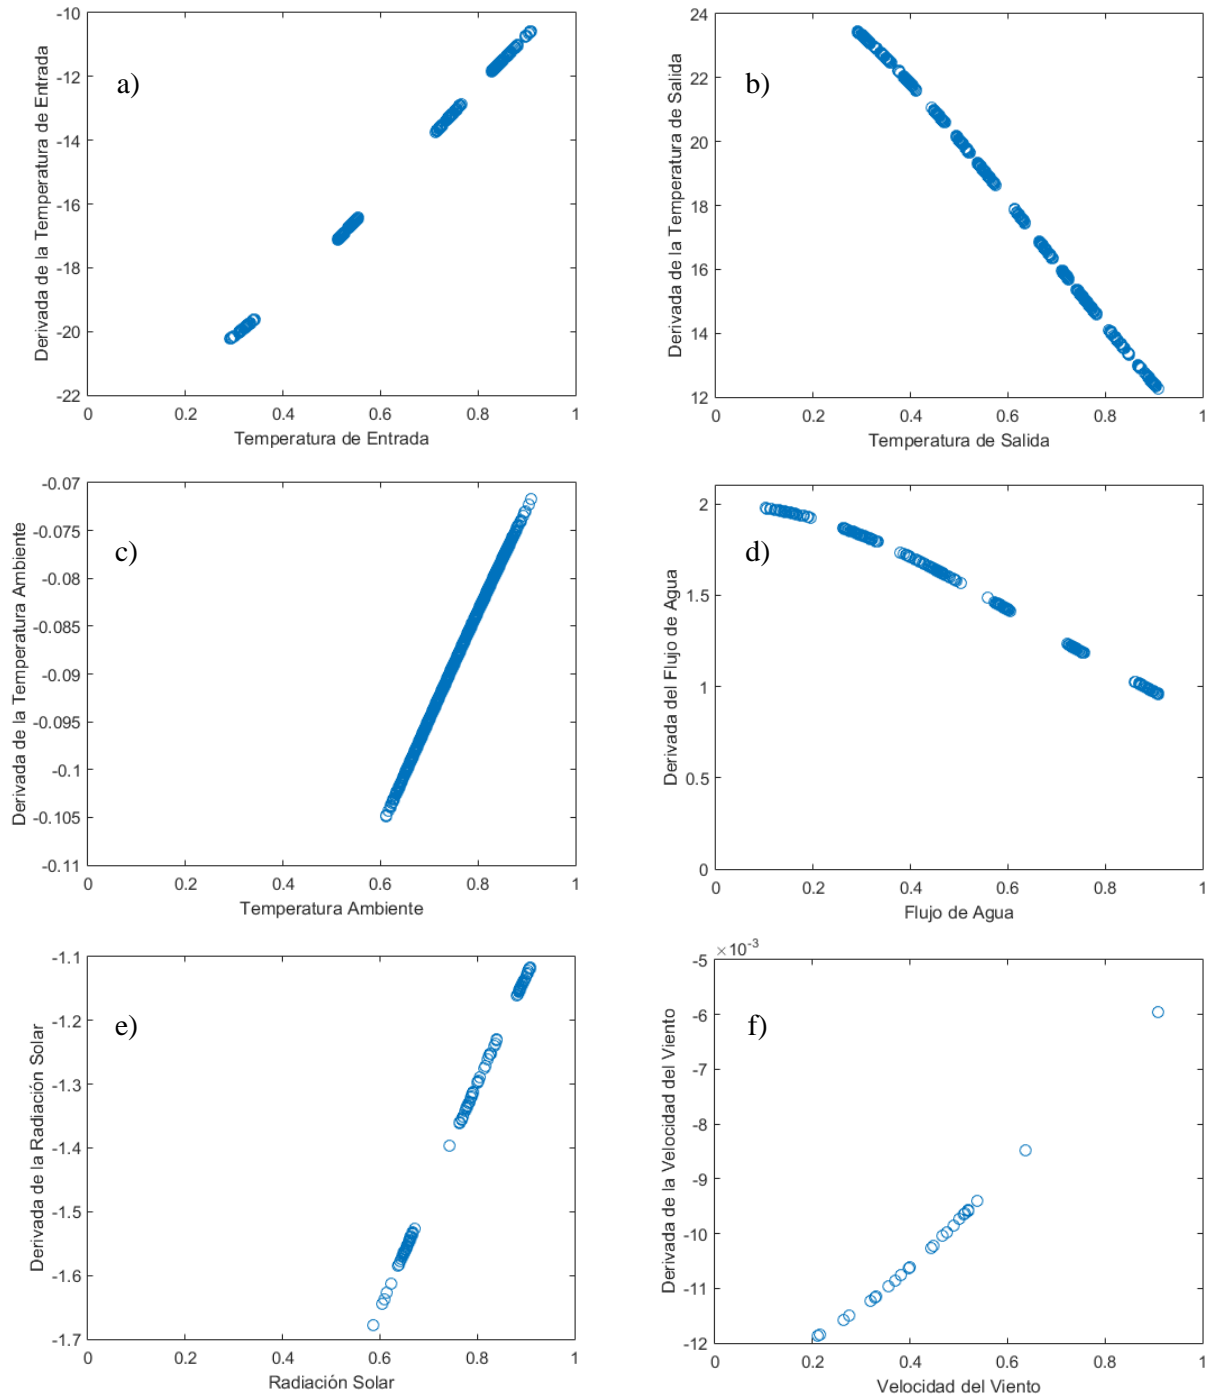


Figura 4.6: Derivadas parciales de las variables del modelo de red neuronal.

Por otra parte la Figura 4.6(d) muestra el comportamiento del flujo de agua el cual, como se puede apreciar, favorece de manera positiva el incremento de la eficiencia térmica. De esta manera es posible determinar que los parámetros que favorecen el incremento de la eficiencia térmica son la T_{sal} y F_w , donde los resultados obtenidos por éste método concuerdan con lo descrito por el método de Garson. Por otra parte, se aprecia en la Figura 4.6(e) y 4.6(f) que la G_d y la V_w concuerdan con lo descrito por el producto de pesos, lo cual está determinado por el poco periodo de medición, restringido por el estándar ANSI/ASHRAE 93:2003, al igual que los resultados dados para T_{amb} , determinado así la necesidad de realizar un estudio dinámico de la eficiencia térmica para conocer la importancia que presentan estas variables ambientales durante periodos prolongados de tiempo.

CONCLUSIONES

En el presente trabajo de tesis se desarrolló un nuevo modelo matemático, mediante el uso de las Redes Neuronales Artificiales como herramienta de modelado, el cual fue capaz de llevar a cabo la predicción de eficiencia térmica de un arreglo de concentradores solares de canal parabólico con ángulos de apertura de 45° y 90° . El modelo matemático generado se obtuvo en función de siete parámetros de entrada demostrando una buena habilidad para la generalización de los resultados. Los siete parámetros empleados para determinar el desempeño térmico, provenientes de una base de datos experimental, fueron el ángulo de apertura, las temperaturas de entrada y salida del agua circulante a través del arreglo de concentradores, la temperatura ambiente, el flujo de agua, la radiación solar directa y la velocidad del viento.

El desarrollo de una metodología computacional para la obtención del modelo de predicción y el empleo de un procedimiento iterativo para el proceso de modelado, fungieron como piezas claves para la obtención de la ecuación matemática de la eficiencia térmica descrita. Debido a esto, el modelo de red neuronal fue exitosamente entrenado y validado mediante una base de datos imparcial (teniendo en cuenta el campo de entrenamiento de determinadas condiciones operativas) tras el empleo de diez diferentes algoritmos back-propagation, obteniendo la mejor arquitectura con el algoritmo Levenberg-Marquardt y ocho neuronas en la capa oculta. La validación de Eficiencia Térmica obtenida por el modelo matemático fue confirmada mediante la aplicación de una comparación estadística entre datos simulados y mediciones experimentales. Por tal motivo el modelo de red neuronal desarrollado puede ser utilizado para la predicción fiable del rendimiento térmico en concentradores solares cilíndrico parabólicos cuando las mediciones de las variables de entrada se encuentran dentro del intervalo de entrenamiento del modelo.

Por otra parte mediante el desarrollo de las diversas técnicas de análisis de sensibilidad aplicadas a los resultados del modelo matemático, se pudo obtener el nivel de impacto que presentan cada uno de los parámetros de entrada sobre la eficiencia térmica siendo el más significativo la temperatura de entrada de agua en los concentradores, seguido de la temperatura de salida, el ángulo de borde, el flujo de agua, la temperatura ambiente, la radiación solar y por último la velocidad del viento. Además se determinó que las variables que afectan de manera favorable la eficiencia térmica son la temperatura de salida y el flujo de agua, de esta manera la información obtenida permite plantear las estrategias idóneas para alcanzar los máximos valores posibles de eficiencia térmica durante la operación del equipo experimental.

El modelo desarrollado por lo tanto puede permitir la aplicación de sensores inteligentes para la determinación de la calidad en línea el comportamiento térmico de concentrador cilindro-parabólico. Sin embargo, la exactitud en la predicción del rendimiento térmico depende esencialmente de la exactitud de los patrones de entrenamiento, que están relacionados con el número de mediciones de variables de entrada experimentales, así como el control de calidad de los mismos. La idea de aplicar redes neuronales artificiales para la estimación del comportamiento térmico durante la operación del sistema no pretende eliminar el uso de los métodos termodinámicos y de transferencia de calor que continuamente se están desarrollando para una mejor estimación de este parámetro fundamental en los sistemas de concentración solar. Por último, mediante los resultados obtenidos en el análisis de sensibilidad, el modelo de red neuronal artificial también puede utilizarse para la optimización de las condiciones de operaciones de concentradores solares de canal parabólico.

RECOMENDACIONES

La base de datos experimental empleada para el entrenamiento de la red neuronal artificial en el trabajo descrito en el presente documento fue adquirida a través de mediciones realizadas bajo el estándar ANSI/ASHRAE 93:2003 el cual contempla parámetros en estado estacionario, por lo cual se recomienda llevar a cabo trabajos a futuro empleando el estándar ISO 9806-1:1994 que considera situaciones dinámicas; todo esto con el fin de obtener un modelo que considere las variaciones de las condiciones ambientales y poder compararlo con el modelo presentado en este trabajo.

De igual manera se recomienda entrenar el modelo de red neuronal considerando una base de datos que incluya diversas configuraciones de la planta como lo son la orientación de los concentradores, los días del año, operación durante periodos prolongados de tiempo, entre otras; así como la incorporación de nuevas variables de estudio como propiedades termodinámicas relacionadas con el vapor generado durante el proceso.

Por otra parte, los resultados del análisis de sensibilidad abren la posibilidad de desarrollar trabajos en una nueva línea de investigación enfocada a la optimización del sistema de concentradores solares bajo diversos métodos tanto numéricos como heurísticos.

REFERENCIAS

- Alemán-Nava, G., Casiano-Flores, V., Cárdenas-Chávez, D., Díaz-Chavez, R., Scarlet, N., Mahlknecht, J., ... Parra, R. (2014). Renewable energy research progress in Mexico: A review. Renewable and Sustainable Energy Reviews, 140-153.
- Almonacid, F., Pérez-Higueras, P., Rodrigo, P., y Hontoria, L. (2013). Generation of ambient temperature hourly time series for some spanish locations by artificial neural networks. Renewable Energy, 285-291.
- ANSI/ASHRAE 93-2003. (2003). Methods of testing to determine the thermal performance of solar collectors. USA: American Society of Heating, Refrigerating and Air-Conditioning Engineers, Inc.
- Azadeh, A., Babazadeh, R., y Asadzadeh, S. (2013). Optimum estimation and forecasting of renewable energy consumption by artificial neural networks. Renewable and Sustainable Energy Reviews, 605-612.
- Baldi, P. (1995). Gradient descent learning algorithm overview: A general dynamical systems perspective. IEEE Transactions.
- Basogain Olabe, X. (2005). Redes neuronales artificiales y sus aplicaciones. ESP: Escuela Superior de Ingeniería de Bilbao.
- Bassam, A., Conde-Guitierrez, R., J.Castillo, Lara, G., y Hernández, J. (2014). Direct neural network modeling for separation of linear and branched paraffins by adsorption process for gasoline octane number improvement. Fuel, 158-167.
- Bassam, A., I.Salgado-Tránsito, I.Oller, Santoyo, E., A.E.Jimenez, Hernández, J., ... S.Malato (2012). Optimal performance assessment for a photo-fenton degradation pilot plant driven by solar energy using artificial neural networks. Energy Research, 1314-1324.
- Bassam, A., Santoyo, E., Andaverde, J., Hernández, J., y Espinoza-Ojeda, O. (2010). Estimation of static formation temperatures in geothermal wells by using an artificial neural network approach. Computers & Geosciences, 1191-1199.

- Battiti, R. (1992). First and second order methods for learning: Between steepest descent and newton's method. Neural Computing.
- Bilgili, M., Sahin, B., y Yasar, A. (2012). Application of artificial neural networks for the spatial estimation of wind speed in a coastal region with complex topography. Renewable Energy, 75-82.
- Bishop, M. (1995). Neural network for pattern recognition. Oxford: Oxford University Press.
- Bowling, M., y Veloso, M. (2001). Variable learning rate and the convergence of gradient dynamics. Proc. 18th International Conference on Machine Learning, Williamstown.
- Brooks, M., Mills, I., y Harms, T. (2005). Design, construction and testing of a parabolic trough solar collector for a developing-country application. Proceedings of the ISES solar world congress.
- Caner, M., Gedik, E., y Kecebas, A. (2011). Investigation on thermal performance calculation of two type solar air collectors using artificial neural network. Expert Systems with Applications, 1668-1674.
- Carta González, J., R. Calero Pérez, Colmenar Santos, A., y Castro Gil, M. (2009). Centrales de Energías Renovables: Generación Eléctrica con Energías Renovables. Madrid, España: Pearson Prentice Hall.
- Ceylan, Í., Erkeymaz, O., Engin, G., y Gurel, A. (2014). The prediction of photovoltaic module temperature with artificial neural networks. Case Studies in Thermal Engineering, 11-20.
- Ceylan, Í., Gedik, E., Erkeymaz, O., Engin, G., y Gurel, A. (2014). The artificial neural network model to estimate the photovoltaic module efficiency for all regions of the turkey. Energy and Buildings, 258-267.
- Demuth, H. B., y Beale, M. H. (2014). Neural network toolbox user's guide. USA: The MathWorks, Inc.
- Dennis, J., y Schnabel, R. (1983). Numerical methods for unconstrained optimization and nonlinear equations. USA: Prentice Hall.
- Dimopoulos, I., Chronopoulos, J., Chronopoulos Sereli, A., y Lek, S. (1999). Neural network models to study relationships between lead concentration in grasses and permanent urban descriptors in athens city (greece). Ecological Modeling, 157-165.

- Dorofki, M., Elshafie, A., Haafar, O., Karim, O., y Mastura, S. (2012). Comparison of artificial neural network transfer functions abilities to simulate extreme runoff data. 2012 International Conference on Environment, Energy and Biotechnology, 39-44.
- Duffie, J. A., y Beckman, W. A. (2013). Solar engineering of thermal processes. USA: Wiley.
- Ertunc, H., y Hosoz, M. (2006). Artificial neural network analysis of a refrigeration system with an evaporative condenser. Apply Thermal Enggengering, 627-635.
- Férrnandez-García, A., Zarza, E., Valenzuela, L., y Pérez, M. (2010). Parabolic-trough solar collectors and their applications. Renewable and Sustainable Energy Reviews, 1695-1721.
- Flecher, R., y Reeves, C. (1964). Function minimization by conjugate gradients. The Computer Journal.
- Garson, G. (1999). Interpreting neural-network connection weights. Artif Int Expert, 47-51.
- Gevrey, M., Dimopoulos, I., y Lek, S. (2003). Review and comparison of methods to study the contribution of variables in artificial neural network models. Ecological Modelling, 249-264.
- Guven, H., y Bannerot, R. (1985). Derivation of universal error parameters for comprehensive optical analysis of parabolic troughs. Solar Energy, 168-174.
- Hagan, M., y Menhaj, M. (1994). Training feedforward networks with the Marquardt algorithm. IEEE Transactions on Neural Networks, 989-993.
- Haykin, S. (1990). Neural networks: A comprehensive foundation. USA: McMillan.
- Hernández, J., Bassam, A., Siquieros, J., y Juarez-Romero, D. (2009). Optimum operating conditions for a water purification process integrated to a heat transformer with energy recycling using neural network inverse. Renewable Energy, 1084-1091.
- Hernández, J., Rivera, W., Colorado, D., y Moreno-Quintanar, G. (2012). Optimal cop prediction of a solar intermittent refrigeration system for ice production by means of direct and inverse artificial neural networks. Solar Energy, 1108-1117.
- Incropera, F., y De Witt, D. (1999). Fundamentos de transferencia de calor. USA: Prentice Hall.
- Isasi Viñuela, P., y Galván León, I. (2003). Redes de neuronas artificiales un enfoque práctico. España: Pearson Prentice Hall.

- ISO 9806-1:1994. (1994). Test methods for solar collectors. USA.
- Izautireta, F., y Saavedra, C. (2000). Redes neuronales artificiales. Departamento de Física, Universidad de Concepción Chile.
- Jaramillo, O., Venegas-Reyes, E., Aguilar, J., Castrejón-García, R., y Sosa-Montemayor, F. (2013). Parabolic trough concentrators for low enthalpy processes. Renewable Energy, 529-539.
- Jeter, M. (1983). Geometrical effects on the performance of trough collectors. Solar Energy, 109-113.
- Johansson, E., Dowla, F., y Goodman, D. (1991). Backpropagation learning for multilayer feed-forward neural networks using the conjugate gradient method. International Journal of Neural Systems, DOI: 10.1142/S0129065791000261.
- Kalogirou, S. (1996). Parabolic trough collector system for low temperature steam generation: designed and permance characteristics. Applied Energy, 1-19.
- Kalogirou, S. (1997). Modelling, optimisation and performance evaluation of a parabolic trough solar collector steam generation system. Solar Energy, 49-59.
- Kalogirou, S. (1999a). Artificial neural networks for estimating the local concentration ratio of parabolic trough collectors. Proceedings of the EuroSun'96 Conference, vol 1, 470-475.
- Kalogirou, S. (1999b). Desing of a solar low temperature steam generation. Proceedings of the EuroSun'96 Conference, vol 1, 224-229.
- Kalogirou, S. (2001). Artificial neural networks in renewable energy. Renewable and Sustainable Energy Reviews, 373-401.
- Kalogirou, S. (2002). Parabolic trough collectors for industrial process heat in Cyprus. Energy, 813-830.
- Kalogirou, S. (2004). Solar thermal collectors and applications. Progress in Energy and Combustion Science, 231-295.
- Kalogirou, S. (2009). Solar energy engineering processes and systems. USA: Elsevier.
- Kalogirou, S., Florides, G., Pouloupatis, P., Panayides, I., Joseph-Stylianou, J., y Zomeni, Z. (2012). Artificial neural networks for the generation of geothermal maps of ground temperature at various depths by considering land configuration. Energy, 233-240.

- Kalogirou, S., Panteliou, S., y Dentsoras, A. (1999). Modeling of solar domestic water heating systems using artificial neural networks. Solar Energy, 335-342.
- Kumar, D. (2012). A review on parabolic trough solar collectors: Innovation, application and thermal energy storage. Proceedings of the National Conference on Trends and Advances in Mechanical Engineering, 90-99.
- LLano, L., Hoyos, A., Arias, F., y Velásquez, J. (2007). Comparación del desempeño de funciones de activación en redes Feedforward para aproximar funciones de datos con y sin ruido. Revista de Avances en Sistemas e Informática, 79-87.
- McCulloch, W., y Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. Bulletin Of Mathematical Biophysics, 115-133.
- Mekhilef, S., Saidur, R., y Safari, A. (2011). A review on solar energy use in industries. Renewable and Sustainable Energy Reviews, 1777-1790.
- Mellit, A., Saglam, S., y Kalogirou, S. (2013). Artificial neural network-based model for estimating the produced power of photovoltaic module. Renewable Energy, 71-78.
- Moller, M. (1993). A scaled conjugate gradient algorithm for fast supervised learning. Neural Networks.
- Montaño, J., y Palmer, A. (2003). Numeric sensitivity analysis to feedforward neural networks. Neural Computational & Application, 119-125.
- Nannariello, J., y Fricke, F. (2001). Introduction to neural network analysis and its application to building services engineering. Building Services Engineering Research and Technology, 58-68.
- Olden, J., y Jackson, D. (2002). Illuminating the black box: a randomization approach for understanding variable contributions in artificial neural networks. Ecological Modelling, 135-150.
- Philippopoulos, K., y Deligiorgi, D. (2007). Application of artificial neural networks for the wind speed prediction of target station using references stations data. Renewable Energy, 2350-2360.
- Piekiewicz, F., y Rybicki, L. (2004). Visual comparison of performance for different activation functions in MLP networks. USA: IEEE.
- Pierce, N. (1976). Efficient, low cost, concentrating solar collectors. Solar Energy, 395-400.

- Polak, E., y Ribiere, G. (1969). Note sur la convergence de directions conjuges. Mathematical Modelling and Numerical Analysis.
- Ponce Cruz, P. (2010). Inteligencia artificial con aplicaciones a la ingeniería. México: Alfaomega.
- Quaschnig, V. (2005). Understanding Renewable Energy Systems. UK: Earthscanl.
- Ramos, C., amirez, R., y J.Beltran. (2014). Potential assessment in Mexico for solar heat applications in food and textile industries. Energy Procedia, 1879-1884.
- Raza, M., y Khosravi, A. (2015). A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings. Renewable and Sustainable Energy Reviews, 1352-1372.
- Solangi, K., Islam, M., Saidur, R., Rahim, N., y Fayaz, H. (2011). A review on solar energy policy. Renewable and Sustainable Energy Reviews, 2149-2163.
- Stine, W., y Harrigan, R. (2008). Solar energy fundamentals and design with computer applications. USA: John Wiley and Sons, Inc.
- Tchaban, T., Taylor, M., y Griffin, J. (1998). Establishing impacts of the inputs in a feedforward neural network. Neural Computing and Applications, 309-317.
- Thomas, A. (1992). Operation and performance of the solar steam generation system installed at the government silk factory. Energy Conversion and Management, 191-196.
- Thomas, A. (1996). Solar steam generating system using parabolic trough concentrators. Energy Conversion and Management, 215-245.
- Thomas, G. (2006). Cálculo una variable. MEX: Pearson.
- Tiwarin, G. (2002). Solar energy: Fundamentals, Design, Modelling and Applications. UK: Alpha Science.
- Valencia, M., Yáñez, C., y Sánchez, P. (2006). Algoritmo backpropagation para redes neuronales: conceptos y aplicaciones. IPN Centro de Investigación en Computación.
- Vasilakos, C., Kalabokidis, K., y j. Hatzopuolos. (2008). Identifiying wildland fire ignition factors trough sensitivity analysis of a neural network. Natural Hazards, 309-317.
- Venegas Reyes, E. (2014). Diseño, construcción y evaluación de un arreglo de concentradores de canal parabólico para calor de proceso (Tesis Doctoral). Universidad Nacional Autónoma de México.

- Verma, S. (2005). Estadística básica para el manejo de datos experimentales: Aplicación en la Geoquímica. MXN: Universidad Nacional Autónoma de México.
- Vidrales Escobar, L. G. (2007). Colector de canal parabólico para la generación directa de vapor para calor de proceso (Tesis de Master). Universidad Nacional Autónoma de México.
- Villicaña-Ortiz, E., Gutiérrez-Trashorras, A., Paredes-Sánchez, J., y Xiberta-Bernat, J. (2015). Solar energy potential in the coastal zone of the Gulf of Mexico. Renewable Energy, 534-542.
- Yadav, A., y Chandel, S. (2014). Solar radiation prediction using artificial neural network techniques: A review. Renewable and Sustainable Energy Reviews, 772-781.
- Yaici, W., y Entchev, E. (2014). Performance prediction of a solar thermal energy system using artificial neural networks. Applied Thermal Engineering, Accepted Manuscript.

ANEXO 1

Presentación en la *XXXIX Semana Nacional de Energía Solar* celebrada en la Ciudad de San Francisco de Campeche, Campeche del 5 - 9 de Octubre del 2015.



PREDICCIÓN DE LA EFICIENCIA DE UN ARREGLO DE CONCENTRADORES DE CANAL PARABÓLICO EMPLEANDO HERRAMIENTAS DE INTELIGENCIA ARTIFICIAL

**Oscar de J. May Tzuc¹, Ali Bassam², Eduardo Venegas Reyes³, Oscar A. Jaramillo Salgado⁴,
Luis J. Ricalde Castellanos² y Eduardo E. Ordoñez López²**

¹Posgrado en Energías Renovables, Facultad de Ingeniería, Universidad Autónoma de Yucatán,
Av. Industrias no Contaminantes por Periférico Norte, Apdo. Postal 150 Cordemex,
Mérida, Yucatán, México. E-mail: maytzuc@gmail.com

Facultad de Ingeniería, Universidad Autónoma de Yucatán,
²Av. Industrias no Contaminantes por Periférico Norte, Apdo. Postal 150 Cordemex,
Mérida, Yucatán, México. Tel.930 0550; Fax. 930 05 59

³Investigador de Cátedras CONACYT, Centro de Investigación en Materiales Avanzados, S.C.CIMAV Unidad Durango
Victoria 147 Nte. Centro, 34000 Durango, México.

⁴Instituto de Energías Renovables, Universidad Nacional Autónoma de México,
Privada Xochicalco s/n, 62580, Temixco, Morelos, México

RESUMEN

Una arquitectura de Red Neuronal Artificial (RNA) es empleada para el desarrollo de un modelo matemático predictivo destinado al cálculo de la eficiencia térmica (η) en un arreglo de Concentradores Solares de Canal Parabólico (CCPs). La arquitectura de RNA diseñada consta de tres capas, las cuales han sido entrenadas a partir de una base de datos experimental compuesta por las variables de operación y ambientales más relevantes, como lo son: temperatura de entrada (T_{ent}) y temperatura de salida (T_{sal}) del fluido de trabajo que circula a través del arreglo de CCPs, flujo del fluido de trabajo (F), radiación solar directa (G_b) y temperatura ambiente (T_{amb}). El entrenamiento de la RNA llevado a cabo emplea el algoritmo de entrenamiento Levenberg-Marquardt (LM), la función de transferencia Tangente-Hiperbólica (Tansig), en la capa oculta, y la función de transferencia Lineal (Purelin) para la capa de salida. Los mejores resultados en la etapa de entrenamiento se obtuvieron a partir de una arquitectura compuesta por cinco neuronas en la capa oculta, lo cual permite predecir la eficiencia térmica con un coeficiente de determinación satisfactorio ($R^2 > 0.993$). El modelo predictivo desarrollado puede tener implementación en sensores inteligentes que permitan mejorar el control del sistema de CCP, lo que con lleva a un mejor aprovechamiento del recurso solar.

ABSTRACT

An Artificial Neural Network (ANN) architecture was employed to develop a predictive mathematical model for the calculation of the thermal efficiency (η) at Parabolic Trough Concentrator array (PTCs). The ANN architecture designed consist of three layers, which they have been trained from an experimental database composed of the most important operational and environmental variables, as they are: inlet temperature (T_{ent}) and outlet temperature (T_{sal}) of the working fluid flowing through the PTCs, working fluid flow (F), direct solar radiation (G_b) and ambient temperature (T_{amb}). ANN training conducted the training algorithm Levenberg-Marquardt (LM), Hyperbolic-Tangent (Tansig) transfer function, at the hidden layer, and Linear (Pureline) transfer function at the out layer. The best results at the trainer phase was obtained from a five hidden neurons architecture, which allow to predict the thermal efficiency with a satisfactory determination coefficient ($R^2 > 0.993$). The predictive model develop can have implementations in intelligent sensors that allow to improve the PTCs control system, generating a better solar resource use.

Palabras claves: *Sistemas fototérmicos, condiciones de operación, redes neuronales artificiales, modelación matemático.*

INTRODUCCION

En la actualidad casi toda la energía transmitida por la red y consumida por sistemas industriales es parcial o totalmente dependiente de la quema de combustibles fósiles para la producción de energía térmica, generando emisiones de gases de efecto invernadero lo cual ha ocasionado fuertes impactos al medio ambiente como lo son el cambio climático y el calentamiento global. En este contexto, se han llevado a cabo una gran cantidad de investigaciones sobre la inclusión de sistemas energéticos basados en fuentes de energía alternativas para emplearse como sustitutos para la generación de calor de procesos a nivel industrial (Fernández-García, et al., 2010; Mekhilef, et al., 2011).

De las energías renovables existentes, la energía solar térmica es la más prometedora a futuro para aplicaciones industriales, debido a que es abundante, limpia, no genera ruido o alguna otra clase de contaminación al ambiente (Mekhilef, et al., 2011). En la industria, existen numerosos procesos que requieren energía térmica con un nivel de temperatura por debajo de los 250°C; industrias como la de los lácteos, la producción de plásticos, el enlatado de alimentos, producción de papel, entre otros requieren de energía térmica para procesos como son el secado, esterilizado, limpieza, evaporación, producción de vapor, así como el acondicionamiento de espacio en naves industriales tanto

para calefacción como refrigeración; esta energía que puede ser suministrada mediante captadores solares de conversión fototérmica, más específicamente Concentradores Solares de Canal Parabólico (CCPs) (Venegas Reyes, 2014). No obstante, como todos los sistemas basados en el empleo de energías alternativas, los CCPs se encuentran vinculados a una gran cantidad de variables y expuestos a diversas fluctuaciones debido a las condiciones climatológicas del medio, lo cual vuelve sumamente complicado los estudios realizados sobre estos sistemas, generando complejas ecuaciones no lineales para su comprensión, lo que se traduce en dificultad para poder optimizar su funcionamiento y obtener el mayor coste beneficio al ponerlos en operación.

En años recientes, el desarrollo de modelos empíricos empleando herramientas computacionales de inteligencia artificial, como las Redes Neuronales Artificiales (RNA), ha ido en aumento principalmente debido a que toda la información proveniente de sistemas basados en fuentes de energía renovables es muy fluctuante, posee demasiado ruido y además el comportamiento no presenta una tendencia lineal; mismas características para las cuales se encuentran diseñada estas herramientas computacionales (Azadeh , et al., 2013).

Por tales motivos, el objetivo de este trabajo se basa en el desarrollo de un modelo computacional, empleando RNA como herramienta de inteligencia artificial, con el propósito de predecir el comportamiento de la eficiencia térmica (η) de un arreglo de CCPs, a partir de parámetros experimentales.

REDES NEURONALES ARTIFICIALES COMO HERRAMIENTA DE INTELIGENCIA ARTIFICIAL

Una Red Neuronal Artificial (RNA) es una estructura compuesta de un número de unidades interconectadas, llamadas neuronas artificiales, las cuales operan de manera paralela y presentan una tendencia natural por el aprendizaje a partir de datos experimentales, por este motivo la RNA puede ser empleada posteriormente para una gran variedad de aplicaciones de ingeniería (Demuth & Beale, 2014). El objetivo principal de una arquitectura de red neuronal es imitar la sinapsis generada en las neuronas animales.

Un modelo de RNA puede ser visto como una caja negra a la cual se le ingresa una base de datos compuesta por una serie de variables de entrada, a cada una de estas variables de entrada se le asigna un factor apropiado de ponderación o peso (W). La suma de la entradas ponderadas y el empleo de sesgos o bias (b), para ajuste, produce un valor de entrada para una función de transferencia que generará una salida (Figura 1). La característica principal de estos modelos es que no requieren información específica del comportamiento físico del sistema ni de la forma en que fueron obtenidos los datos (Bassam, et al., 2014).

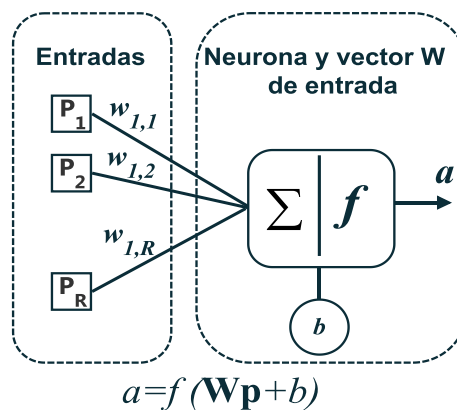


Figura 1.- Neurona básica con R entradas.

La RNA puede ser entrenada para la solución de problemas multivariantes y ecuaciones no lineales asociados con fenómenos muy complejos y de difícil solución por métodos convencionales. Esto se lleva a cabo mediante un proceso de entrenamiento de la RNA a través de algoritmos, de los cuales el más utilizado es el conocido como back-propagation; además la RNA emplea funciones de transferencia para cada capa de la red (Kalogirou, 2001). Durante el proceso de entrenamiento la red va aprendiendo de sus errores hasta llegar a un modelo que describa lo más exacto posible el fenómeno estudiado; durante este entrenamiento se generan lo que se denominan matrices de pesos y bias las cuales se van modificando en cada iteración hasta obtener el modelo matemático óptimo.

SISTEMA DE CONCENTRACIÓN SOLAR DE CANAL PARABÓLICO

El equipo experimental empleado para el desarrollo del presente trabajo está basado en una planta generadora de vapor de baja entalpía perteneciente al Instituto de Energías Renovables de la Universidad Nacional Autónoma de México, localizado en Temixco, Morelos. Este sistema emplea agua como fluido de trabajo y se encuentra integrado por un arreglo de CCPs de 2.44 metros de largo; dos tanques de almacenamiento térmico con capacidad de 120 litros cada uno (los cuales poseen una resistencia eléctrica de 3 y 6 kW respectivamente para el precalentamiento del agua; 2 bombas de agua de 1/2 hp y un circuito hidráulico compuesto por válvulas que permite operar el equipo ya sea en modo de circuito abierto o circuito cerrado. Además, la planta se encuentra instrumentada con sensores de flujo a las salidas de los tanques de almacenamiento, indicadores de presión y sensores de temperatura tanto a la entrada como a la salida del arreglo de CCPs, así como un sistema de control para la activación de las bombas (Venegas Reyes, 2014). La Figura 2 muestra el diagrama de la planta generadora de vapor de baja entalpía.

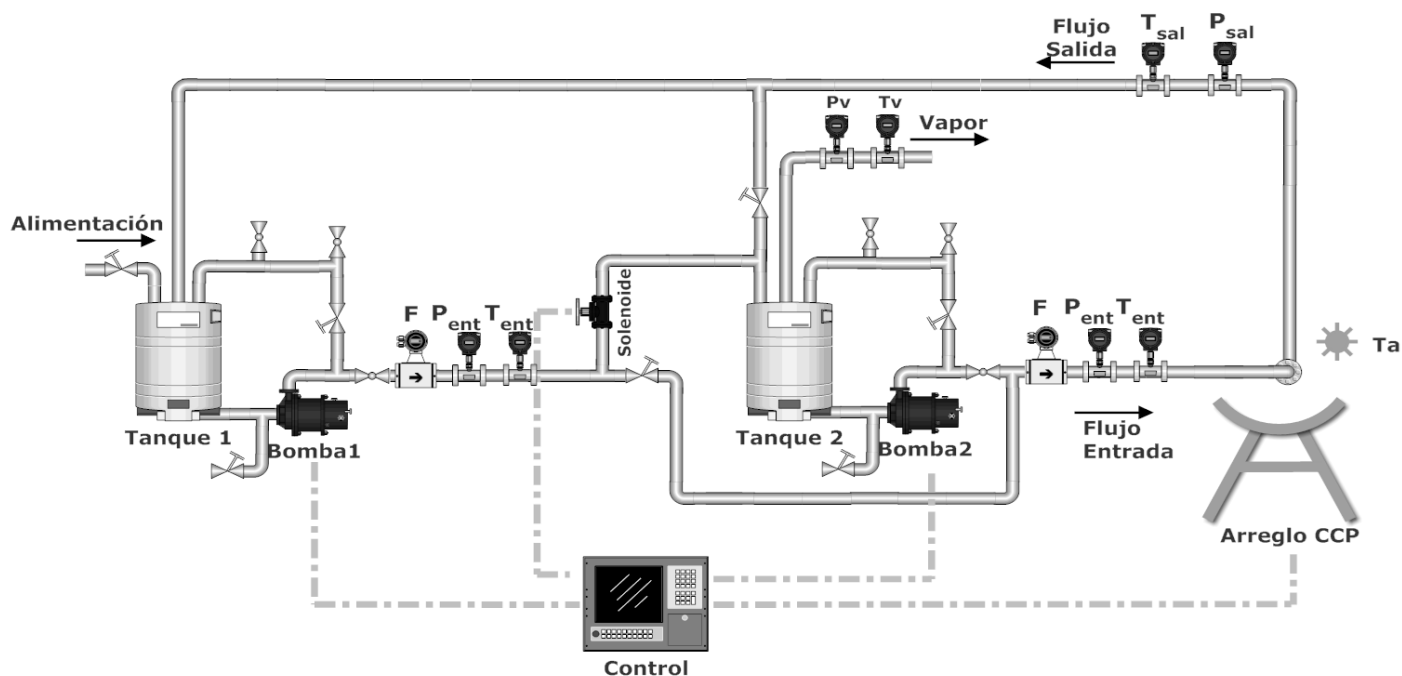


Figura 2.- Planta generadora de vapor de baja entalpía para producción de calor de procesos.

Durante la operación del sistema, se obtuvo una base de datos constituida por las principales variables de operación, mismas que son empleadas para el desarrollo del modelo de predicción de eficiencia térmica. La Tabla 1, muestra las variables de operación del sistema así como los rangos bajo los cuales operan cada una.

Tabla 1.- Variables de operación empleadas en el modelo de RNA.

Variables de Operación	Mín	Max	Unidades
<i>Entrada:</i>			
Temperatura de entrada del fluido (T_{ent})	25.43	84.18	[°C]
Temperatura de salida del fluido (T_{sal})	35.96	99.95	[°C]
Temperatura ambiente (T_{amb})	26.02	37.88	[°C]
Flujo del fluido de trabajo (F)	0.96	6.08	[L/min]
Radiación solar directa (G_b)	648.3	1009	[W/m ²]
<i>Salida:</i>			
Eficiencia Térmica (η)	0.15	0.71	[-]

MODELO NEURONAL

Para el desarrollo del modelo de predicción de eficiencia térmica, se realizaron una serie de entrenamientos de red neuronal a partir de la base de datos experimental obtenida del sistema de concentración de canal parabólico. El entrenamiento se desarrolló empleando una arquitectura de red de tres capas (capa de entrada, capa oculta y capa de salida), variando el número de neuronas de la capa oculta y utilizando el algoritmo de entrenamiento Levenberg–Marquardt (LM) para la optimización de los pesos y bias de la red. Las funciones de transferencia empleadas durante dicho entrenamiento fueron la función Tangente-Hiperbólica (Tansing) para las neuronas ubicadas en la capa oculta y la función de transferencia Lineal (Pureline) para la capa de salida. El mejor conjunto de datos de entrenamiento fue obtenido con una arquitectura de RNA compuesta por 5 neuronas en la capa oculta (5-5-1). La Figura 3 muestra la arquitectura de RNA obtenida para la predicción de la eficiencia térmica del arreglo de CCPs.

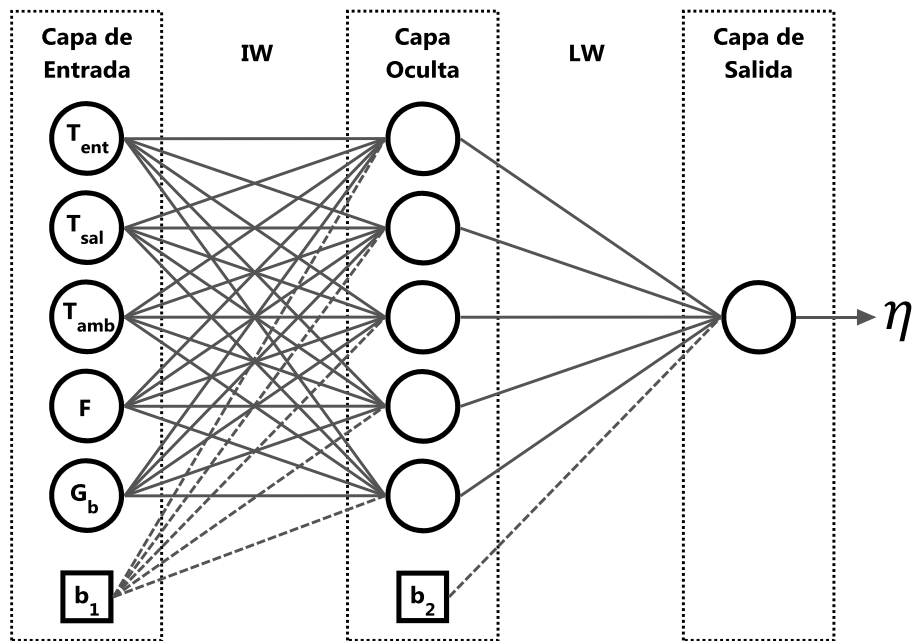


Figura 3.- Arquitectura de RNA para la predicción de eficiencia térmica (η) del arreglo de CCPs.

Los resultados obtenidos fueron validados a través de una comparación estadística con datos experimentales obteniendo un Error Medio Cuadrado RMSE= 0.0074. La Figura 4 muestra una comparativa entre los valores de eficiencia térmica obtenidos a partir del modelo de RNA (η_{RNA}) y los valores de eficiencia que formaron parte del entrenamiento de la red (η_{Exp}), de los cuales se obtuvo un modelo de regresión lineal satisfactorio dado por:

$$\eta_{RNA} = 0.99064 \eta_{Exp} + 0.00463 \quad (1)$$

este modelo presenta un coeficiente de determinación $R^2=0.9929$, indicando un adecuada adaptación a las variaciones de los parámetros experimentales

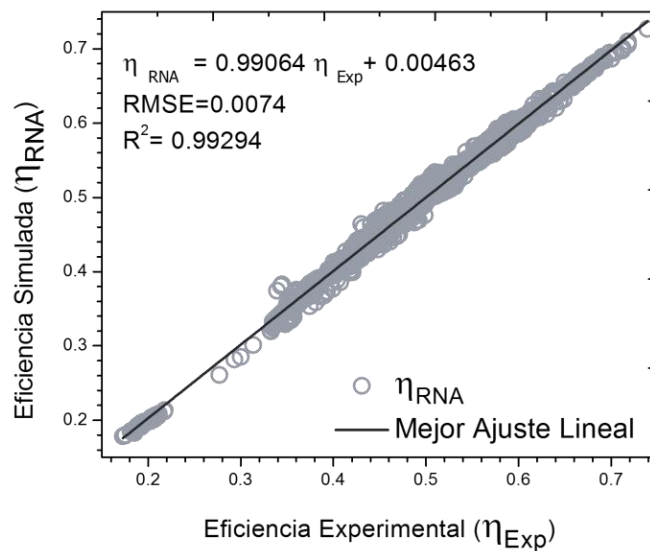


Figura 4.- Comparación estadística entre eficiencia experimental y eficiencia modelada por RNA.

Tabla 2.- Pesos y bias óptimos del modelo de predicción de RNA.

Número de Neuronas	Pesos (W)					Bias (b)		
	Capa Oculta (S = 5, K = 5) IW(s,k)				Capa Salida LW (s, 1)			
	$T_{ent}(k=1)$	$T_{sal}(k=2)$	$T_{amb}(k=3)$	$F(k=4)$	$G_b(k=5)$	$\eta(s, 1)$	$b_1(s)$	b_2
1	3.1066	-3.0819	-0.9834	-0.3334	6.9687	-1.1434	-3.7062	
2	-8.1068	9.6298	-0.4179	-0.3078	2.8024	2.3154	-0.8142	
3	-2.7809	3.6089	-1.0558	0.9297	2.3546	0.4526	-1.8835	-2.5305
4	-7.4278	-9.4395	6.1754	-3.1581	-5.8927	0.0351	12.259	
5	-2.7704	2.9459	0.4871	-1.6200	-3.5138	-1.6511	1.3767	

La Tabla 2 presenta los pesos y bias óptimos generados durante el entrenamiento de la red siendo IW y LW los pesos de entrada y pesos de la capa oculta respectivamente, K y S los números totales de entradas (K=5) y de neuronas (S=5); y b_1 y b_2 los factores de ajuste o bias. Así, basándose en la arquitectura desarrollada en la Figura 3 y los valores de la Tabla 2, el modelo propuesto para predicción de la eficiencia térmica del arreglo de CCPs puede ser presentado analíticamente por la siguiente ecuación:

$$\eta_{RNA} = \sum_{j=1}^S \left[LW(1, j) \left(\frac{2}{1 + \exp(-2(\sum_{k=1}^K (IW(j, k) Ent(k)) + b_1(j)))} \right) - 1 \right] + b_2 \quad (2)$$

de la cual IW, LW, b_1 , b_2 , K y S son los valores descritos en la Tabla 2 y Ent el valor del parámetro de operación correspondiente.

Validación del modelo de RNA

Con el propósito de comprobar la efectividad de predicción del modelo matemático generado mediante RNA, se realizó una comparación entre datos experimentales de eficiencia térmica, los cuales no formaron parte del entrenamiento de la RNA, y la eficiencia obtenida a través de la simulación. La comparación de eficiencias se realizó en función del parámetro de pérdida de calor $\Delta T/G_b$, dicha comparación es mostrada en la Figura 5 en la cual se aprecia que a cada punto de eficiencia experimental le corresponde un valor respectivo de eficiencia simulada de tal manera que con los valores de la simulación es posible trazar una curva que describa la posición de los puntos experimentales. Por lo tanto los valores de eficiencia obtenidos a través del modelo matemático generado por RNA consiguen emular con un alto grado de precisión el comportamiento de la eficiencia térmica experimental del CCPs.




Figura 5.- Validación de eficiencias térmicas simuladas en función del parámetro de pérdida de calor $\Delta T/G_b$.

CONCLUSIONES

Un modelo matemático de Red Neuronal Artificial fue entrenado exitosamente y validado estadísticamente para la estimación y predicción de la eficiencia térmica de un arreglo de Concentradores Solares de Canal Parabólico. El modelo de RNA desarrollado se encuentra en función de cinco parámetros de entrada del sistema los cuales son temperatura de entrada (T_{ent}) y temperatura de salida (T_{sal}) del fluido de trabajo que circula a través del arreglo de CCPs, flujo del fluido de trabajo (F), radiación solar directa (G_b) y temperatura ambiente (T_{amb}). Este modelo predictivo es presentado mediante una ecuación matemática de computo sencillo la cual posibilita una aplicación rápida y directa.

Los resultados obtenidos tras la validación de este modelo permiten su aplicación directa en tarjetas de desarrollo destinadas a la predicción y estimación en línea de la eficiencia térmica del arreglo de CCPs. Por otro lado, el empleo de este modelo permite reducir los tiempos de investigación y los costos de operación del sistema. Por último, el modelo predictivo desarrollado puede ser empleado para realizar la optimización de las condiciones de operación del arreglo de concentradores solares.

AGRADECIMIENTOS

Parte de esta investigación fue realizada mediante PAPIIT-UNAM bajo el proyecto it100514 así como por Sep-Prodep a través del proyecto “Sistema de concentradores solares de canal parabólico para la generación de calor de proceso: diseño, construcción y evaluación”.

REFERENCIAS

- Azadeh, A., Babazadeh, R. & Asadzadeh, S., 2013. Optimum estimation and forecasting of renewable energy. *Renewable and Sustainable Energy Reviews*, pp. 605-612.
- Bassam, A., del Castillo, A., García-Valladares, O. & Santoyo, E., 2014. Determination of pressure drops in flowing geothermal wells by using artificial neural networks and wellbore simulation tools. *Applied Thermal Engineering*. pp. 1-12.
- Demuth, H. & Beale, M., 2014. *Neural Network Toolbox for use with MATLAB*. USA: MathWorks, Inc..
- Fernández-García, A., Zarza, E., Valenzuela, L. & Pérez, M., 2010. Parabolic-trough solar collectors and their applications. *Renewable and Sustainable Energy Reviews*, p. 1695–1721.
- Kalogirou, S., 2001. Artificial neural networks in renewable energy systems applications: a review. *Renewable and Sustainable Energy Reviews*, p. 373–401.
- Mekhilef, S., Saidur, R. & Safari, A., 2011. A review of solar energy use in industries. *Renewable and Sustainable Energy Reviews*, p. 1777–1790.
- Venegas Reyes, E., 2014. *Diseño, construcción y evaluación de un arreglo de concentradores de canal parabólico para calor de procesos*. México, DF.: s.n.

ANEXO 2

Presentación en el *Encuentro Universitario de Sistemas Computacionales*, celebrado en la Ciudad de Mérida, Yucatán del 16 - 18 de Marzo del 2016.

Desarrollo de Interfaz Computacional para el Dimensionamiento y Estimación de la Eficiencia Óptica y Térmica de Concentradores Solares de Canal Parabólico

O. May Tzuc, I. Peña Quintal, and A. Bassam

Facultad de Ingeniería, Universidad Autónoma de Yucatán
Av. Industrias no Contaminantes por Periférico Norte, Apdo. Postal 150 Cordemex
maytzuc@gmail.com, irvingspq@gmail.com, baali@correo.uady.mx

Abstract. El presente trabajo describe la metodología utilizada para el desarrollo de un conjunto de interfaces computacionales, diseñadas en MATLAB mediante su herramienta *Graphical User Interface*, destinadas a realizar los cálculos para la obtención del dimensionamiento, eficiencia óptica (η_o) y eficiencia térmica (η_T) de Concentradores Solares de Canal Parabólico (CCP), a partir de las medidas de ciertos materiales empleados para su construcción así como parámetros de los mismos y propiedades del aire. La interfaz permite visualizar de manera gráfica las dimensiones de la sección transversal del CCP, la variación de η_o respecto al ángulo de incidencia de los rayos solares y la variación de η_T respecto al parámetro de pérdida de calor. El programa también brinda la posibilidad de exportar los resultados obtenidos en un archivo .xls, para su posterior tratamiento de ser necesario.

Palabras Clave: Energía Fototérmica, Concentrador de Canal Parabólico, Interfaz Computacional.

1 Introducción

En el sector industrial actual existen numerosos procesos como el secado, estereolizado, limpieza, evaporación, producción de vapor y refrigeración que requieren energía térmica con temperaturas entre los 80°C y 250°C misma que puede ser suministrada empleando energía solar mediante el uso de Concentradores Solares de Canal Parabólico (CCPs) [1], siendo uno de retos actuales para los ingenieros en concentración solar térmica el desarrollo de sistemas de captación solar aptos para su aplicación dentro de este rango de temperaturas [2].

Hoy en día, las herramientas computacionales se han convertido en una opción viable para el auxilio en el análisis de procesos y dispositivos, dado que la información obtenida es confiable con la ventaja de tener bajo costo y resultados rápidos, ofreciendo la capacidad de llevar a cabo cambios en las variables y simular distintas condiciones [3]. Debido a esto el presente trabajo se centra en el desarrollo de un código de programación ejecutable a través de un conjunto de

interfaces visuales, construidas en MATLAB mediante su herramienta *Graphical User Interface* (GUI), que calculen el dimensionamiento, eficiencia óptica (η_o) y térmica (η_t) para un CCP a partir de las medidas del material de fabricación así como de parámetros del mismo y propiedades del aire.

2 Concentrador Solar de Canal Parabólico




Fig. 1. Sección transversal de un CCP con receptor circular [5].

Un concentrador solar de canal parabólico consiste en una lámina en forma de canal con sección transversal parabólica, su superficie debe tener un alto valor de reflectancia (ρ); en el foco de la parábola (f) se encuentra un tubo absorbedor de metal, recubierto con una superficie selectiva con alto valor de absorptividad (α) y baja emisividad (ϵ). Un tubo de vidrio se coloca concéntrico al absorbedor con alta transmisividad (τ) para de minimizar pérdidas convectivas (h_v), y el espacio entre ambos tubos debe estar evacuado, minimizando así las pérdidas por conducción del tubo absorbedor. Dentro del tubo absorbedor, el fluido de trabajo gana energía debido a la concentración de la irradiación solar en la zona focal llegando a una temperatura mayor al final del concentrador (T_s) [4], la Fig. 1 muestra el diagrama transversal de un CCP y los parámetros que lo conforman.

2.1 Diseño de un CCP

Una de las formas más prácticas para calcular las dimensiones de un CCP es considerando la longitud de la curva de la superficie reflectiva (S), dada por:

$$S = \frac{f}{a} \left(b - \frac{a}{2} \ln(f^2) + a \ln(cf) \right) \quad (1)$$

en donde los coeficientes a , b y c , están determinados por el ángulo que forma la superficie parabólica respecto de la vertical que pasa por el foco, llamado ángulo de apertura ϕ_r . La Tabla 1 muestra los valores de estos coeficientes para diversos posibles ángulos de borde en un CCP.

Tabla 1. Valores de las constantes según el ángulo de borde (ϕ_r).

Angulo de Borde (ϕ_r)	a	b	c
40°	2	1.5795	1.4927
50°	2	1.7404	1.5199
60°	18	14.420	5.6055
70°	2	2.3000	1.5974
80°	2	2.7846	1.6485
90°	2	2.8284	2.4142

La Fig. 1 muestra los parámetros más relevantes empleados en el diseño del perfil parabólico del CCP, donde una explicación más detallada de ellos se encuentra dada por Kalogirou [5].

2.2 Eficiencia Óptica de CCPs

La eficiencia óptica está definida como la razón entre la energía absorbida por el receptor y la energía incidente en el área de apertura del colector; depende de las propiedades ópticas de los materiales empleados, la geometría y de efectos implícitos en la manufactura del CCP, se encuentra dada por [5]:

$$\eta_o = \rho\tau\alpha\gamma[(1 - A_f \tan(\theta)) \cos(\theta)] \quad (2)$$

donde θ es ángulo de incidencia de los rayos del Sol; γ es el factor de intercepción el cual representa las pérdidas ópticas por cuestiones ambientales y de manufactura; y A_f es la relación entre el área perdida por efectos de borde y el área de apertura [5]:

$$A_f = \frac{2/3W_a h_p + fW_a \left[1 + \frac{W_a^2}{48f^2}\right]}{A_a} \quad (3)$$

h_p y A_a , son el lado recto de la parábola y área total del CCP respectivamente.

2.3 Eficiencia Térmica de CCPs

La eficiencia térmica representa la relación entre la energía producida por un CCP y la energía empleada para operar. Esta se expresa mediante:

$$\eta_T = \frac{Q_u}{A_a G_b} = F_R \left(\eta_o - \frac{U_L}{C} \left(\frac{\Delta T}{G_b} \right) \right) \quad (4)$$

donde G_b representa la radiación solar directa, y Q_u , F_R , U_L y $\Delta T/G_b$ (con $\Delta T = T_{entrada} - T_{ambiente}$) son la energía útil obtenida, el factor de remoción, el coeficiente de pérdida de calor y el parámetro de pérdida de calor respectivamente, detallados por Kalogirou [5]. En la práctica la η_T generalmente es graficada en función del parámetro de pérdida de calor.

3 Desarrollo de Algoritmos de Programación

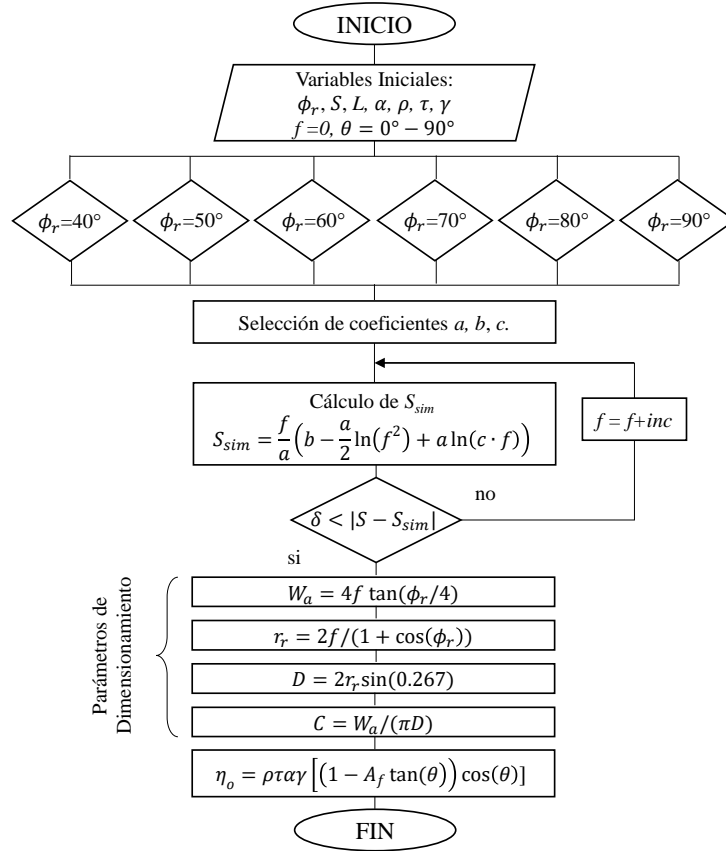


Fig. 2. Código implementado para la obtención del dimensionamiento y η_o .

Para realizar los cálculos del dimensionamiento y η_o , se implementó el código descrito en la Fig. 2. Como se aprecia, en primera instancia se ingresan los valores de la longitud de la lámina de construcción (S), la longitud del CCP (L), α , ρ , τ , γ , y se realiza la selección de ϕ_r respecto a 6 valores predefinidos (40° , 50° , 60° , 70° , 80° y 90°). A partir de la elección de ϕ_r , se asignan los valores adecuados para los coeficientes a , b y c (Ec. 1). Posteriormente inicia un proceso iterativo para el cálculo de f (inicialmente es cero), comparando la longitud de la lámina obtenida por la Ec. 1 (S_{sim}) respecto al valor real (S). De no cumplir la comparación un cierto criterio estadístico, se realiza un incremento en el valor de f y se repite el proceso. Una vez obtenido el valor óptimo de f , se ejecutan los cálculos para la obtención de los demás parámetros de dimensionamiento los cuales son la Abertura de la Parábola (W_a), el Radio Máximo (r_r), el Diámetro mínimo del receptor (D), la Razón de Concentración (C) así como de la eficiencia óptica.

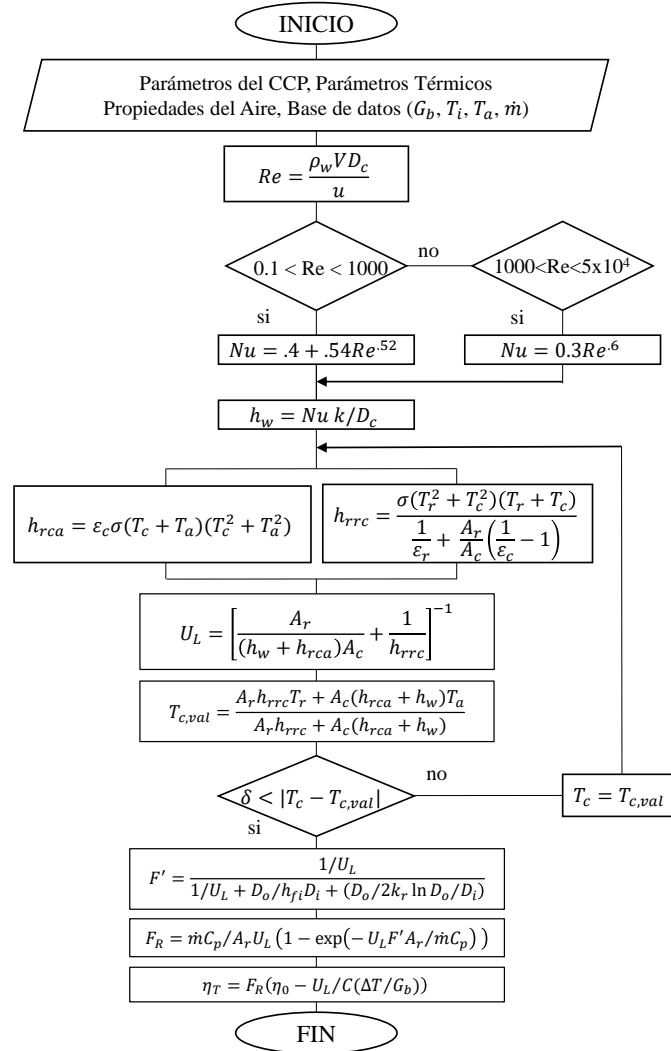


Fig. 3. Código implementado para la obtención de la η_T .

La Fig. 3 describe el algoritmo implementado para la obtención de η_T . El algoritmo requiere la introducción de parámetros divididos en tres categorías: Parámetros del CCP (longitud del CCP (L), Abertura de la parábola (W_a), Diámetro interior del receptor (D_i), Diámetro exterior del receptor (D_o), Diámetro de la cubierta de vidrio (D_c), emisividad del receptor (ε_r) y emisividad de la cubierta de vidrio (ε_c)); Parámetros térmicos (calor específico del fluido de trabajo (C_p), conductividad térmica del receptor (k_r), coeficiente de transferencia de calor en el interior del tubo (h_{fi}), velocidad del viento (V), temperatura del receptor (T_r) y la temperatura de la cubierta de vidrio (T_c)); y propiedades del aire (densidad (ρ_w), viscosidad (u) y conductividad térmica

(k). De la misma forma, es requerida una base de datos, en un archivo extensión .xls, para la introducción de parámetros variables como lo son la radiación solar (G_b), la temperatura ambiente (T_a), la temperatura de entrada del fluido (T_i) y el flujo másico (\dot{m}). Una vez capturado dichos valores se calcula el Número de Reynolds (Re) para determinar si el viento es considerado como laminar ($0.1 < Re < 1000$) o turbulento ($1000 < Re < 50,000$), y así obtener el adecuado Número de Nusselt (Nu). Posteriormente, mediante Nu y las propiedades del aire, el algoritmo obtiene el coeficiente de pérdida de calor convectiva (h_w). Una vez realizado estos cálculos, inicia un proceso iterativo para la obtención de U_L calculando los coeficientes de pérdida de calor por radiación de la cubierta de vidrio al ambiente (h_{rca}) y del receptor a la superficie de vidrio (h_{rrc}); un valor de la temperatura de la cubierta de vidrio es estimada ($T_{c, val}$) y comparada bajo un criterio estadístico (δ), respecto al valor estimado (T_c), de no cumplirse dicho criterio el valor es remplazado y se realiza el computo nuevamente. Después de obtener el valor óptimo de U_L , se ejecutan los cálculos para F' , F_R y η_T .

4 Interfaz Computacional




Fig. 4. Interfaz para el dimensionamiento y obtención de η_o .

La Fig. 4 muestra la interfaz desarrollada para la obtención de la dimensiones de un CCP así como su η_o . Como se puede apreciar al ingresar las variables la interfaz realiza un gráfico de corte transversal del CCP diseñado así como de la variación de η_o en función de θ . Por otra parte la Fig. 5 muestran la interfaz para la obtención de η_T , la cual tras ingresar la base de datos y las variables solicitadas realiza una gráfica de eficiencias térmicas puntuales en función del parámetro de pérdida de calor, a las cuales se le aplica una regresión lineal para visualizar su tendencia. Como se observa en ambas figuras, las interfaces presentan la opción de exportar los valor calculados así como los conjuntos de datos obtenidos para realizar las gráficas.

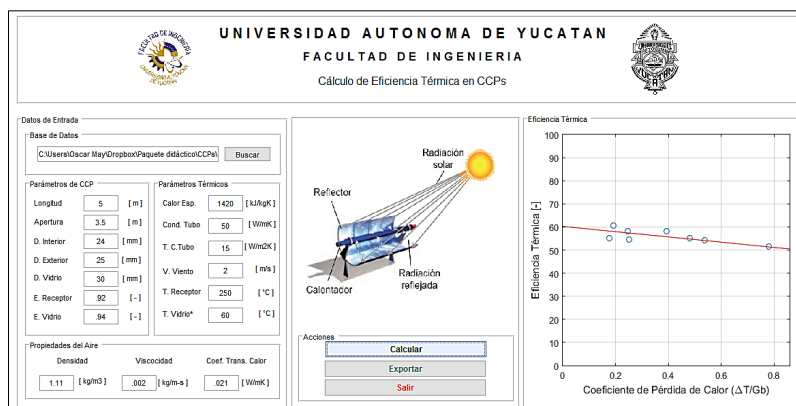


Fig. 5. Interfaz para la obtención de η_T .

5 Conclusiones

A través de las dimensiones del material de construcción, parámetros térmicos y propiedades del aire un conjunto de interfaces computacionales para la obtención de las dimensiones, eficiencia óptica y eficiencia térmica de un Concentrador de Canal Parabólico fueron desarrollados. Las interfaces permiten visualizar gráficamente las dimensiones del corte transversal del concentrador solar, la eficiencia óptica y la eficiencia térmica. Los resultados obtenidos pueden ser exportados a un archivo .xls, permitiendo la construcción y análisis de estos sistemas de captación solar, facilitando así su inclusión en la industria.

Agradecimientos

Este trabajo fue desarrollado como parte del proyecto PRODEP 2015 103.5/15/10486.

Referencias

1. E. Venegas-Reyes, O. A. Jaramillo, R. Castrejón-García, J. O. Aguilar, F. Sosa-Montemayor: Design, construction, and testing of a parabolic trough solar concentrator for hot water and low enthalpy steam generation. *J. Renewable Sustainable Energy* 4, 053103 (2012)
2. O. A. Jaramillo, E. Venegas-Reyes, J. O. Aguilar, R. Castrejón-García, F. Sosa-Montemayor: Parabolic trough concentrators for low enthalpy processes. *Renewable Energy* 60, 529-539 (2013)
3. E. Enciso, J. Barbosa, P. Quinto, C. Gutiérrez: Metodología para la Optimización del Software SOLEEC para el Diseño de CCPs con Generación Directa de Vapor. XXXIX Semana Nacional de Energía Solar (2015)
4. J. Carta González, R. Calero, A. Colmenar, M. Castro: Centrales de Energías Renovables: Generación Eléctrica con Energías Renovables. Madrid, España: Pearson Prentice Hall (2009)
5. S.A. Kalogirou: Solar energy engineering processes and systems. Elsevier (2009)

ANEXO 3

Presentación en el *International Symposium on Intelligent Computing Systems*,
celebrado en la Ciudad de Mérida, Yucatán del 16 - 18 de Marzo del 2016.

Thermal Efficiency Prediction of a Solar Low Enthalpy Steam Generating Plant Employing Artificial Neural Networks

O. May Tzuc, A. Bassam^(✉), Manuel Flota-Banúelos, E.E. Ordonñez López, Lifter Ricalde-Cab, R. Quijano, and Alan E. Vega Pasos

Faculty of Engineering, Autonomous University of Yucatan (UADY),
Av. Industrias no contaminantes por Periférico Norte, Apdo. Postal 150 Cordemex,
Mérida, Mexico

maytzuc@gmail.com, {baali,mbolanos,eduardo.ordonez,oricalde,
renan.quijano,alan.vega}@correo.uady.mx

Abstract. The present paper describes a mathematical model based on application of Artificial Neural Networks (ANN) employing a Multi-Layer Perceptron (MLP) model for thermal efficiency prediction of a solar low enthalpy steam generation plant composed by a Parabolic Trough Collector (PTCs) array. The MLP model uses physical data measurement in the steam production for heat processes. The input parameters used to achieve the prediction of thermal efficiency where: inlet and outlet working fluid temperature, flow working fluid, ambient temperature, direct solar radiation and wind velocity. After several training, the best MLP architecture was obtained employing Levenberg-Marquardt optimization algorithm, the logarithmic sigmoid transfer-function and the linear transfer-function for the hidden and output layer; and four neurons at the hidden layer, which predicts the thermal efficiency with a satisfactory determination coefficient ($R^2 = 0.99996$). The predictive model can be implemented at intelligent sensors that allow to improve control of the PTCs system and leads to better utilization of the solar resource.

Keywords: Photothermal systems · Parabolic trough solar collector · Mathematical model · Artificial intelligences

1 Introduction

In the last decades the rapid increase of energy demand has become a topic of vital importance. Of the total world-wide demand, more than 50 % of the energy is required for industrial processes, principally for heat processes generation [1]. However, almost all the global energy produced for heat processes is generated from fossil fuels, which causes several environmental impacts like global warming and climate change. These reasons show the need to replace the conventional energy generation for alternative and sustainable energy sources.

Among various renewable energies, solar energy is one of the best renewable sources for industrial applications because it is abundant, clean, cheap, free and present minimum environmental impact [2]. At the industry, there are several processes that require temperatures between the range of 80C and 250C; industries such as dairies, plastics, paper, canned food, textiles and among others, required thermal energy for processes like drying, sterilizing, cleaning, evaporation, steam and conditioning warehouses space for heating and cooling. This energy could be provided by photothermal solar collectors, specifically Parabolic Trough Solar Collectors (PTCs) [3,4]. Nevertheless, like all renewable energy systems, PTCs are linked to several variables and exposed to diverse fluctuations by the site climate condition, making the study of this systems very complex and consequently difficult to optimize its performance and to obtain the best cost-benefit at the operation process [5,6].

During the last years, the development of empiric models employing computational artificial intelligences techniques, like Artificial Neuronal Networks (ANN), has been shown as a powerful tool for complex problem solution from noisy and fluctuant data that cannot be solved using conventional methods; the same characteristics are present at most of renewable energy systems, reason for that this computing techniques have been adopted at the present for the modelling of renewable energies [7,8]. At the area of photothermal energy some examples of the use of ANN can be found in works like those made by Kaloguirou et al., [9] who developed an ANN model to predict the useful energy extracted from solar domestic hot water system, using as input data the physical characteristics of the system as collector area, storage type, mean storage tank heat loss, capacity, mean ambient temperature, mean cold water temperature and weather conditions. For the other hand, Géczy-Vg and Farkas [10] used data measurement from a domestic hot water system to develop a model by ANN to describe the thermal stratification in a solar storage tank. Also, Soliutis et al., [11] employed the ANN combined with the software TRNSYS in order to predict the performance of a Integrate Collector Storage prototype using as input data the month of year, the ambient temperature, global radiation, wind speed and incident angle to produce to produce the mean storage tank temperature. Finally Yaci and Entchev [12] predicted by ANNs the preheat tank stratification temperatures, the heat input values from the solar collector to the heat exchanger, the heat input to the auxiliary propane-tank and the derived solar fraction, for the solar thermal energy systems employed for hot water and heating applications.

For this reasons, the aim of this work is the development of a computational model employing ANN for thermal efficiency prediction (Eff) of a solar steam generation plant composed by a PTCs array, from experimental parameters.

2 Artificial Neural Networks

An Artificial Neural Network (ANN) is a structure inspired by the way the nervous system of animals works, and it is integrated by a number of interconnected units, called neurons (Fig. 1). This structure are used to estimate or

approximate functions that can depend on a large number of inputs and are generally unknown; reason why ANN are considered nonlinear statistical data modelling tools and have been used in several engineering applications [13–15].




Fig. 1. Elementary neuron with R inputs.

An ANN can be seen like a black box in which enters a data base conformed by input variables. Each of the input variables is assigned with an appropriate weighting factor (W). The sum of the weighted inputs and the bias (b) produces the input for a transfer function which will generate an output value. The main characteristic of this model is that specific information of the physical behaviour system or the way in which the data were obtained are not required [16].

One of the more used ANN model is the known as multi-layer perceptron (MLP) [17] which can be trained to solve multivariable problems with nonlinear equations. The training process is realized by specific algorithms, where the most used is known as back-propagation [14]. The architecture of a MLP is usually divided into three parts: an input layer, a hidden layer(s) and an output layer (Fig. 2). At the training, the network learns from its errors until to get a model that describes with as much accuracy as possible the studied phenomenon. During the training, weight and bias matrices are generated which each iteration is modified until obtaining the optimal values [18]. At this work the transfer functions employed for nonlinear solutions are the hyperbolic tangent sigmoid transferfunction (Tansig, Eq. 1) and logarithmic sigmoid transferfunction (Logsig, Eq. 2) at the hidden layer; and a linear transfer function at the output layer [19].

$$Tansig(n) = \frac{2}{1 + \exp(-2n)} - 1 \tag{1}$$

$$Logsig(n) = \frac{2}{1 + \exp(-n)} \tag{2}$$

$$Pureline(n) = n \tag{3}$$




Fig. 2. Multi-layer perceptron neural network.

3 Solar Low Enthalpy Steam Generation Plant

The experimental database employed to carry out the present work, was obtained from a low enthalpy steam generation plant composed by a 2.44 m PTCs array. Figure 3 shows a schematic diagram of the system which operates with water as working fluid. The plant consists of two 120 L thermal storage tanks; two hp water pumps; several sensors for the measurement of temperature, pressure and fluid flow at various sections of the system; and an hydraulic circuit that allows to configure the plant for operation in two different modes, open circuit and close circuit.

The data acquisition of variables used for the predictive model development process was measured with average values at intervals of one minute according to ANSI/ASHRAE Standard 93 1986 (RA 91) which describe the assessment method for computing the thermal efficiency of a concentrating collector [20].

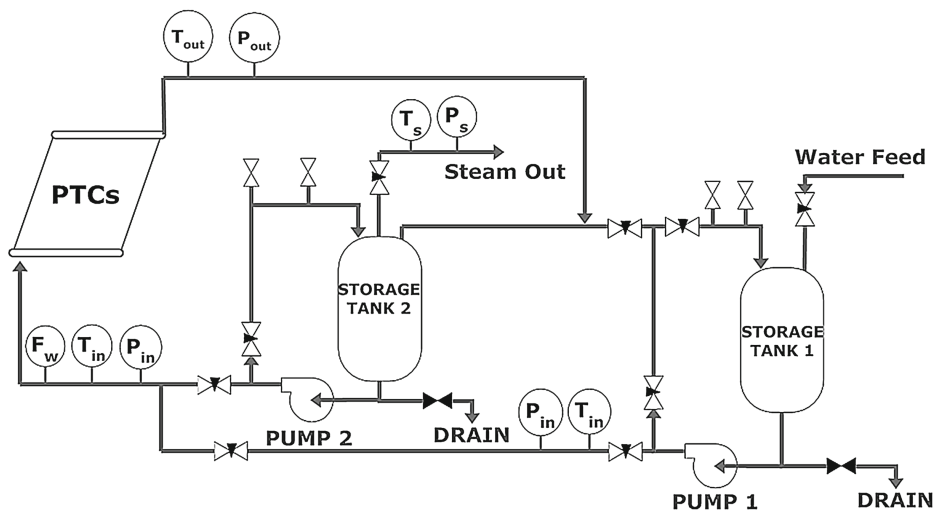


Fig. 3. Solar low enthalpy steam generation plant operation diagram.

The parameters measurement is divided in two categories: operational variables conformed by inlet temperature (T_{in}) and outlet temperature (T_{out}) working fluid, as well as flow working fluid (F_w); and environmental variables composed by ambient temperature (T_{amb}), direct solar radiation (G_b) and wind velocity (V_w). Table 1 shows the six parameters that form the database and the minimum and maximum ranges of each one.

Table 1. Parameters employed at the RNA prediction model.

Parameters		Min	Max	Units
Input				
<i>Operational Variables:</i>				
Inlet Flow Temperature	(T_{in})	27.75	86.30	[°C]
Outlet Flow Temperature	(T_{out})	34.70	100.2	[°C]
Flow working fluid	(F_w)	0.94	6.11	[L/min]
<i>Environmental Variables:</i>				
Ambient temperature	(T_{amb})	24.26	36.99	[°C]
Direct solar radiation	(G_b)	830.0	1014.0	[W/m ²]
Wind velocity	(V_w)	0.95	3.98	[m/s]
Output				
Thermal Efficiency	(Eff)	0.16	0.63	[-]

4 Predictive Mathematical Model

The development of predictive mathematical model of the experimental database was divided in two parts, 80 % was destined to MLP learning and testing process and the other 20 % was employed for the validation of the results, in order to obtain a good representation of the data distribution.

At the training process, a normalized database, was entered into a MLP architecture, where the number of neurons at the input and output layers was given by the number of nput and output variables in the process, respectively. The LevenbergMarquardt (LM) backpropagation algorithm (which is a derivation of the Newton method) was employed to obtain the optimums weights and bias for the MLP model, due it is one of the most successful algorithms in increasing the convergence speed of the ANN with MLP architectures [21]. Once completed the training, a statistical comparison between experimental data and MLP training results is made, if it doesn't meet the criteria, the MLP architecture is modified and the training process is repeated. Figure 4 shows a schematic diagram of the numerical iteration of MLP training process described.

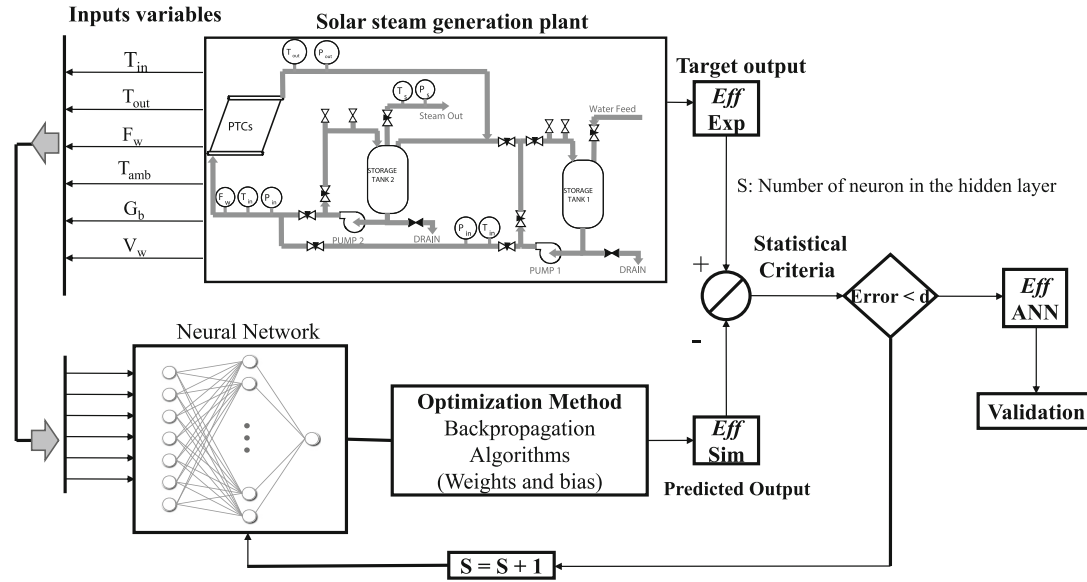


Fig. 4. Numerical procedure used for the MLP learning process, and the iterative architecture used by the model to predict the thermal efficiency in a low enthalpy steam generation plant.

4.1 Optimal ANN Architecture

In order to obtain the optimal MLP architecture, two different pairs of transfer functions (Tansig-Purelin and Logsig-Purelin) for the hidden layer and output layer were tested, varying the neuron number of the hidden layer. The Table 2 shows the results of statistical methods employed (Mean Absolute Percentage Error (MAPE), Root Mean Square Error (RMSE) and correlation coefficient (R^2)) [22] to each one of transfer function pairs with respect to experimental data.

Table 2. Results after training MLP

Neurons	T. Functions	MAPE	RMSE	R^2	Best L. Equation
1	<i>Tansig-Purelin</i>	6.3780	0.0343	0.83976	$y = 0.8393x + 0.0767$
	<i>Logsig-Purelin</i>	6.3784	0.0343	0.83974	$y = 0.8394x + 0.0767$
2	<i>Tansig-Purelin</i>	0.9107	0.0055	0.99606	$y = 0.9945x + 0.0014$
	<i>Logsig-Purelin</i>	0.7184	0.0045	0.99729	$y = 0.9956x + 0.0018$
3	<i>Tansig-Purelin</i>	0.3005	0.0017	0.99959	$y = 0.9984x + 7.26e^{-4}$
	<i>Logsig-Purelin</i>	0.4138	0.0024	0.99920	$y = 0.9988x + 5.36e^{-4}$
4	<i>Tansig-Purelin</i>	0.1831	0.0011	0.99984	$y = 0.9996x + 1.72e^{-4}$
	<i>Logsig-Purelin</i>	0.0955	0.0006	0.99996	$y = 1.0000x + 8.017e^{-5}$




Fig. 5. MLP architecture for thermal efficiency prediction of low enthalpy steam generation plant.

As it can be seen the best MLP model prediction was obtained with 4 neurons in the hidden layer, and the transfer function pair Logsig-Purelin, generating a 6-4-1 MLP architecture (Fig. 5). This model present a smaller MAPE = 0.0955 % and RMSE = 0.0006; and the best linear behaviour fitting with respect to the experimental values given by:

$$Eff_{MLP} = 1.000Eff_{Exp} + 8.017 \times 10^{-5} \quad (4)$$

where the slope of the equation (Eq. 4) is equal to the unity, and its ordinate is very close to zero, indicating a perfect linear fitting borne out by the determination coefficient value ($R^2 = 0.99996$).

The Figs. 6 and 7 shows a comparative between the experimental and simulated thermal efficiency values used at the training and testing stages, respectively. At both figures can be seen that simulated thermal efficiency present the same behaviour ($R^2 = 0.99996$) respect to experimental thermal efficiency independently if it belong to testing or training phase, indicating that samples selected for these process are representative of the phenomenon. On the other hand, through the axes of the graphs, it is possible to observe that the data base values employed covers all the measurement ranges, indicated at the Table 1.

The optimums weights and bias obtained for the best MLP model are shown in the Table 3; IW and LW are the input weights and output weights from the hidden layer; K and S are the total input ($K = 6$) and neuron ($S = 4$) numbers, and b1 and b2 the bias factor.

Therefore, based on the develop MLP architecture (Fig. 4); the logarithmic sigmoid transferfunction (Eq. 2); the linear transfer-function (Eq. 3);




Fig. 6. Experimental versus simulated Eff values for the learning database.




Fig. 7. Experimental versus simulated Eff values for the test database.

Table 3. MLP model prediction optimums weights and bias.

Neurons Number		1	2	3	4	
Weights (W)	Hidden Layer S = 4 K = 6 IW(s,k)	T _{in} (k = 1)	-6.3264	-2.9117	-6.9882	9.5489
		T _{out} (k = 2)	7.2664	-2.4053	8.2889	-10.9960
		F _w (k = 3)	-2.0889	-6.7280	-2.1711	-2.9307
		T _{amb} (k = 4)	-0.2029	-1.1090	0.3753	0.2811
		G _b (k = 5)	-2.4611	-12.240	3.1826	4.0485
		V _w (k = 6)	0.0203	-0.7129	-0.0338	-0.0259
	Output Layer LW(s,1)	Eff (k = 7)	-3.0657	0.0441	2.0878	-2.0904
Bias (b)	b1 (s)	-0.3510	21.1948	-0.7278	0.0081	
	b2	0.3365				

and the values at the Table 3, the proposed model can be analytically represented by the following equation:

$$Eff_{MLP} = \sum_{j=1}^S \left[LW(1, j) \left(\frac{1}{1 + \exp(-(\sum_{k=1}^K (IW(j, k)in(k)) + b1(j)))} \right) \right] + b2 \quad (5)$$

where LW, IW, b1, b2, K and S are described at Table 3, and In is the parameter value corresponding operation.




Fig. 8. Experimental thermal efficiency in function of the heat loss parameter for different work fluid flows.

5 Neural Network Validation

5.1 Thermal Efficiency and Heat Loss Parameter

The manner in which thermal efficiency is shown for a photothermal system is given by the ANSI/ASHRAE Standard 93 1986 (RA 91) [20]. This standard indicate that thermal efficiency must be plotted in function of a variable known as heat loss parameter ($\Delta T/GT_b$), where ΔT is the differences between the flow inlet temperature and the ambient temperature ($\Delta T = T_{in}-T_{amb}$), because this is affected by the solar radiation as well as the amount of heat that provides to

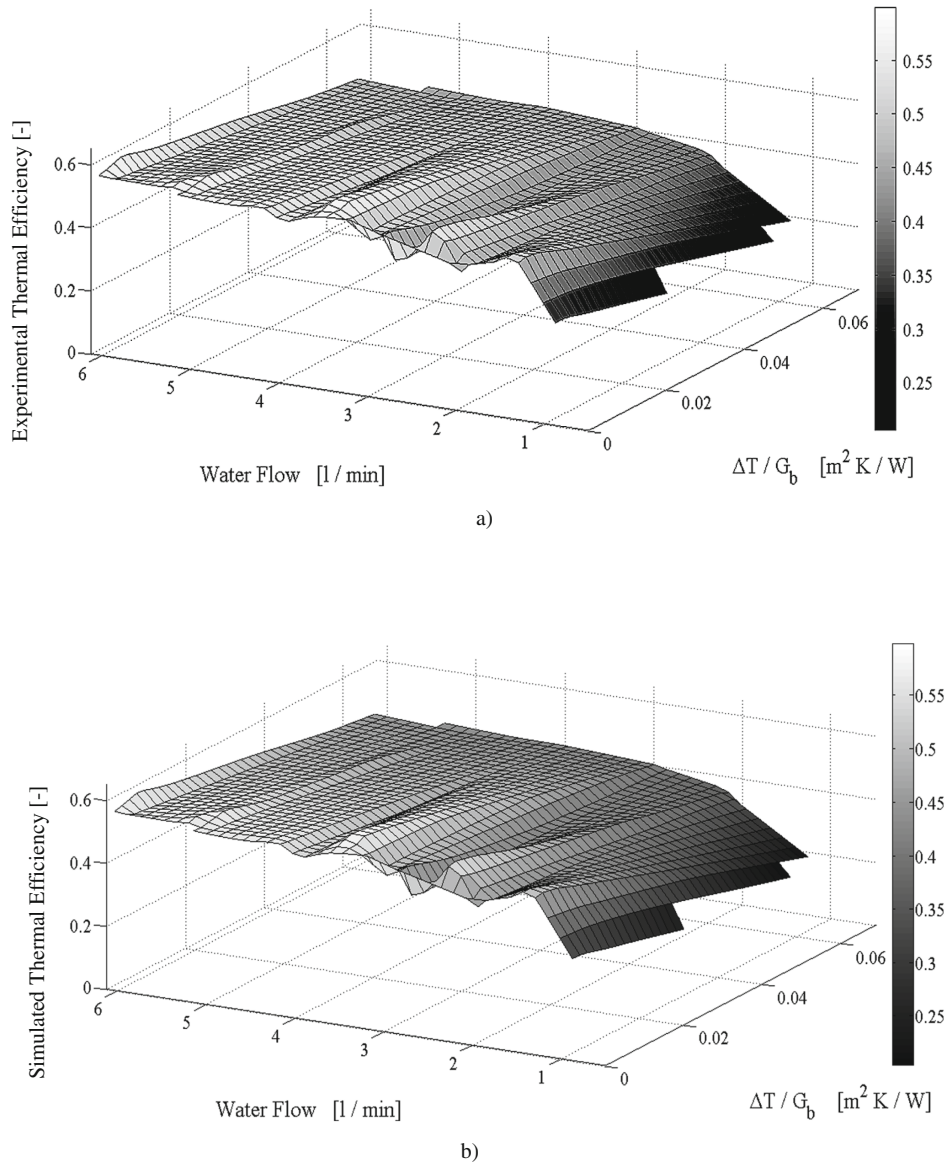


Fig. 9. Thermal efficiency validation. (a) Experimental thermal efficiency not included at the MLP training. (b) Simulate Thermal efficiency from MLP model.

the system. The Fig. 8 shows the experimental thermal efficiency measurement at different working fluid flow values with its respective linear fits. At this picture is possible observe that the equation for each one of the working fluid flows is very poor at all the cases (as is suggested by their coefficients of determination), indicating that is no possible to solve this problem with a linear regression due this is a multivariable case and the equations not regard all the parameter that impact in the thermal efficiency.

5.2 Comparison of Experimental and Simulated Efficiency

The validation of the MLP model was carried out through a comparison employing data not included at the training process [23]. The efficiency comparison was made in function of two variables, the heat loss parameter ($\Delta T/Gb$) and the working fluid flow. Figure 9a shows the real behaviour of the thermal efficiency of the system in function of both parameters (heat loss parameter and fluid flow) and where can be seen a trend to decrease when ΔT increases. Moreover, Fig. 9b represents the values of thermal efficiency obtained from the mathematical model generated with MLP where an appropriate reproduction of the real efficiency curves can be seen, demonstrating that the model is capable of adapting to the variations of flow and heat losses as it is indicated in the statistical criteria from Table 2.

The results obtained after the model validation allows direct application to development cards destined to thermal efficiency prediction and estimation on line of the solar steam generation plant. On the other hand, the employment of this model can reduce research time and costs of system operation. Finally, the predictive model developed can be used to optimize the operating conditions of the arrangement of solar concentrators system.

6 Conclusions

A thermal efficiency predictive model of a solar low enthalpy steam generation plant was develop employing a Multi-Layer Perceptron Artificial Neural Network. The predictive model is presented like a simple computational mathematical equation obtained in function of six input parameters: inlet and outlet working fluid temperature, flow working fluid, ambient temperature, direct solar radiation and wind velocity. The neural networks model have been effectively train with experimental database and validated with an unbiased experimental database (considering the specified training range of operating conditions). The strength of the thermal efficiency computed is also carried out using statistical comparison between the stately and replicated values. Therefore, MLP model could be used for the consistent purpose of thermal efficiency in solar low enthalpy steam generation plants when the input variables measurements are well known into the training algorithms, creating the interactions without the need for a priori expectations about the nature of the connections between inputs and output variables. The progress of this model might have carried

out the application of smart sensors for on-line quality assessment of thermal efficiency in solar low enthalpy steam generation plant. Besides, the model obtained allow a new research line employing the model as an objective function for the optimization of the system using heuristic and numeric computational models.

Acknowledgments. Part of this investigation was sustained by project: **PRODEP 2015 103.5/15/10486**.

References

1. Mekhilef, S., Saidur, R., Safar, A.: A review of solar energy use in industries. *Renew. Sustain. Energy Rev.* **15**, 1777–1790 (2011)
2. Solangi, K., Islam, M.R., Saidur, R., Rahim, N.A., Fayaz, H.: A review on solar energy policy. *Renew. Sustain. Energy Rev.* **15**, 2149–2163 (2011)
3. Kalogirou, S.A.: The potential of solar industrial process heat applications. *Appl. Energy* **76**, 337–361 (2003)
4. Fernández-Garca, A., Zarza, E., Valenzuela, L., Pérez, M.: Parabolic-trough solar collectors and their applications. *Renew. Sustain. Energy Rev.* **14**, 1695–1721 (2010)
5. Bilgili, M., Sahin, B.: Comparative analysis of regressions and artificial neural network models for wind speed prediction. *Meteorol. Atmos. Phys.* **109**, 61–72 (2010)
6. Bhandari, B., Lee, K.-T., Lee, G.-Y., Cho, Y.-M., Ahn, S.-H.: Optimization of hybrid renewable energy power systems: A review. *Int. J. Precis. Eng. Manuf. Green Technol.* **2**, 99–112 (2015)
7. Azadeh, A., Babazadeh, R., Asadzadeh, S.: Optimum estimation and forecasting of renewable energy. *Renew. Sustain. Energy Rev.* **27**, 605–612 (2013)
8. Raza, M.Q., Khosravi, A.: A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings. *Renew. Sustain. Energy Rev.* **50**, 1352–1372 (2015)
9. Kalogirou, S., Panteliou, S., Dentsoras, A.: Modeling of solar domestic water heating systems using artificial neural networks. *Sol. Energy* **65**, 335–342 (1999)
10. Géczy-Vg, P., Farkas, I.: Neural network modelling of thermal stratification in a solar DHW storage. *Sol. Energy* **84**, 801–806 (2010)
11. Solioutis, M., Kalogirou, S., Tripagnotopoulos, Y.: Modelling on a ICS solar water heater using artificial neural networks and TRNSYS. *Renew. Energy* **34**, 1333–1339 (2010)
12. Yaci, W., Entchev, E.: Performance prediction of a solar thermal energy system using artificial neural networks. *Appl. Thermal Eng.* **73**, 1348–1359 (2014)
13. Haykin, S.: *Neural Networks*, 2nd edn. Prentice Hall, Cambridge (1999)
14. Demuth, H., Beale, M.: *Neural Network Toolbox for use with MATLAB, User's guide version 4*. The MathWorks (2014)
15. Kalogirou, S.: Artificial neural networks in renewable energy systems applications: a review. *Renew. Sustain. Energy Rev.* **5**, 373–401 (2001)
16. Bassam, A., Conde-Gutierrez, R.A., Castillo, J., Laredo, G.: Direct neural network modeling for separation of linear and branched paraffins by adsorption process for gasoline octane number improvement. *Fuel* **124**, 158–167 (2014)

17. Rumelhart, D., Geoffrey, E., Williams, R.J.: Learning internal representations by error propagation. In: *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, vol. 1, Foundations. MIT Press (1986)
18. Wasserman, P., Schwartz, T.: Neural networks. II. What are they and why is everybody so interested in them now? *IEEE Expert* **3**, 10–15 (1988)
19. Bassam, A., del Castillo, A.A., Garca-Valladares, O., Santoyo, E.: Determination of pressure drops in flowing geothermal wells by using artificial neural networks and wellbored simulators. *Appl. Thermal Eng.* **75**, 1217–1228 (2014)
20. ANSI/ASHRAE 93–1986 (RA 91), Methods of testing to determine the thermal performance of solar collectors, American Society of Heating, Refrigerating and Air-Conditioning Engineers Inc. (1991)
21. Hagan, M., Menhaj, M.: Training feed forward networks with the marquardt algorithm. *IEEE Trans. Neural Netw.* **5**, 989–993 (1994)
22. Yadav, A., Chandel, S.: Solar radiation prediction using artificial neural network techniques: a review. *Renew. Sustain. Energy Rev.* **33**, 772–782 (2014)
23. Viuela, P.I., Len, I.G.: *Artificial Neural Network Practical Approach*. Pearson Prentice Hall, New York (2003)