



**EDUCACIÓN**

SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO  
NACIONAL DE MÉXICO

# Tecnológico Nacional de México

Centro Nacional de Investigación  
y Desarrollo Tecnológico

## Tesis de Maestría

Implementación de Redes Neuronales para  
Optimización de Sistemas de Calentamiento Solar

presentada por

**Ing. Sandra Ayala Zambrano**

como requisito para la obtención del grado de

**Maestra en Ciencias de Ingeniería  
Mecánica**

Director de tesis

**Dr. José Jassón Flores Prieto**

Cuernavaca, Morelos, México. Agosto de 2020.



# EDUCACIÓN

SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO  
NACIONAL DE MÉXICO

Centro Nacional de Investigación y Desarrollo Tecnológico

"2020, Año de Leonora Vicario, Benemérita Madre de la Patria"

Cuernavaca, Morelos **14/julio/2020**

OFICIO No. SAC/ 215/2020

Asunto: Autorización de impresión de tesis

**SANDRA AYALA ZAMBRANO**  
**CANDIDATA AL GRADO DE MAESTRA EN CIENCIAS**  
**EN INGENIERÍA MECÁNICA**  
**PRESENTE**

Por este conducto tengo el agrado de comunicarle que el Comité Tutorial asignado a su trabajo de tesis titulado *"Implementación de redes neuronales para optimización de sistemas de calentamiento solar"*, ha informado a esta Subdirección Académica, que están de acuerdo con el trabajo presentado. Por lo anterior, se le autoriza a que proceda con la impresión definitiva de su trabajo de tesis.

Esperando que el logro del mismo sea acorde con sus aspiraciones profesionales, reciba un cordial saludo.

### ATENTAMENTE

Excelencia en Educación Tecnológica  
"Conocimiento y tecnología al servicio de México"



CENTRO NACIONAL  
DE INVESTIGACIÓN  
Y DESARROLLO  
TECNOLÓGICO  
SUBDIRECCIÓN  
ACADÉMICA

**DR. GERARDO VICENTE GUERRERO RAMÍREZ**  
**SUBDIRECTOR ACADÉMICO**

C.c.p. M.E. Guadalupe Garrido Rivera. Jefa del Departamento de Servicios Escolares  
Expediente  
CVGR/CHG



Interior Internado Palmira S/N. Col. Palmira. C. P. 62490, Cuernavaca, Morelos

Tel. (01) 777 3 62 77 70, ext. 4106, e-mail: dir\_cenidet@tecnm.mx

www.tecnm.mx | www.cenidet.edu.mx





Centro Nacional de Investigación y Desarrollo Tecnológico  
Departamento de Ingeniería Mecánica

"2020, Año de Leona Vicario, Benemérita Madre de la Patria"

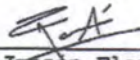
Cuernavaca, Mor., 30/ junio/ 2020


OFICIO No. DIM/136/2020


Asunto: Aceptación de documento de tesis  
CENIDET-AC-004-M14-OFICIO

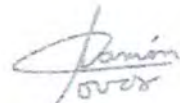
**DR. GERARDO VICENTE GUERRERO RAMÍREZ**  
**SUBDIRECTOR ACADÉMICO**  
**PRESENTE**

Por este conducto, los integrantes de Comité Tutorial de la Ing. Sandra Ayala Zambrano con número de control M18CE058, de la Maestría en Ciencias en Ingeniería Mecánica, le informamos que hemos revisado el trabajo de tesis de grado titulado "Implementación de redes neuronales para optimización de sistemas de calentamiento solar" y hemos encontrado que se han atendido todas las observaciones que se le indicaron, por lo que hemos acordado aceptar el documento de tesis y le solicitamos la autorización de impresión definitiva.

  
Dr. José Jassón Flores Prieto  
Director de tesis

  
Dra. Sara Lilia Moya Acosta  
Revisor 1

  
Dr. Efraín Simá Moo  
Revisor 2

  
Dr. Ramón Tovar Olvera  
Revisor 3

C.c.p. Depto. Servicios Escolares.  
Expediente / Estudiante  
Iniciales ABO/mrsr

## DEDICATORIA

*A mis papás **Angeles y Alejandro** por todo su apoyo y tiempo, no hubiera podido llegar a donde estoy sin sus consejos y cariño. Son mi ejemplo a seguir y siempre me impulsan a ir por más.*

*A mis hermanas **Rebeca y Cecilia** por estar siempre ahí para escucharme, guiarme y demostrarme que lo que se quiere se puede.*

*A mi novio **Alan** por escucharme y soportarme en mis momentos de mayor estrés. Y por estar siempre al pie del cañon cuando más lo necesito.*

*A mis compañeros y amigos del CENIDET por las risas y tormentos que compartimos, así como el apoyo que nos brindamos los unos a los otros para poder salir de los problemas juntos.*

## AGRADECIMIENTOS

A mi director de tesis: **Dr. José Jassón Flores Prieto** por su guía, atención y apoyo, que me ayudó a cumplir el objetivo planteado en este trabajo de tesis en tiempo y forma.

A mi comité revisor: **Dra. Sara Lila Moya Acosta, al Dr. Efraín Simá Moo y al Dr. Ramón Tovar Olvera** por sus consejos, recomendaciones y tiempo invertido en la revisión de este trabajo que lo llevó a su mejora y enriquecimiento.

Al Consejo Nacional de Ciencia y Tecnología (**CONACYT**) por el apoyo económico que me brindaron para proseguir con mi formación académica.

Al Centro Nacional de Investigación y Desarrollo Tecnológico (**CENIDET**) por la oportunidad que me brindó para ahondar en mi formación académica.

	<b>Pág.</b>
<b>Índice general</b>	<b>I</b>
<b>Índice de Figuras</b>	<b>IV</b>
<b>Índice de Tablas</b>	<b>VI</b>
<b>Nomenclatura</b>	<b>VII</b>
<b>Resumen</b>	<b>IX</b>
<b>1. Introducción</b>	<b>1</b>
1.1. Motivación . . . . .	1
1.2. Revisión bibliográfica . . . . .	3
1.2.1. Dimensionamiento de sistemas de calentamiento solar . . . . .	3
1.2.2. Simulación energética de sistemas de calentamiento solar . . . . .	7
1.2.3. Optimización térmica y económica . . . . .	13
1.2.3.1. Análisis variacional . . . . .	13
1.2.3.2. Inteligencia artificial en la optimización de sistemas . . . . .	17
1.2.4. Conclusiones de la revisión bibliográfica . . . . .	23
1.3. Objetivos y Alcances . . . . .	25
1.3.1. Objetivo general . . . . .	25
1.3.2. Objetivos específicos . . . . .	25
1.3.3. Alcances . . . . .	25
1.4. Escritura de la tesis . . . . .	25
<b>2. Muestra y Metodología</b>	<b>27</b>
2.1. Fundamentos Teóricos . . . . .	27
2.1.1. Redes Neuronales Artificiales . . . . .	27

2.1.2.	Calentamiento solar . . . . .	29
2.1.2.1.	Evaluación del recurso solar . . . . .	29
2.1.2.2.	Captador solar . . . . .	30
2.1.2.3.	Termotanque . . . . .	30
2.1.2.4.	Intercambiador de calor . . . . .	31
2.1.2.5.	Calentador auxiliar: . . . . .	32
2.1.2.6.	Razón de uso . . . . .	32
2.1.2.7.	Razón volumétrica . . . . .	33
2.2.	Caso de estudio . . . . .	33
2.2.1.	Localización de la planta solar . . . . .	33
2.2.2.	Demanda térmica . . . . .	35
2.2.3.	Configuración de sistema de calentamiento solar propuesto . . . . .	37
2.3.	Método de optimización de SHIPs con inteligencia artificial . . . . .	39
2.3.1.	Selección de la inteligencia artificial . . . . .	40
2.3.2.	Figuras de mérito . . . . .	41
2.3.2.1.	Parámetros térmicos . . . . .	41
2.3.2.2.	Parámetros económicos . . . . .	42
2.3.2.3.	Parámetros de desempeño de la red neuronal artificial . . . . .	43
2.3.3.	Generación de la base de datos . . . . .	43
2.3.4.	Método de construcción de la red neuronal artificial . . . . .	45
<b>3.</b>	<b>Plataformas de simulación</b>	<b>47</b>
3.1.	Simulación Térmica . . . . .	47
3.2.	Simulación Económica . . . . .	51
3.3.	Verificación de los simuladores . . . . .	55
<b>4.</b>	<b>Desarrollo de la red neuronal</b>	<b>56</b>
4.1.	Análisis de la base de datos . . . . .	56
4.2.	Desarrollo de la arquitectura de la red neuronal . . . . .	67
4.3.	Método de entrenamiento de la red . . . . .	71
<b>5.</b>	<b>Desempeño de las redes neuronales</b>	<b>76</b>
5.1.	Optimización de las redes neuronales . . . . .	76

5.1.1.	Dimensionamiento de la base de datos . . . . .	76
5.1.2.	Designación del parámetro de regularización . . . . .	78
5.1.3.	Selección de la arquitectura de la red neuronal . . . . .	79
5.2.	Verificación de la red neuronal mediante análisis estadísticos . . . . .	80
5.3.	Desempeño de la red neuronal . . . . .	82
5.3.1.	Tiempo de cómputo . . . . .	82
5.3.2.	Número de entradas . . . . .	83
5.3.3.	Habilidades para la optimización . . . . .	83
<b>6.</b>	<b>Conclusiones y recomendaciones para trabajos futuros</b>	<b>84</b>
6.1.	Conclusiones . . . . .	84
6.2.	Recomendaciones para trabajos futuros . . . . .	85
	<b>Referencias</b>	<b>87</b>
	<b>A. Recurso solar</b>	<b>93</b>



## ÍNDICE DE FIGURAS

	<b>Pág.</b>
2.1. <i>Esquema de una neurona artificial [Russell and Norvig, 2016]. . . . .</i>	27
2.2. <i>Esquema de una red neuronal artificial [Russell and Norvig, 2016]. . . . .</i>	28
2.3. <i>Esquema de un captador solar [Cruz-Pinuelas, 2019]. . . . .</i>	30
2.4. <i>Esquema de un termotanque [Cruz-Pinuelas, 2019]. . . . .</i>	31
2.5. <i>Esquema de un intercambiador de calor [Cruz-Pinuelas, 2019]. . . . .</i>	31
2.6. <i>Esquema de un calentador auxiliar [Cruz-Pinuelas, 2019]. . . . .</i>	32
2.7. <i>Distribución municipal de zonas climáticas [González-Osorio and Beele, 2016].</i>	34
2.8. <i>Producto Interno Bruto de las actividades secundarias en el 2017 [INEGI, 2018].</i>	34
2.9. <i>Temperatura en procesos industriales [Muster et al., 2015]. . . . .</i>	36
2.10. <i>Demanda térmica en procesos industriales [Muster et al., 2015]. . . . .</i>	36
2.11. <i>Modelo físico del sistema de referencia para calentamiento solar de agua.</i>	37
2.12. <i>Modelo físico del circuito de captación. . . . .</i>	38
2.13. <i>Modelo físico del circuito de almacenamiento. . . . .</i>	38
2.14. <i>Modelo físico del circuito de integración. . . . .</i>	39
2.15. <i>Esquema del método planteado. . . . .</i>	40
2.16. <i>Metodología de la generación de la base de datos. . . . .</i>	44
2.17. <i>Metodología de la construcción de la red neuronal artificial. . . . .</i>	46
3.1. <i>Sistema de calentamiento solar en la plataforma de simulación. . . . .</i>	49
3.2. <i>Circuito de colección y datos meteorológicos. . . . .</i>	50
3.3. <i>Circuito de almacenamiento. . . . .</i>	50
3.4. <i>Circuito de integración. . . . .</i>	50
3.5. <i>Perfil de carga. . . . .</i>	51
3.6. <i>Algoritmo del programa económico. . . . .</i>	52
3.7. <i>Tabla de optimización térmica. . . . .</i>	53

3.8. <i>Tabla de optimización económica.</i> . . . . .	54
3.9. <i>Tabla de optimización normalizada.</i> . . . . .	54
4.1. <i>Perfiles de carga utilizados para la generación de la base de datos.</i> . . . . .	57
4.2. <i>Gráficas de la <math>R_u</math> en función de la <math>T</math> y la demanda.</i> . . . . .	59
4.3. <i>Gráficas de la <math>R_v</math> en función de la <math>T</math> y la demanda.</i> . . . . .	61
4.4. <i>Gráficas de los LCS en función de la <math>T</math> y la demanda.</i> . . . . .	63
4.5. <i>Gráficas del PB en función de la <math>T</math> y la demanda.</i> . . . . .	65
4.6. <i>Esquema de la primera propuesta de arquitectura</i> . . . . .	67
4.7. <i>Función sigmoideal [Mathworld, 2020].</i> . . . . .	68
4.8. <i>Esquema de la segunda propuesta de arquitectura</i> . . . . .	68
4.9. <i>Esquema de la propuesta de arquitectura final.</i> . . . . .	71
4.10. <i>Diagrama de flujo del entrenamiento de la red para la segunda versión de la arquitectura.</i> . . . . .	72
4.11. <i>Diagrama de flujo del entrenamiento de la red para la arquitectura final.</i> . . . . .	74
4.12. <i>Gráficas de convergencia el método de entrenamiento para (a) <math>R_u</math>, (b) <math>R_v</math>, (c) LCS y (d) PB.</i> . . . . .	75
5.1. <i>Gráficas dimensionamiento de la base de datos para las redes neuronales de (a) <math>R_u</math>, (b) <math>R_v</math>, (c) LCS y (d) PB.</i> . . . . .	77
5.2. <i>Gráficas de <math>\lambda</math> vs <math>J_{train}</math> y <math>J_{test}</math> para las redes neuronales de (a) <math>R_u</math>, (b) <math>R_v</math>, (c) LCS y (d) PB.</i> . . . . .	78
5.3. <i>Gráficas de número de neuronas vs <math>J_{train}</math> y <math>J_{test}</math> para las redes neuronales de (a) <math>R_u</math>, (b) <math>R_v</math>, (c) LCS y (d) PB.</i> . . . . .	79
5.4. <i>Comparación de la base de datos vs los datos calculados por las redes neuronales.</i> . . . . .	81
A.1. <i>Recurso solar en México.</i> . . . . .	93
A.2. <i>Recurso solar en Ecatepec.</i> . . . . .	94
A.3. <i>Recurso solar en Monterrey.</i> . . . . .	94
A.4. <i>Recurso solar en Campeche.</i> . . . . .	95

## ÍNDICE DE TABLAS

	<b>Pág.</b>
2.1. Rangos de temperatura de distintas ramas industriales [Ortega, 2018]. . . . .	35
2.2. Entradas económicas [Ramírez-Martínez, 2019]. . . . .	42
3.1. Características del captador de tubo evacuado [Helmke et al., 2015]. . . . .	47
3.2. Características de los intercambiadores de calor [Helmke et al., 2015]. . . . .	48
3.3. Características de las bombas hidráulicas [Helmke et al., 2015]. . . . .	48
3.4. Características del tanque de almacenamiento [Helmke et al., 2015]. . . . .	49
3.5. Entradas de la plataforma de simulación económica. . . . .	51
3.6. Verificación térmica. . . . .	55
3.7. Verificación económica. . . . .	55
4.1. Parámetros estadísticos de la $R_u$ para los casos optimizados en Campeche, Ecatepec y Monterrey para los perfiles de carga 4.1a, 4.1b, 4.1c y 4.1d. . . . .	58
4.2. Parámetros estadísticos de la $R_v$ óptima en Campeche, Ecatepec y Monterrey para los perfiles de carga 4.1a, 4.1b, 4.1c y 4.1d. . . . .	60
4.3. Parámetros estadísticos de los LCS óptimos en Campeche, Ecatepec y Monterrey para los perfiles de carga 4.1a, 4.1b, 4.1c y 4.1d. . . . .	62
4.4. Parámetros estadísticos del PB óptimos en Campeche, Ecatepec y Monterrey para los perfiles de carga 4.1a, 4.1b, 4.1c y 4.1d. . . . .	64
4.5. Coeficientes de correlación entre las variables dependientes y las variables independientes. . . . .	66
4.6. Diferencias porcentuales entre los errores para las funciones de tanh y ReLU. 70	
5.1. Comparación de tiempo de cómputo para la optimización del método de redes neuronales con el método variacional. . . . .	82

## ***Acrónimos***

<b>Sigla</b>	<b>Descripción.</b>
ANN	Red Neuronal Artificial.
SHIP	Sistema de calentamiento solar para los procesos en la industria.
ETC	Colector de tubos evacuados.
GCS	Ganancia de calor solar.
LOCE	Costo nivelado de la energía.
SD	Desviación estandar.
GCS	Ganancia de calor solar.

## ***Variables***

<b>Símbolo</b>	<b>Descripción</b>	<b>Unidades</b>
$A_{col}$	Área de colección	$m^2$
$A^{[i]}$	Función de activación de las neuronas en la capa $i$	-
$W^{[i]}$	Matriz de peso de las neuronas en la capa $i$	-
$b^{[i]}$	Vector bias para las neuronas en la capa $i$	-
$Z^{[i]}$	Función de entrada para las neuronas en la capa $i$	-
$J_{train}$	Parámetro de error en el entrenamiento	-
$J_{test}$	Parámetro de error en la prueba	-
$J_{cv}$	Parámetro de error en la verificación	-
$T$	Temperatura requerida del proceso	$^{\circ}C$
$D$	Demanda de agua diaria del proceso	$\frac{l}{día}$
$C$	Ciudad de estudio	-
$P - d$	Perfil diario de trabajo	-
$P - s$	Perfil semanal de trabajo	-
$V_{alm}$	Volumen de almacenamiento	$m^3, l$

$R_u$	Razón de uso	$\frac{l}{m^2 \text{ día}}$
$R_v$	Razón volumétrica	$\frac{l}{m^2}$
LCOH	Costo de calor nivelado	$\frac{\$}{kWh}$
LCOE	Costo nivelado de la energía	\$
LCS	Ahorro de Ciclo de Vida	\$
PB	Tiempo de Retorno	años
FS	Fracción Solar	-
$Q_u$	Energía útil	$\frac{kWh}{m^2}$

A lo largo de este trabajo se desarrolla una estrategia de optimización utilizando redes neuronales artificiales, para optimizar sistemas de calentamiento solar de agua con captadores solares de tubos evacuados y almacenamiento térmico, para diferentes ciudades, perfiles de carga, temperaturas requeridas y demandas de agua. En el sistema de calentamiento solar, la razón de uso ( $R_u$ ), la razón volumétrica ( $R_v$ ), los ahorros solares ( $LCS$ ) y el periodo de retorno ( $PB$ ) son los parámetros que se optimizan con una red neuronal diferente cada uno. El desarrollo de las redes neuronales se enfocó en tres aspectos principales. El primero fue la generación y análisis de la base de datos. El segundo fue la arquitectura de la red neuronal, donde se determinaron las funciones de activación de la(s) capa(s) oculta(s) y de salida, el parámetro de regularización, el número de neuronas en cada capa oculta y el número de capas ocultas. El tercer punto fue el entrenamiento de la red, donde se estableció el método de entrenamiento y las ecuaciones utilizadas en éste. La optimización del desempeño de las redes neuronales tomó en cuenta la cantidad de datos utilizados para el entrenamiento, el número de capas ocultas, el número de neuronas en las capas ocultas y el parámetro de regularización. La cantidad mínima de datos fue de mil ejemplos, para asegurar el desempeño adecuado de la red. En las cuatro redes neuronales se utilizó una capa oculta, sin regularización y el número óptimo de neuronas para fue de 4000 para  $R_u$ , 1000 para  $R_v$  y 6000 para  $LCS$  y  $PB$ . El error medio cuadrático menores del 1.2% para  $R_u$ , 5.7% para  $R_v$ , 0.4% para  $LCS$  y 1.3% para  $PB$ . La velocidad de cómputo con el método de optimización de redes neuronales es considerablemente menor que el utilizado en el método variacional, ya que éste toma 23 *min*, mientras que la red neuronal 2 *s*. Con lo anterior, la red neuronal se observa como una herramienta útil para la optimización de  $R_u$ , y  $R_v$ , de los sistemas de calentamiento solar para agua con almacenamiento térmico.

Éste capítulo se presenta la motivación para realizar el trabajo, el estado del arte del tema, que se divide en tres secciones (dimensionamiento, simulación y optimización de los sistemas de calentamiento solar) y los objetivos y alcances de la tesis.

### 1.1. Motivación

Hoy en día, se estima que el 50% de la energía consumida a nivel mundial se destina a procesos industriales [Allouhi et al., 2017]. En el sector industrial, el 74% de la energía se utiliza para generar calor para procesos, principalmente utilizando combustibles fósiles. Lo anterior implica que en la actualidad, el sector industrial representa el 36% de emisiones de  $CO_2$  a nivel mundial y el 17% a nivel nacional. De la demanda de calor en la industria, el 52% se destina para temperaturas por debajo de los  $400^\circ C$ , donde el 22% para producir calor de media temperatura ( $400-150^\circ C$ ) y el 30% para producir calor de baja temperatura (menor a  $150^\circ C$ ). Sin embargo, la aportación de la energía solar a esta demanda de media y baja temperatura aún es limitado [Payback, 2018].

La tecnología de calentamiento solar en la industria mexicana ha mostrado viabilidad, técnica y económica, que se ve reflejada con más de  $400,000 m^2$  de captadores solares instalados en todo el país. El crecimiento promedio anual se estima del 14%, crecimiento considerablemente alto cuando se compara con el crecimiento global de tan solo el 1.7% [Ortega, 2018, AEE, 2019]. La industria de los sistemas de captación solar se encuentra en constante crecimiento y desarrollo en lo referente a aplicaciones domésticas. Sin embargo, las aplicaciones industriales son aún limitadas debido a la reducida competitividad y a la alta incertidumbre de los costos termo-económicos. Esto se ve reflejado en el reducido porcentaje del área de colección instalada de sistemas de calentamiento solar para aplicaciones industriales (SHIP), que es de sólo del 8%. El número total de SHIPs instalados en la república es de 79, que corresponde a una capacidad térmica total de  $14,441.76 kW$  [AEE, 2019].

Los elevados costos de los SHIPs se han atendido de manera limitada, ya que en la mayoría de los casos, los diseños se enfocan en cubrir los requerimientos energéticos y consideran de manera general los costos económicos iniciales del proyecto. Como consecuencia, los costos energéticos de los SHIPs suelen resultar mayores a los casos al compararlos con calentadores eléctricos o de gas [Bouhal et al., 2017]. No obstante, los costos de los sistemas de calentamiento solar pueden ser competitivos con un buen dimensionamiento y selección adecuada de la tecnología dependiendo del perfil de cargas a satisfacer [Allouhi et al., 2017, Barrera-Ayar, 2017, Silva et al., 2014, Tian et al., 2018, Vargas-Bautista et al., 2017]. Con lo anterior, estudios termo-económicos encaminados a reducir costos son una alternativa para el impulso de la industria solar.

El desarrollo de software de simulación térmica ha permitido identificar el comportamiento de dichas variables en función de las condiciones de operación. Sin embargo, en lo general, los diseños de los SHIPs están encaminados a satisfacer demandas específicas bajo condiciones de operación determinadas, restringiendo su uso a casos específicos [He et al., 2012, Hobbi and Siddiqui, 2009, Platzer, 2015]. Por otra parte, en las plataformas de simulación más comunes actualmente, se consume considerable tiempo de cómputo, el usuario debe estar familiarizado con la plataforma y debe tener considerable nivel de *expertise* para lograr resultados congruentes [Quijera et al., 2014].

El desarrollo de metodologías de optimización del diseño de los sistemas continúan siendo clave en el desarrollo de la aplicación de los SHIPs. Algunos factores importantes a considerar en las técnicas de optimización son las condiciones meteorológicas (las cuales pueden tener mediciones o datos incorrectos ocasionando, en caso de no ser detectado, producen una inapropiada optimización del sistema de calentamiento solar) y requerimientos de la industria [Yaïci and Entchev, 2014]. Actualmente, las plataformas para la simulación para la optimización que se encuentran disponibles en el mercado son: TRNSYS, TRANSOL, WATSUN, Polysun y F-Chart. Empero, estas plataformas tienen de varias limitaciones debido a su restricción de uso a configuraciones de sistemas estandarizados. Otra limitación es la incertidumbre derivadas del uso de datos meteorológicos promedio, los cuales son considerados simétrico referente al medio día solar [Duffie et al., 2013, Kalogirou et al., 2008].



La aplicación de inteligencia artificial en la optimización de sistemas es una herramienta que ha venido surgiendo en los últimos 20 años y su crecimiento en su uso se debe a la rapidez de optimización una vez entrenada la red. También, la inteligencia artificial permite que personal sin alto grado de *expertise* pueden utilizarla en la optimización de sistemas de calentamiento solar [Kalogirou et al., 1999]. La capacidad de la inteligencia artificial permite realizar optimización a pesar del ruido o errores que se pueda tener en los datos de entrada [Yaïci and Entchev, 2016]. También cabe mencionar que, al implementar inteligencia artificial para la optimización, el programa se encuentra en un continuo aprendizaje, por lo que con cada nuevo caso se van mejorando los resultados [Kalogirou et al., 2014].

## **1.2. Revisión bibliográfica**

La revisión bibliográfica se dividió en tres rubros: el dimensionamiento de sistemas de calentamiento solar, simulación energética de sistemas de calentamiento solar y optimización térmica y económica (la cual se divide en análisis variacional e inteligencia artificial). A lo largo de éstos rubros se realizó un resumen de los diversos trabajos estudiados relacionados con estos temas.

### **1.2.1. Dimensionamiento de sistemas de calentamiento solar**

Tang et al. [2011] compararon de manera experimental el desempeño, de manera experimental, de dos captadores solares de tubo evacuado iguales al cambiar el ángulo de inclinación. Uno de los captadores fue inclinado  $22^\circ$  y el segundo a  $46^\circ$ . Los dos captadores presentaron, bajo las mismas condiciones, diferentes ganancias de calor. Los investigadores concluyeron que para maximizar la ganancia anual de calor, para los captadores de tubo evacuado, el captador debe tener un ángulo de inclinación que maximice su colección anual de radiación solar. Los experimentos mostraron que el ángulo de inclinación juega un papel importante en el desempeño de los captadores.

Silva et al. [2014] diseñaron una planta de captadores parabólicos para aplicaciones de calentamiento en la industria, seguido de su optimización para lo que se desarrolló un algoritmo memético. Los parámetros variables del diseño fueron: el número de captadores en serie, su número de filas, el espaciamiento entre las

filas y el volumen del tanque de almacenamiento. Como parámetros a optimizar se escogieron: las funciones económicas, ahorro de ciclo de vida, energía solar nivelada y periodo de recuperación, para lo cual, se propuso una aproximación de optimización multi-objetivo. Se llevaron a cabo un extensivo conjunto de casos de optimización para estimar la influencia del precio del combustible, locación de la planta, perfil de demanda, condiciones de operación, orientación del campo solar, incertidumbre de la radiación en el diseño óptimo. Los resultados permitieron cuantificar la optimización del diseño termo económico basada en criterio de corto tiempo ya que el periodo de reembolso lleva a plantas más pequeñas con mayores eficiencias y fracciones solares menores, mientras que la optimización basada en periodos largos, tales como el ahorro de ciclo de vida, lleva a la conclusión opuesta.

Quijera et al. [2014] propusieron un procedimiento para encontrar el mejor escenario de integración de un sistema de calentamiento solar en un proceso industrial, con el fin de obtener una fracción solar deseada. El objetivo principal de la metodología propuesta fue determinar el orden de prioridad correcto para la incorporación del SHIP en el proceso. El primer paso formulado fue la obtención de la información del flujo de agua, seguido de la selección factible de los flujos fríos. La eficiencia del sistema se incrementa con el decremento de la temperatura del flujo, por lo que, según el método propuesto, se debe realizar la clasificación de los flujos. A partir de lo cual se puede encontrar el intercambiador de calor crítico. El sistema de calentamiento se incorpora al intercambiador de calor crítico, en caso de que haya exceso de calor, el calor excedente se conecta al siguiente intercambiador crítico. Para la demostración de la eficiencia del método, el trabajo presenta el caso de estudio de una planta destiladora. El SHIP propuesto constó de más de  $5000 \text{ m}^2$  de área de colección con captadores de tubo evacuado, con agua como fluido de trabajo, sin almacenamiento, con una carga de  $4000 \text{ kW}$ . En el sistema se propuso incluir dos intercambiadores de calor. Energy Plus fue utilizado para simulaciones anuales, el cual se acopló al algoritmo propuesto, con el fin de encontrar la fracción solar objetivo. Tras las simulaciones se obtuvo una fracción solar mensual máxima (en agosto) de 0.03, 0.05 y 0.06 para los 500, 750 y 1000 captadores, respectivamente. Y se calculó un periodo de recuperación de 7-8 años. Con base a lo anterior, se puede concluir que el método propuesto puede mejorar la eficiencia del sistema de calentamiento solar.

Pérez-Grajales [2015] llevó a cabo una evaluación de tres sistemas de calentamiento solar en TRNSYS. El primer sistema se conformó por un área de colección, cuatro bombas, un tanque de almacenamiento y dos intercambiadores de calor, uno antes y uno después del tanque. La configuración del segundo y tercer sistema consistieron en un área de colección, tres bombas hidráulicas, un tanque de almacenamiento y un intercambiador de calor, colocado antes del tanque para el segundo sistema y después del tanque para el tercer sistema. La fracción solar, para un área de colección de  $200 \text{ m}^2$  y un volumen de  $12 \text{ m}^3$ , fue de 0.19, 0.20 y 0.12, para el primer, segundo y tercer sistema, respectivamente. Al variar el volumen del tanque de almacenamiento de  $2.5$  a  $17.5 \text{ m}^3$ , la FS obtuvo valores de 0.10-0.11, 0.14-0.19 y 0.05-0.15, para el primer, segundo y tercer sistema. A partir de lo cual, se puede observar que el segundo sistema tiene un mejor desempeño que el primero, siendo el tercer sistema el que tiene peor desempeño de los tres sistemas. También, al aumentar el volumen de almacenamiento en el primer y segundo sistema la FS también fue aumentando, sin embargo para el tercer sistema al aumentar el volumen, la FS fue disminuyendo.

Barrera-Ayar [2017] diseñó un sistema de captación solar de mediana temperatura para el precalentamiento de agua de reposición para calderas, con una demanda de  $25 \frac{\text{m}^3}{\text{día}}$ . El agua tratada se entrega a  $90^\circ\text{C}$ , y el desempeño del sistema en términos de la fracción solar y calor útil anual se comparó para la Ciudad de México, Toluca y Monterrey. El diseño implicó establecer las condiciones climáticas de cada una de las ciudades; posteriormente, se simuló y verificó el sistema en la plataforma TRNSYS. Para lo anterior, el sistema se configuró con un conjunto de área de captadores solares, dos intercambiadores de calor, cuatro bombas hidráulicas, un tanque de almacenamiento y un calentador auxiliar. Finalmente, se hizo una optimización de la fracción solar, variando la razón volumétrica con  $10$ ,  $20$  y  $50 \frac{\text{l}}{\text{m}^2\text{-año}}$ , a partir de lo cual, se observó que la razón volumétrica óptima fue de  $20 \frac{\text{l}}{\text{m}^2\text{-año}}$ , dados por la fracción solar obtenida y costos de instalación. La razón de uso estimada, para el sistema, fue de  $62 \frac{\text{l}}{\text{m}^2\text{-día}}$  para un área de colección de  $420 \text{ m}^2$ , para obtener una fracción solar de 0.42, 0.45 y 0.49 para Toluca, la Ciudad de México y Monterrey, respectivamente. En este trabajo, se mostró la importancia de la razón de flujo en la eficiencia del sistema. Por otra parte, se obtuvieron comportamientos similares para la Ciudad de México y Toluca.

Arcos-Adame [2018] realizó una herramienta para el diseño de sistemas de calentamiento solar para el precalentamiento de agua mediante energía solar, para 12 ciudades con cuatro climas diferentes de México. Las ciudades fueron Monterrey, Chihuahua y Hermosillo (clima seco), Torreón, Mexicali y La Paz (clima muy seco), Cd. Victoria, Poza Rica y Cd. Del Carmen (clima cálido subhúmedo) y Toluca, Cd. De México, y Guadalajara (clima templado). La herramienta se llevó a cabo variando la razón de uso,  $R_u$ , y la razón volumétrica,  $R_v$ , así como el ahorro de ciclo de vida,  $LCS$ . Las figuras de mérito fueron la fracción solar,  $FS$  y la ganancia de calor solar. La plataforma de simulación utilizada para la optimización térmica fue TRNSYS y para la optimización económica fue una hoja de cálculo. La  $FS$  varió de 0.05 a 0.6 para las áreas de  $138 \text{ m}^2$  a  $1100 \text{ m}^2$ , respectivamente. Al variar el volumen, la  $FS$  varió aproximadamente un 15%. Todas las ciudades mostraron el ahorro máximo con una razón de uso de  $50 \frac{\text{l}}{\text{m}^2\text{-día}}$ . La razón volumétrica óptima fue de  $50 \frac{\text{l}}{\text{m}^2}$  para Chihuahua, Hermosillo, Torreón, Mexicali, La Paz, Cd. Del Carmen y Toluca y  $30 \frac{\text{l}}{\text{m}^2}$  para Monterrey, Cd. Victoria, Poza Rica, Ciudad de México y Guadalajara. La fracción solar fue de 0.58, 0.68, 0.7, 0.63, 0.65, 0.7, 0.56, 0.46 y 0.64 para Monterrey, Chihuahua, Hermosillo, Torreón, Mexicali, La Paz, Cd. Victoria, Poza Rica, Cd. Del Carmen, respectivamente. Se concluyó que el tipo de clima no tiene un impacto significativo en el desempeño económico de un SHIP, sin embargo la cantidad de irradiación si tiene un mayor impacto en el desempeño del mismo. Las  $R_u$  y  $R_v$  son factores importantes para un buen dimensionamiento de sistemas de calentamiento solar, así como el uso de figuras económicas.

El dimensionamiento de un sistemas de calentamiento solar es la base clave para que estos sistemas sean competitivos. Esto se debe a que un sistema sobredimensionado implica una fuerte inversión, lo que conlleva a que el sistema no sea económicamente viable. Por otra parte, si un sistema es sub-dimensionado, entonces implica que el sistema no aporte el calor requerido. La  $FS$  es el parámetro térmico más usado para el dimensionamiento de estos sistemas. El área de colección, el volumen de almacenamiento, la configuración del sistema y el punto de incorporación al proceso pueden hacer variar la  $FS$  en más de un 15%. Por dicha razón, estas variables son consideradas importantes para el dimensionamiento de los SHIPs.

## 1.2.2. Simulación energética de sistemas de calentamiento solar

Ayompe et al. [2011] presentaron un modelo validado de TRNSYS para sistemas de calentamiento solar con circulación forzada. El modelo se utilizó para evaluar dos sistemas de calentamiento solar, uno con captadores de placa plana y el otro con tecnología de tubo evacuado. El modelo se validó con un sistema de captadores instalados en una azotea plana con dirección al sur y una inclinación de  $53^\circ$ , en un edificio del Instituto de Tecnología de Dublín en Dublín, Irlanda. El área de colección fue de  $3.0$  y  $4.0 \text{ m}^2$  para las tecnologías de tubo evacuado y placa plana, respectivamente. Cada sistema fue equipado con un tanque de almacenamiento cilíndrico presurizado de  $300 \text{ l}$ . El perfil de demanda utilizado fue de un volumen total de  $200 \text{ l}$  a  $60^\circ\text{C}$  diario. Para la obtención de los datos meteorológicos, tres días fueron escogidos, uno en verano, uno en otoño y uno en invierno, los datos obtenidos fueron utilizados como entradas en el modelo de TRNSYS. El porcentaje promedio del error absoluto y el porcentaje promedio de error fueron utilizados para la cuantificación de las variaciones entre los valores medidos y los predichos. Los porcentajes promedio de error absoluto calculados de la temperatura de salida, el calor recolectado y entregado fue, respectivamente, de  $16.9\%$ ,  $14.1\%$  y  $6.9\%$  para la tecnología de placa plana y de  $18.4\%$ ,  $16.8\%$  y  $7.6\%$  para la tecnología de tubo evacuado. Por otra parte, los porcentajes promedio de error obtuvieron valores de  $-9.7\%$ ,  $7.6\%$  y  $6.9\%$ , para la tecnología de placa plana, y  $13.7\%$ ,  $12.4\%$  y  $7.6\%$ , para la tecnología de tubo evacuado de la temperatura de salida, el calor recolectado y entregado respectivamente. Para los captadores de placa plana, el modelo subestimó la temperatura de salida y sobreestimó el calor recolectado y entregado. En el caso de tecnología de tubo evacuado, el modelo sobreestimó los tres parámetros. A partir de lo anterior, los autores concluyeron que el modelo validado de TRNSYS puede ser utilizado para la predicción de un desempeño a largo plazo de sistemas de calentamiento solar en diferentes locaciones y la simulación de desempeño de sistemas bajo diferentes condiciones meteorológicas y condiciones de operación.

Hazami et al. [2013] estudiaron el potencial energético y térmico de los sistemas de calentamiento solar domésticos en Túnez, Túnez y los compararon con los métodos de calentamiento de agua en el sector doméstico. En primera instancia, se realizaron simulaciones con el software TRNSYS, para tecnologías de placa plana y tubo evacuado. Las simulaciones fueron realizadas para una casa con 4-5 ocupantes (con un consumo estimado de  $265 \frac{\text{l}}{\text{día}}$ ) a lo largo de un año. Posteriormente,

se validó experimentalmente el modelo de simulación, obteniendo una diferencia entre lo simulado y lo medido del 4 % y del 3 % para las tecnologías de placa plana y tubo evacuado, respectivamente. Una vez validado, los resultados obtenidos de las simulaciones fueron utilizados para evaluar la energía colectada y la fracción solar relativa a las dos instalaciones (tecnología de placa plana y de tubo evacuado). A partir de lo cual, se evaluaron los ahorros, la viabilidad económica y los tiempos de recuperación para las dos tecnologías. La energía colectada varió alrededor de 336-694.5 y 670-959  $\frac{kWh}{m^2}$  para las tecnologías de placa plana y tubo evacuado respectivamente. La fracción solar promedio anual, para la tecnología de placa plana, fue del 68 %, mientras que para la tecnología de tubo evacuado fue del 84 %. El ahorro anual en energía eléctrica y periodo de recuperación, para la tecnología de placa plana, fue de 1316  $\frac{kWh}{año}$  y 8 años (comparado a un calentador eléctrico) y de 306  $\frac{m^3}{ciudad}$  y 6 años de periodo de recuperación (comparado a un calentador de gas). Para la tecnología de tubo evacuado, se obtuvieron ahorros de 1459  $\frac{kWh}{año}$  y un periodo de recuperación de 10 años (comparado a un calentador eléctrico) y de 410  $\frac{m^3}{ciudad}$  y 7.5 años de periodo de recuperación (comparado a un calentador de gas). Con base a lo cual, los autores concluyeron que los sistemas de energía solar son eficientes y costo efectivos.

Abdunnabi et al. [2014] realizaron una modelación en TRNSYS de un sistema de calentamiento solar para uso doméstico. El sistema consistió de cuatro captadores de tubo evacuado, conectados en serie, componentes de las bombas hidráulicas y un tanque de almacenamiento de 200 l. La modelación fue validada con datos experimentales obtenidos cada cinco minutos, a lo largo de seis días consecutivos (del 20 al 26 de marzo del 2013) en el Center for Solar Energy Research and Studies en Tajoura. Los parámetros medidos fueron las temperaturas del agua de entrada y salida del tanque y del captador, los datos meteorológicos y la razón de flujo. Los resultados mostraron una discrepancia máxima de 13 % entre los valores simulados y los medidos de la radiación solar global por día. Para las temperaturas de retorno y salida de los captadores, el porcentaje de error fue entre el 6 - 20 % y el 8.5- 23 %, respectivamente. El error promedio entre la energía acumulada medida y simulada fue menor a 20.5 %. Los resultados mostraron que la plataforma de modelación TRNSYS provee de predicciones satisfactorias comparadas con los datos experimentales.

Platzer [2015] realizó un reporte en el cual analizan siete diferentes softwares

de simulación de *SHIP*. A lo largo del reporte realizaron una descripción detallada de cada una de las herramientas de simulación. Cada uno de los softwares son analizados considerando una introducción, seguido de los fundamentos matemáticos y de programación, el modelado de sistemas térmicos solares, evaluaciones de unos sistemas de calentamiento solar y terminando con un resumen de las ventajas y desventajas de cada uno de estos softwares. Los softwares analizados son TRNSYS, Colsim, Insel, TSOL, Polysun, Greenius y EXCEL-SOPRO. Los autores determinaron que TRNSYS es una herramienta flexible y adecuada, cuando se tiene disponible una descripción detallada del sistema con componentes bien descritos, donde los parámetros del modelo están claramente definidos. Así mismo, COLSIM también fue descrito como una herramienta flexible, aunque menos práctica para estudios básicos, sin embargo, muy adecuada para la optimización de parámetros operacionales de plantas existentes o plantas con una planeación detallada. Por su parte, los autores creen que en Insel, el uso de los bloque DELAY puede influenciar la funcionalidad de algunos bloques de control. Mientras que TSOL mostró que las simulaciones de los procesos se pueden realizar rápidamente, debido a los modelos pre-configurados, además de ser una herramienta altamente intuitiva, empero, debido a dichos sistemas pre-configurados los modelados con arreglos hidráulicos complejos y sus estrategias correspondientes de control son limitados. Al igual que en TSOL, Polysun cuenta con modelos predefinidos, sin embargo, el software está limitado a valores de cada hora promedio y a un sistema con presiones máximas de 50 bar, sin mencionar las limitaciones dadas por sus limitaciones al definir el perfil de carga. Los autores consideraron que Greenius es el software para estimaciones de desempeño preliminares dentro de un estudio de factibilidad, pero no debe ser utilizado para cuestiones ingenieriles más detalladas. EXCEL-SOPRO fue descrita como una herramienta de diseño simple y relativamente fácil de usar, sin embargo, varias características necesitan ser mejoradas. Por lo que se puede concluir que TRNSYS y COLSIM son herramientas útiles para la modelación de diferentes tipos de sistemas, y se tiene un poco más de libertad que en el resto de los softwares, a la hora de escoger la configuración del sistema.

Vargas-Bautista et al. [2017] realizaron un estudio termo-económico de una planta destiladora de etanol con calentamiento solar, para la producción de etanol al 95% en la ciudad de Monterrey, México. El estudio se realizó a lo largo de un año, se evaluaron tecnologías de tubo evacuado y de canal parabólico, para la simulación térmica y económica se utilizó TRNSYS. El flujo volumétrico fue de 200

$\frac{l}{h}$  para concentraciones acuosas de etanol del 5% y 10%. La fracción solar con la tecnología de tubo evacuado fue 12.6% mayor que con la de canal parabólico. El periodo de recuperación y el costo nivelado fue de 20 y 18.79 años 1.152 y 1.197  $\frac{US\$}{l}$  para el captador de tubo evacuado y para canal parabólico respectivamente. Los autores mostraron que la tecnología de tubo evacuado provee una mayor fracción solar y costo nivelado que la de canal parabólico.

Bouhal et al. [2018] estudiaron los efectos de la tecnología de los captadores, condiciones climáticas y el perfil de demanda de agua caliente, en el desempeño de un sistema de calentamiento de agua solar doméstico en Marruecos. El sistema se conformó de captadores, un tanque de almacenamiento térmico aislado, una bomba, un tanque de almacenamiento, un sistema de calentamiento auxiliar y controles. Las tecnologías consideradas en este estudio fueron: de placa plana, de tubo evacuado y de canal parabólico. Marruecos fue dividido en seis ciudades de referencia, la división se basó en los grados del día y zona geográfica. El software Meteororm se utilizó para la obtención de los datos meteorológicos en cada una de las ciudades. Las simulaciones fueron realizadas con el software TRANSOL 3.0 para la obtención de la temperatura del tanque de almacenamiento y la temperatura de salida de cada captador. Cinco perfiles de carga fueron considerados (el DTIE, el diurno, el europeo, el mañanero y el de la tarde) para un consumo de agua diario de 240 l a una temperatura de 45°C. La energía colectada, a lo largo del año, fue de 220-440 kWh, 255-450 kWh y 280-500 kWh, con áreas de 2.3 m<sup>2</sup>, 2 m<sup>2</sup> y 2 m<sup>2</sup>, para las tecnologías de placa plana, de canal parabólico y de tubo evacuado, respectivamente. Las FS obtenidas para los perfiles DTIE, diurno y mañanero, fueron del 42 al 80% para los meses de diciembre, enero, febrero y marzo. Mientras que para los perfiles de carga europeo y de la tarde, las FS obtenidas variaron entre 42 y el 52%, para los mismos meses. También, se apreció que la tecnología de tubo evacuado se desempeñó mejor, que la de placa plana y captador parabólico, siendo las FS de entre 32-78% para la tecnología de placa plana, 42-88% para la de tubo evacuado y de 35-82% para la de canal parabólicos. Con base a lo anterior, se concluyó que es importante el tipo de perfil de carga y tecnología utilizada.

Cruz-Pinuelas [2019] desarrolló una herramienta gráfica para la evaluación del desempeño térmico de un sistema de calentamiento solar, para el precalentamiento de agua para calderas, con captadores planos y almacenamiento. La herramienta gráfica, construida en la plataforma de simulación TRNSYS, se utilizó



en un caso de estudio con una demanda de  $18 \frac{m^3}{\text{día}}$  de agua a  $90^\circ C$  en Guaymas, Sonora. La configuración del sistema seleccionado para el caso de estudio estuvo conformado por captadores solares, intercambiadores de calor, tanque de almacenamiento térmico, bombas hidráulicas y calentador auxiliar. Los parámetros de optimización utilizados fueron la  $FS$  y la ganancia de calor solar ( $GCS$ ). En el trabajo se estudiaron 3 configuraciones de carga con 24 perfiles de carga continuos cada una, 8 razones de uso (25, 50, 75, 100, 125, 150, 175 y  $200 \frac{l}{m^2-día}$ ) y 3 razones volumétricas (30, 50 y  $70 \frac{l}{m^2}$ ). Los valores máximos de la  $FS$  fueron de 0.89-0.92 para la razón de uso de  $25 \frac{l}{m^2-día}$ . Por otra parte, los valores máximos de la  $GCS$  fluctuaron entre  $1923.8$  a  $1938.4 \frac{kWh}{m^2-año}$ , para la razón de uso de  $200 \frac{l}{m^2-día}$ , es decir, a mayor razón de uso mayor  $FS$  y menor  $GCS$ . También, se observó que, a partir del perfil de carga de 11 horas, los valores de la  $FS$  y  $GCS$  son similares para las tres configuraciones y sufren un decremento del 5.0 % y  $110.02 \frac{kWh}{m^2-año}$ , respectivamente. Para los diferentes perfiles de carga, se encontró una variación del 15 al 60 % en la  $FS$  y de 390 a  $1490 \frac{kWh}{m^2-año}$  en la  $GCS$ . El autor concluyó que los valores de la  $FS$  y la  $GCS$  se ven afectados en primer lugar por el perfil de carga, seguido por la  $R_u$ . El autor concluyó que la razón volumétrica tiene un efecto poco considerable sobre los parámetros de optimización.

Ramírez-Martínez [2019] realizó una optimización termo-económica de un sistema de precalentamiento de agua mediante energía solar en Chihuahua, Cancún y la Ciudad de México. El sistema se conformó de captadores de tubo evacuado, dos intercambiadores de calor, tres bombas hidráulicas, un tanque de almacenamiento y dos controles de temperatura. El sistema trabaja con tres fluidos de trabajo, agua/etilenglicol, agua potable y agua tratada para el circuito de colección, de almacenamiento y de proceso, respectivamente. Las figuras de mérito son la fracción solar, la energía útil, la tasa interna de retorno, el tiempo de retorno y los ahorros solares. Las simulaciones térmicas del sistema se realizaron con TRNSYS, donde se estableció una demanda de  $27,500 \frac{l}{\text{día}}$  a  $90^\circ C$ . La plataforma de simulación económica se desarrolló en una hoja de cálculo del programa Excel, y se basó en un análisis de ahorro de ciclo de vida. En la optimización térmica, el área de colección y volumen de almacenamiento óptimos fueron de  $275 m^2$  y  $13.75 m^3$  para las tres ciudades, respectivamente. Las fracciones solares óptimas fueron de 0.53, 0.43 y 0.39, mientras que las energías útiles óptimas fueron de  $1356.63 \frac{kWh}{m^2-año}$ ,  $1090.7 \frac{kWh}{m^2-año}$  y  $983.98 \frac{kWh}{m^2-año}$  para Chihuahua, CDMX y Cancún, respectivamente. En el análisis económico para las ciudades CDMX y Cancún fue necesario conside-

rar subsidio, ya que sin él se generaron ahorros solares negativos. En la CDMX se obtuvo un ahorro solar máximo de \$508,964.12, una tasa interna de recuperación máxima de 12.42% y un tiempo de recuperación mínimo de 4.16 años, considerando subsidio del 50%. Para Cancún, el ahorro solar máximo, la tasa interna de recuperación máxima y el tiempo de recuperación mínimo obtuvieron los valores de \$362,073.48, 11.78% y 3.67 años considerando un subsidio del 60%, respectivamente. Mientras que para Chihuahua la optimización económica se presentó para un área de colección de  $275 m^2$ , un volumen de almacenamiento de  $19.25 m^3$ , con lo cual se obtuvo un ahorro solar máximo de \$527,697.29, una tasa interna de recuperación de 9.9% y un tiempo de retorno de la inversión mínimo de 6.75 años. Por lo que el autor pudo concluir que en Chihuahua resulta viable implementar este sistema, mientras que en la CDMX y Cancún es necesario un subsidio. Por otra parte, en el estudio económico, se observó que la tasa interna de retorno y los ahorros solares son los parámetros económicos con mayor sensibilidad a los cambios en la razón de uso y volumétrica, que el periodo de retorno de la inversión y el precio de la energía.

Lugo et al. [2019] desarrollaron una subrutina en TRNSYS (Type), para el cálculo de pérdidas térmicas en las tuberías, en un sistema de calentamiento de agua solar para la industrial, basada en un modelo numérico. La validación del modelo matemático se realizó con datos experimentales de 100 días, en Temixco, México. El sistema experimental consistió de 18 *ETC*, un tanque de almacenamiento de 700 l, un calentador auxiliar eléctrico de 10 kW, un intercambiador de calor acoplado con un enfriador, controles de temperatura diferencial y bombas de recirculación. El modelo de validación consideró una carga térmica de 15 a 20 kW, con un perfil diario de carga a lo largo 6 h. El Type de cada componente del sistema se validó, y también en su conjunto. La desviación promedio entre los resultados numéricos y experimentales fue de  $\pm 6.5\%$  para la ganancia térmica útil y las pérdidas térmicas en las tuberías. La desviación promedio para las temperaturas fue de  $\pm 0.5\%$ . La pérdida de energía por tuberías en sistemas de calentamiento de dimensiones grandes debe ser tomado en cuenta y reducido en su mayor medida. Es importante el arreglo de los captadores, con el fin de reducir las pérdidas por las tuberías.

Los softwares de simulación de *SHIP* han demostrado ser una herramienta útil y fehaciente para estudiar, diseñar y analizar dichos sistemas. Entre éstos softwares, TRNSYS y COLSIM se destacan por su libertad en la elección de las confi-

gurasiones de los sistemas. Se pudo apreciar que la tecnología de los captadores solares también afecta considerablemente al desempeño del sistema, ya que al cambiar el tipo de captador, la fracción solar llegó a tener diferencias de hasta el 10 %. El perfil de carga de un sistema de calentamiento solar, a nivel industrial, puede afectar un 40 % en el desempeño del sistema, mientras que a nivel doméstico, el efecto se reduce al 10 %. La pérdida de energía por tuberías en sistemas de calentamiento de dimensiones grandes debe ser tomada en cuenta.

### **1.2.3. Optimización térmica y económica**

En esta sección se analizan los trabajos de optimización de sistemas de calentamiento solar mediante dos métodos principalmente, el variacional y el de inteligencia artificial.

#### **1.2.3.1. Análisis variacional**

Banos et al. [2011] hicieron una recolección de los estudios que se han hecho en optimización en energías renovables, tales como la energía eólica, solar, hidráulica, geotérmica y bioenergía. En la optimización de sistemas de energías renovables, el reto implica identificar los parámetros a considerar, seleccionar la metodología e identificar el lugar de estudio. Los estudios de optimización mencionan los diversos métodos de optimización, entre los cuales las aproximaciones de redes neuronales se destacaron por el poco tiempo en llevarse a cabo, en comparación al tiempo que se toma para las otras optimizaciones. La revisión bibliográfica consideró 216 artículos, de los cuales, 29 se enfocan a la energía solar. Estos artículos mencionan el uso de redes neuronales para realizar diversas optimizaciones, demostrando que el uso de redes neuronales es sumamente útil para este tipo de estudios. En los estudios de energías renovables, se observa que por lo general es necesario hacer una optimización multi-objetivo, lo cual puede ser sumamente complicado siguiendo un enfoque tradicional tales como la programación de intervalo lineal, programación cuadrática, entre otros.

Baniassadi et al. [2015] evaluaron la viabilidad de la integración de un sistema de calentamiento solar en una fábrica empacadora de atún, en el lado del Atlántico del país Vasco, utilizando análisis pinch. El perfil de carga fue de 12 horas al día, por cinco días a la semana en invierno, y por seis días a la semana en verano. El análisis Pinch se realizó con base a la información de los flujos fríos y calientes, tomando

en cuenta la compatibilidad temporal de flujos. El punto pinch global fue ubicado en  $105.0^{\circ}\text{C}$ , con un requerimiento de  $3875 \frac{\text{kWh}}{\text{día}}$ . A partir de un primer análisis pinch se propuso un diseño optimizando la energía. El desempeño se evaluó por con un segundo análisis pinch. Una vez que los requerimientos energéticos del proceso optimizado se determinó la viabilidad de la incorporación del sistema de calentamiento solar para precalentamiento de agua para caldera. La factibilidad de la instalación termo solar se estimó para dos escenarios diferentes, el acomodo de los captadores solares en serie o en serie-paralelo. Las orientaciones de los captadores se establecieron hacia el sur con un ángulo de  $43^{\circ}$ . El fluido de trabajo utilizado fue una mezcla de propineltglicol-agua al 35 %. Para el caso de los captadores en serie, el área de absorción fue  $359 \text{ m}^2$ , alcanzando una fracción solar de 0.115, y produciendo una carga de calor neta de  $547 \frac{\text{kWh}}{\text{día}}$ . En el segundo escenario se evaluó el sistema con un arreglo de dos líneas de captadores en serie , con Propineltglicol-agua al 55.4 %. La fracción solar en el segundo escenario fue de 0.097 con un área de absorción de  $371 \text{ m}^2$ . A partir de lo anterior, el sistema de calentamiento solar se incorporó al proceso. Tras la incorporación del sistema seleccionado al proceso, el proceso se evaluó con un nuevo análisis pinch, en el cual, se observó un pequeño decremento del punto pinch global a  $98.2^{\circ}\text{C}$ . Después de la optimización y la incorporación del sistema de calentamiento solar, la reducción de combustible fósil fue del 24 %. Para finalizar, los autores concluyeron que en el proceso se pudo reducir notoriamente su consumo de combustible alcanzando un nivel de independencia de energía significativo.

Allouhi et al. [2017] exploraron la utilización de calentamiento solar de agua centralizada con diferentes perfiles de carga, para su aplicación en la industria de la comida. El proceso estudiado, se dividió en cuatro etapas, cada una con diversos requerimientos. El sistema propuesto, se conformó por una red de captadores solares, un tanque de almacenamiento centralizado, una serie de bombas hidráulicas y un sistema de calentadores en serie a la entrada de cada proceso. Con dos circuitos de control para la activación de las bombas, en función a la radiación solar incidente, y la comparación de las temperaturas en el intercambiador de calor y el fondo del tanque. El sistema se diseñó con base a las condiciones climáticas de Marruecos, se realizó un modelo matemático para los componentes del sistema y se realizó un análisis económico. Se llevó a cabo una optimización del ahorro anual del ciclo de vida, en términos del ángulo de inclinación, área del campo de captadores y volumen del tanque; para lo cual, se realizaron una serie de simulaciones.

Obteniendo como resultado un ángulo de inclinación de  $30^\circ$ , un área de  $400 \text{ m}^2$  y un volumen de almacenamiento mínimo de  $2000 \text{ l}$ , esto considerando un flujo de masa de  $9000 \frac{\text{kg}}{\text{h}}$ . Se calculó un  $PB$  de  $12.27 \text{ años}$  y una  $FS$  de  $41.01\%$ , correspondiente a un ahorro de energía alrededor de  $216.62 \text{ MWh}$ . Con una reducción de emisiones de  $\text{CO}_2$  de  $77.23 \text{ toneladas}$ . Se observó que el área de colectores y el ángulo de inclinación son de suma importancia. El ahorro de ciclo de vida puede llegar a variar hasta en un  $40\%$  y  $20\%$ , debido al área de colección y volumen de almacenamiento, respectivamente, también puede variar en un  $100\%$  e incluso llegar a números negativos debido al ángulo de inclinación de los captadores.

Acir et al. [2017] realizaron un estudio para identificar los parámetros con mayor influencia en las eficiencias de energía y exergía de un calentador de aire de tubos evacuados. El análisis se realizó utilizando datos experimentales, las razones de contribución de cada parámetro fue determinada mediante un análisis de varianza. Cabe mencionar que las ecuaciones empíricas de las eficiencias de energía y exergía fueron comparadas con los datos experimentales y derivadas con un análisis de regresión. De acuerdo con el análisis de varianza, los factores con mayor influencia en las eficiencias fueron el número de Reynolds con un  $51.30\%$ , los ángulos de desahogo con un  $22.59\%$ , y las longitudes de los tubos con  $22.51\%$  de influencia. Por otra parte, los resultados obtenidos con el análisis de regresión obtuvieron una  $R^2$  de  $0.9227$  al compararlos con los datos experimentales, por lo que se concluye que el uso del análisis de regresión es adecuado para estimar los datos requeridos.

Jannesari and Babaei [2018] hacen una evaluación termo-económica utilizando energía solar, para la extracción por solventes del cobre para la mina de cobre Sarcheshmeh en Kerman, Iran. Como parámetros de entrada se incluyeron los efectos climáticos y almacenamiento térmico. El escenario base se conformó de captadores ETC-1 con inclinación de  $20^\circ$ , orientación norte-sur, temperatura de entrada a los captadores de  $60^\circ\text{C}$ , con agua como fluido de transporte de calor, una fracción solar ( $FS$ ) aceptada mínima de  $40\%$  con un tanque de 5 capas de aislamiento. En el estudio se varió cada una de las especificaciones y se evaluó su efecto en el periodo de reembolso, hasta que se cambió la función de costo de ahorro de ciclo de vida. Entre los resultados obtenidos, se encontró que modificando la orientación el  $PB$  aumentó a  $16.3 \text{ años}$  y la  $FS$  bajo a  $40.44\%$ . Y al cambiar el fluido de transferencia de calor por etileno glicol, se obtuvo un  $PB$  de  $6.36 \text{ años}$  con una  $FS$

de 71%. Finalmente, al cambiar la función de costo a *LCS* la *FS* se redujo a 43.12%. También se observó que, cuando no hay una limitación en el terreno disponible, los captadores más baratos (ETC-3) son una opción de mayor interés, mientras que reduciendo la temperatura de entrada a los captadores se gana más calor. También se pudo apreciar que el cambiar agua por etilenglicol se obtiene una *FS* mucho mayor, mientras que la mejor orientación es norte-sur. Es de suma importancia resaltar que, al reducir la *FS*, el periodo de reembolso no varió mucho, por lo que es importante hacer una optimización multi-objetivo con *PB* y *LCS* como un vector para optimizar. Por otra parte, se mostró que el sistema puede abastecer hasta un 78% de la demanda total de calor, lo cual lleva a reducir alrededor de 970 toneladas de emisiones de bióxido de carbono por año.

Tian et al. [2018] realizaron una optimización termo económica de una planta solar híbrida de 9999  $m^2$ , la cual se encuentra compuesta de captadores planos y parabólicos. Como parámetros de optimización se usaron el costo de calor nivelado (*LCOH*, por sus siglas en inglés) y la energía de salida. Para esto, se utilizó TRNSYS-GenOpt para llevar a cabo la optimización multi-variable. Al hacer la variación del volumen entre 2430  $m^3$  y 5000  $m^3$ , el *LCOH* obtuvo casi el mismo valor de 0.420  $\frac{DKK}{kWh}$ , mientras que la energía de salida de la planta incrementa de 422 a 434  $\frac{kWh}{m^2}$ ; sin embargo, cuando el volumen es de 7000  $m^3$  la energía de salida llega a 438  $\frac{kWh}{m^2}$ . A partir de lo cual, se observó que el volumen razonable varía de 5000 a 7000  $m^3$ . Posteriormente fueron comparados cuatro diferentes escenarios, para las razones de áreas de los captadores, fueron comparados; a partir de lo cual, se vieron varias conclusiones de las diferentes funciones objetivo. Por una parte, los captadores parabólicos son más eficientes que los captadores planos para altos niveles de temperaturas. Por otro lado, el precio de los captadores parabólicos es mayor al de los planos. Finalmente se analizaron siete escenarios de demanda de calor, variando de 0 a 60% extra del escenario base. Con el incremento de la demanda se observó que la energía de salida de los captadores parabólicos llegó a incrementar de 418 a 528  $\frac{kWh}{m^2}$  y el *LCOH* neto se redujo de 0.42 a 0.363  $\frac{DKK}{kWh}$ . El *LCOH* puede reducirse hasta un 5-9% con un sistema híbrido. El *LCOH* neto de la planta resultó de 0.42, que es menor que el precio promedio de calor proveniente de calentadores de gas. Por lo que se puede decir, que un método multi-variable de costo de calor nivelado puede ayudar al diseño y la construcción de plantas de calentamiento solar a gran escala.

La optimización de los sistemas de calentamiento solar puede llevar a que éstos sean económicamente viables. La figura de mérito térmica es principalmente la fracción solar, mientras que las económicas es el tiempo de recuperación y el ahorro de ciclo de vida. El ahorro de ciclo de vida puede llegar a variar hasta en un 40% y 20%, debido a variaciones del área de colección y volumen de almacenamiento, respectivamente, también puede variar en un 100% e incluso llegar a números negativos debido al ángulo de inclinación de los captadores. Un método multi-variable de costo de calor nivelado puede ayudar al diseño y la construcción de plantas de calentamiento solar a gran escala. Ya que al utilizar el periodo de recuperación, este tiende a ocasionar que el *SHIP* tenga dimensiones reducidas, pero no toma en cuenta la *FS*. El ahorro de ciclo de vida se ve directamente afectado por la *FS*, sin embargo, puede generar un dimensionamiento elevado. El uso de un análisis variacional puede generar la reducción de combustible fósil sea del 24%, debido a la optimización e incorporación de *SHIPs*.

### **1.2.3.2. Inteligencia artificial en la optimización de sistemas**

Kalogirou [1996] utilizó una red neuronal para la predicción de la razón de concentración local de captadores de cilindro parabólicos, para estimar el factor de intersección del captador y su eficiencia óptica. Para el entrenamiento de la red, utilizó una base de datos experimentales, para los ángulos de incidencia de 15° y 60°. Con dos neuronas de entrada para los valores del ángulo de incidencia (*LCR*), en el tubo y en la parábola, siendo la salida un elemento vector correspondiente a los valores de *LCR*. La ganancia y momentum fueron de 0.1 y 0.5, respectivamente. La capa de entrada lineal fue utilizada como una función de activación, con un peso de 0.3. Los parámetros para el entrenamiento fueron constituidos de 35 patrones, mientras que para la prueba se hizo uso solamente de 3. Una vez entrenada la red, se predijeron los valores de *LCR* para los ángulos de incidencia de 0°, 30° y 45°, lo cual permitió obtener un coeficiente de correlación cercano a 1. A partir del *LCR*, las estimaciones del ángulo de incidencia y eficiencia óptica se hicieron con una desviación máxima de 3.2%. Con lo anterior se observó que el método puede ser utilizado para la estimación de valores *LCR*.

Kalogirou et al. [1999] predijo la energía útil extraída y el aumento de temperatura en el almacenamiento de agua, en un sistema de calentamiento de agua doméstico utilizando una red neuronal, en Atenas, Grecia. La red se entrenó con

33 casos conocidos, obtenidos de las pruebas llevadas a cabo siguiendo el estándar griego ELOT 879, para sistemas disponibles en el mercado griego. El entrenamiento implicó variar las áreas del captador de 1.81 a 4.28  $m^2$ , con datos de salidas experimentales, se consideraron sistemas abiertos y cerrados, y tanques de almacenamiento verticales y horizontales. Después del entrenamiento, se realizó una validación, haciendo uso de tres sistemas desconocidos para la red, obteniendo un porcentaje de error de 7.1% y 9.7% para los sistemas conocidos y los desconocidos, respectivamente. El tiempo de entrenamiento de la red fue de 30 *min* en una máquina Pentium 133 *MHz*. Mientras que, una vez ya entrenado la red, el tiempo para las predicciones data fue entre 1 a 2 *s* en la misma máquina. Con lo anterior se concluyó que, al comparar con los métodos convencionales, la *ANN* tiene mejor velocidad de cálculo, mayor simplicidad y la ventaja de que puede aprender de ejemplos.

Kalogirou [2004] hizo uso de la red neuronal Group Method of Data y un algoritmo genético para la optimización de un sistema de energía solar en Cyprus, Grecia. El ahorro de ciclo de vida (*LCS*) fue usado como parámetro de optimización. Para esto, en primera instancia, se realizaron una serie de simulaciones con el programa TRNSYS, para un sistema de calentamiento solar. El sistema se conformó por una red de captadores, un tanque de almacenamiento, una bomba solar, válvula de alivio y un calentador auxiliar. Para las simulaciones se varió el área captadora y un volumen del tanque de 20  $m^3$ , posteriormente se varió el volumen a 10 y 30  $m^3$ . A partir de los valores obtenidos se entrenó la red neuronal, ya que se hizo una relación de los dos parámetros con el *LCS*, creando una base de datos. Tras la validación se observó que la red neuronal aprendió con una precisión de 0.9968. Subsecuentemente, se realizó la optimización con el algoritmo genético el cual incremento los *LCS* en un 4.9%. Ambos métodos tomaron alrededor de 10 *s* de cómputo, demostrando que ambos métodos pueden ser utilizados para la optimización de sistemas, con la ventaja de que pueden ser utilizados para el diseño y la optimización de otro tipo de sistemas de calentamiento solar.

Kalogirou [2005] optimizó económicamente un sistema de calentamiento de agua solar para uso doméstico, utilizando una red neuronal y un algoritmo genético, para Nicosia, Chipre. Para la optimización, primero se simuló el sistema con el software TRNSYS, seguido se utilizó la red neuronal para obtener la energía auxiliar requerida y luego se optimiza de manera económica mediante con el algoritmo



genético. El sistema, que provee agua caliente a 10 casas, se conforma con captadores de placa plana, un tanque de almacenamiento, una bomba hidráulica solar y un calentador auxiliar. La carga diaria a satisfacer es de 120 lt a  $50^{\circ}C$  para cada casa. Los parámetros a optimizar son el área de colección, la inclinación, la razón de flujo y el volumen de almacenamiento y la figura de mérito económica fue el ahorro de ciclo de vida. La base de datos se construye combinando 48 casos, de los cuales, 42 se utilizan para el entrenamiento de la red y seis para su verificación. La red se entrena con el algoritmo back-propagation y se conforma de 4 neuronas de entrada, tres bloques con 10 neuronas en la capa oculta y una neurona de salida. Los coeficientes de determinación múltiple (valor- $R^2$ ) obtenidos fueron de 0.9999, para la fase de entrenamiento, y de 0.9885 para la fase de verificación. Los resultados óptimos obtenidos del algoritmo genético fueron  $36 m^2$ ,  $39^{\circ}$ ,  $30 \frac{kg}{h-m^2}$ ,  $1.79 m^3$  y £5,918. Los resultados obtenidos con el método tradicional fueron de  $35 m^2$ ,  $40^{\circ}$ ,  $54 \frac{kg}{h-m^2}$ ,  $2.0 m^3$  y £4,981. La diferencia porcentual entre los valores obtenidos para la energía auxiliar entre la red neuronal y TRNSYS fue de 1.8%. Por su parte, el mayor ahorro de ciclo de vida se obtuvo con el algoritmo genético, con una diferencia porcentual de 15.8%, comparado al obtenido por el método tradicional de prueba y error. El tiempo de entrenamiento de la red fue de 5 *min* y el tiempo de cómputo requerido por el algoritmo genético fue de 130 *s*, en una máquina Pentium 400 *MHz*. Se puede observar que el método propuesto muestra mejores resultados que los obtenidos por métodos tradicionales, aparte del corto tiempo necesario para la obtención de resultados. También, dado que el sistema óptimo es dado directamente, no es necesario analizar los datos de salida con el fin de encontrar las características del sistema óptimo. El método se puede utilizar para el diseño y optimización de nuevos y más complicados sistemas.

Kalogirou et al. [2008] hizo uso de seis redes neuronales artificiales para la predicción de los parámetros de desempeño de captadores solares de placa plana. La arquitectura de las redes constó de una capa de entrada (con un bloque), dos ocultas (una con dos bloques y la otra con uno) y una de salida (con un bloque). Por otra parte, la mejora de red y el factor de momento fueron ajustados a 0.1 para todas las redes. La base de datos y el algoritmo de aprendizaje back-propagation fueron utilizados para el entrenamiento de las redes neuronales. Para la validación, los valores obtenidos de las redes del modificador de ángulo de incidencia, la constante de tiempo y la capacidad de calentamiento de cuatro diferentes captadores fueron comparados con los valores experimentales obteniendo una diferencia má-

xima de 0.0057, 4.2 s y  $1.38 \frac{kJ}{K}$ , respectivamente. A partir de lo cual, se probó que las redes neuronales se pueden desempeñar con una precisión satisfactoria para la predicción de desempeño de captadores solares. Lo que puede ayudar a los ingenieros diseñadores a obtener parámetros de desempeño de nuevos diseños de captadores.

Ammar et al. [2013] utilizan redes neuronales artificiales para determinar el punto de operación de poder óptimo de paneles fotovoltaicos y térmicos considerando el comportamiento del modelo. En el trabajo se presenta los efectos del flujo de masa en los sistemas térmicos y fotovoltaicos. El algoritmo de las redes neuronales se utilizó para calcular la tasa de flujo másico óptima para el punto de operación, con las entradas: irradiación solar y temperatura ambiente. La base de datos utilizada se dividió en el 60 % para el entrenamiento, 20 % para la prueba y 20 % para la verificación. La red neuronal obtuvo un error de bias bedio normal (NMBE) de 13.05 %. Los autores concluyeron con base a los resultados que el control del flujo másico para paneles fotovoltaicos y térmicos con redes neuronales es preciso.

Kalogirou et al. [2014] utilizaron redes neuronales para la predicción del desempeño de un sistema de calentamiento solar, considerando la disponibilidad, a corto plazo, de medidas relativamente simples. La arquitectura de la red neuronal se compone de tres neuronas de entrada, tres bloques en la capa oculta con cinco neuronas cada uno, y un bloque de salida con dos neuronas. Para el entrenamiento y la validación de la red neuronal, la radiación, la temperatura ambiente, las temperaturas de entrada y salida del tanque de almacenamiento, el flujo másico del agua y la temperatura en diversos puntos del tanque se monitorearon a lo largo de un año. De las 226 bases de datos diarias que se consideraron válidas, 184 fueron utilizadas para el entrenamiento y 42 para la validación de la red neuronal. El algoritmo de propagación hacia atrás se utilizó para el entrenamiento, se estableció la razón de aprendizaje a un valor constante de 0.1 y con un factor de momentum de 0.3. Los pesos fueron inicializados a un valor de 0.3. La temperatura ambiente promedio diaria, la radiación incidente total diaria y la temperatura inicial del tanque de almacenamiento fueron utilizadas como parámetros de entrada. Las salidas fueron la energía promedio diaria del sistema y la temperatura máxima del agua en el tanque al final del día. El coeficiente de correlación obtenido varió de 0.9546-0.9625 y de 0.9681-0.9560 para la temperatura máxima del agua y de la energía promedio del sistema, respectivamente. Los resultados obtenidos se

compararon con los datos experimentales resultando un error cuadrático de 0.96. El método propuesto presenta ventajas por su simplicidad de implementación, y por el potencial de mejorar la capacidad de la red neuronal, para la predicción del desempeño del sistema solar mediante la continua integración de nuevos datos.

Yaïci and Entchev [2014] predijeron el desempeño de un sistema de energía solar térmico doméstico. La predicción fue realizada mediante una red neuronal de avance de múltiples capas perceptron (multilayer feed-forward perceptron). El algoritmo para el entrenamiento seleccionado fue la propagación regresiva Levenberg-Marquadt. El entrenamiento y la validación emplearon 185 conjuntos de datos diarios experimentales (130 para el entrenamiento y 55 para la validación), obtenidos a lo largo de 2 años en Ottawa, Canadá. La red neuronal fue utilizada para la predicción de varios parámetros de desempeños del sistema, tales como la fracción solar y el calor de entrada. La red neuronal permitió obtener un error relativo promedio de 1.09-1.16 % con una desviación estándar entre 1.04-1.22 %. También, la red neuronal permitió predecir las temperaturas de precalentamiento de agua en el tanque de estratificación y las fracciones solares con errores menores al  $\pm 3\%$  y  $\pm 10\%$ , respectivamente. En la medición fueron empleados dos niveles de ruido con el fin de ver la capacidad de predicción de la red neuronal. Los resultados obtenidos, con los dos niveles de ruido en la medición, fueron del mismo orden de magnitud que el propuesto sin datos inciertos, lo que mostró la extensión del método. La optimización con redes neuronales muestra que las redes neuronales pueden tener una alta exactitud y confiabilidad para la predicción del desempeño de sistemas de energía solar térmica complejos.

Yaïci and Entchev [2016] utilizaron un método de sistema de inferencia neurodifusa adaptativa (*ANFIS*, por sus siglas en inglés) para la predicción del desempeño de los parámetros en un sistema de energía solar, para la aplicación doméstica. En el estudio se utilizó un algoritmo híbrido de aprendizaje, combinando el método de mínimos cuadrados y el método de pendiente de gradiente para leer los parámetros. Los datos utilizados para el aprendizaje fueron obtenidos de manera experimental, compilados en trece casos, diez para el entrenamiento y 3 para la validación y evaluación del modelo de red en *ANFIS*, con un amplio rango de condiciones ambientales. A partir de la validación, se encontró que los parámetros predichos, las temperaturas de estratificación del tanque de precalentamiento, el calor de entrada de los captadores al intercambiador de calor, el calor de entrada

al tanque auxiliar y las fracciones solares, concordaban con los valores experimentales. Las desviaciones estándar de los errores relativos fueron de 0.25-1.87 %, con errores relativos de 0.11-0.57 %. Lo anterior, mostró alta precisión, efectividad y confiabilidad del método ANFIS para la predicción en el desempeño de sistemas térmicos de energía solar. También, los resultados obtenidos por el método *ANFIS* fueron comparados con resultados obtenidos mediante redes neuronales. A pesar de que los resultados obtenidos por el modelo *ANFIS*, estos fueron mejores que los obtenidos con redes neuronales. El método de redes neuronales, en comparación del método *ANFIS*, es más flexible en términos de la implementación del modelo, velocidad de cómputo y facilidad para el usuario.

Boukelia et al. [2016] evaluaron el desempeño de una red neuronal, con tres diferentes variantes (Lenvengerge Marguardt, Gradiente Escalado Conjugado, y el Gradiente Conjugado Pola-Ribiere), para para la optimización económica de un calentador solar de canal parabólico para generación de energía eléctrica, en Bechar, Sudáfrica. Los algoritmos entrenados se probaron y evaluaron utilizando  $R^2$ . El ajuste de Lenvengerge Marguardt obtuvo el mejor resultado con una  $R^2 = 0.09998$  para el costo nivelado de la energía (*LCOE*). El algoritmo se puede utilizar para la optimización de sistemas de calentamiento solar complejos. La variante de Lenvengerge Marguardt se puede emplear para la evaluación de los desempeños económicos de las plantas.

Ghritlahre and Prasad [2018] realizaron un revisión de las aplicaciones de las redes neuronales artificiales para la predicción del desempeño de sistemas de colección solar. A lo largo del trabajo, los autores demuestran que las redes neuronales artificiales son más rápidas y precisas para la solución de problemas complejos no lineales comparados con las técnicas convencionales. En el trabajo se presentan tres tipos de redes neuronales y su uso en el campo de energía solar. El primer tipo es una red neuronal de alimentación hacia delante, el segundo tipo es la función básica radial y el tercer tipo es el sistema de inferencia Neuro-Fuzzy artificial. Una vez presentados los tipos de redes neuronales, los autores mencionan diferentes trabajos que han empleado redes neuronales en el área de energía solar. Y terminan concluyendo que el uso de redes neuronales artificiales es apropiado para la predicción del desempeño de sistemas de calentamiento solar.

El uso de redes neuronales, al comparar con los métodos convencionales, tiene

mejor velocidad de cálculo, mayor simplicidad y la ventaja de una continua mejora, sin mencionar la facilidad de uso para el usuario. También, se observa que las redes neuronales pueden ser utilizadas para el diseño y la optimización de varios tipos de sistemas de calentamiento solar. Es decir, el método de redes neuronales, en comparación a otros métodos, es más flexible en términos de la implementación de modelo, velocidad de cómputo y facilidad para el usuario, sin sacrificar mucho en precisión. La capacidad de predicción de las redes neuronales, a pesar de la introducción de datos erróneos muestra superioridad respecto a otros métodos.

#### **1.2.4. Conclusiones de la revisión bibliográfica**

La aplicación de los sistemas de calentamiento solar en la industria es factible y, con un buen diseño, viable. El dimensionamiento de un sistema de calentamiento solar es la base clave para que dichos sistemas se vuelvan competitivos. Esto se debe que un sistema sobredimensionado implica una fuerte inversión, lo que conlleva a que el sistema no sea viable económicamente hablando. Por su parte, si un sistema es sub-dimensionado, entonces implica que el sistema no aporte el calor requerido. Los sistemas de calentamiento solar, tras una buena optimización en el diseño, pueden abastecer un porcentaje significativo de la energía necesaria para un proceso ( $FS$ ), como se mostró en la revisión bibliográfica en más de un sistema de calentamiento solar. La  $FS$  es el parámetro térmico más usado para la selección de las dimensiones de estos sistemas. Dentro de los factores importantes para el diseño hay que tomar en cuenta la locación de la planta, el perfil de demanda (ya que afecta a la  $FS$  en 40 % en sistemas industriales y en un 10 % en sistemas domésticos) y las condiciones de operación. El área de colección, el volumen de almacenamiento, la configuración del sistema y el punto de incorporación al proceso pueden hacer variar la  $FS$  en más de un 15 %. Por dicha razón, estas variables son consideradas importantes para el dimensionamiento de los  $SHIPs$  y calentadores solares domésticos.

La tecnología de los captadores solares también afecta considerablemente al desempeño del sistema, ya que al cambiar el tipo de captador, la fracción solar llegó a tener diferencias de hasta el 10 %. La pérdida de energía por tuberías en sistemas de calentamiento de dimensiones grandes debe ser tomada en cuenta y reducida en su mayor medida. Para el dimensionamiento de sistemas de calen-

tamiento solar, es necesario de hacer uso de herramientas computacionales. Los softwares de simulación de sistemas de calentamiento solar han demostrado ser una herramienta útil y fehaciente para el estudio y diseño de dichos sistemas. Los softwares más utilizados para la simulación de sistemas de calentamiento solar son TRNSYS, COLSIM, TSOL, TRANSOL y Polysun. Entre estos softwares, TRNSYS y COLSIM se destacan por su libertad en la elección de las configuraciones de los sistemas.

La optimización de los sistemas de calentamiento solar puede llevar a que estos sean económicamente viables. Existen diversos métodos de optimización, tales como PINCH, multi-objetivo y el de redes neuronales. La figura de mérito térmica es principalmente la fracción solar, mientras que las económicas es el tiempo de retorno y el ahorro de ciclo de vida. El ahorro de ciclo de vida puede llegar a variar hasta en un 40% y 20%, debido al área de colección y volumen de almacenamiento, respectivamente, también puede variar en un 100% e incluso llegar a números negativos debido al ángulo de inclinación de los captadores. El uso de un análisis variacional puede generar la reducción de combustible fósil fue del 24%, debido a la optimización e incorporación de *SHIPs*. Al utilizar el periodo de recuperación, como figura de mérito económica, este tiende a ocasionar que el *SHIP* tenga dimensiones reducidas, pero no toma en cuenta la *FS*. El ahorro de ciclo de vida se ve directamente afectado por la *FS*, sin embargo puede generar un dimensionamiento elevado. Un método multi-variable de costo de calor nivelado puede ayudar al diseño y la construcción de plantas de calentamiento solar a mayor escala. El uso de las redes neuronales, comparado con los métodos convencionales, tiene mejor velocidad de cálculo, mayor simplicidad, la ventaja de una continua mejora y facilidad de uso para el usuario. Además pueden ser utilizadas para el diseño y la optimización de varios tipos de sistemas de calentamiento solar. El método de redes neuronales, en comparación a otros métodos, es el más flexible en términos de la implementación de modelo, velocidad de cómputo y facilidad para el usuario, sin sacrificar mucho en precisión. La capacidad de predicción de las redes neuronales, a pesar de la introducción de datos erróneos, muestra superioridad respecto a otros métodos. Esto nos permite suponer que el uso de redes neuronales facilita la optimización termo-económica de un sistema de calentamiento solar.

## **1.3. Objetivos y Alcances**

En esta sección se presenta el objetivo general de la tesis presentada en este trabajo, así como los objetivos específicos y los alcances.

### **1.3.1. Objetivo general**

Desarrollar una estrategia para optimizar sistemas de calentamiento solar, basada en inteligencia artificial, que permitan incrementar el desempeño termo económico de los sistemas, en términos de fracción solar, energía útil y ahorros solares.

### **1.3.2. Objetivos específicos**

- \* Seleccionar los parámetros a optimizar y los parámetros de entrada.
- \* Generar una base de datos para el entrenamiento de la red neuronal.
- \* Construir la red neuronal artificial.
- \* Evaluar el desempeño de la red neuronal.

### **1.3.3. Alcances**

- \* Definir un perfil de demanda para una aplicación con potencial de ahorro y uso eficiente de la energía.
- \* Construir una plataforma basada en redes neuronales para la optimización de sistemas de calentamiento solar con tecnología de captadores solares planos.
- \* Realizar una optimización de un sistema con al menos cuatro parámetros, para al menos un caso específico.

## **1.4. Escritura de la tesis**

En el Capítulo 1 se presentaron las generalidades y la revisión bibliográfica que justifica, con base a sus conclusiones, este trabajo de tesis; también se presentaron los objetivos y alcances. En el Capítulo 2 se presentan los fundamentos teóricos, los casos de estudio seleccionados y la descripción de los modelos térmicos, económicos y de optimización con redes neuronales que se van a utilizar, así como la creación de la base de datos que se utilizara para el entrenamiento de la red. En el

Capítulo 3 se muestra la metodología general, para la construcción y verificación de las plataformas de simulación utilizadas para la generación de la base de datos. En el Capítulo 4 se presenta y analiza la base de datos generada, se construye las arquitecturas de las redes neuronales artificiales y se define el método de entrenamiento y las ecuaciones para el mismo. En el Capítulo 5 se realiza la optimización de las redes neuronales propuestas, su verificación y se evalúa su desempeño. En el Capítulo 6 se presentan las conclusiones del trabajo y las recomendaciones para trabajos futuros.



En éste capítulo se introducen los fundamentos teóricos utilizados, el planteamiento de los casos de estudio y el método empleado.

### 2.1. Fundamentos Teóricos

Los fundamentos teóricos presentados en este trabajo se dividen en dos secciones: redes neuronales artificiales y calentamiento solar.

#### 2.1.1. Redes Neuronales Artificiales

La Figura 2.1 presenta un esquema del funcionamiento de una neurona artificial. Las entradas,  $z_j$  (ecuación 2.1), alimentan a cada neurona de la primera capa, para utilizarse en la función de activación,  $a_j$  (ecuación 2.2), junto con los pesos designados a cada entrada. La función de activación  $g$  permite determinar una señal de activación, que se recibe en todas las neuronas de la siguiente capa y se introduce, junto con los pesos de cada neurona de la capa anterior, a la función de activación, para obtener las nuevas señales de activación, y así sucesivamente hasta llegar a las neuronas de salida.




Figura 2.1: Esquema de una neurona artificial [Russell and Norvig, 2016].

La función de entrada y señal de activación se representan con las ecuaciones

2.1 y 2.2 respectivamente

$$z_i = \sum_{j=0}^n W_{ij}a_j + b_i \quad (2.1)$$

$$a_i = g(z_i) = g\left(\sum_{j=0}^n W_{ij}a_j + b_i\right) \quad (2.2)$$

donde  $a_i$  es la función de activación,  $z_i$  es la función de entrada,  $W_{ij}$  es el parámetro de peso,  $a_j$  es la función de activación de entrada (de la capa anterior) y  $b_i$  es el vector bías, otro parámetro de peso utilizado para hacer el cálculo en las redes neuronales.

Las redes son ordenadas en capas, de tal manera que cada unidad recibe entradas sólo de los nodos de la capa anterior inmediata. Este tipo de red usualmente está conformado de una capa de entrada, una o más capas ocultas y una capa de salida, como se muestra en la Figura 2.2.




Figura 2.2: Esquema de una red neuronal artificial [Russell and Norvig, 2016].

Para que una red neuronal funcione adecuadamente es necesario entrenarla. Existen varios métodos de entrenamiento de las redes neuronales. El método de entrenamiento de propagación hacia atrás es el método de entrenamiento de redes neuronales más usado. Este método consiste en calcular de manera iterativa los valores óptimos de las matrices de peso y los vectores bías utilizados en la red neuronal. Con el fin de saber si la red neuronal fue entrenada adecuadamente se

hace uso de la función de error,  $J$ , que se representa con la siguiente ecuación [Andrew et al., 2019c, Gomila-Salas, 2020, Andrew, 2019, Russell and Norvig, 2016]:

$$J = \frac{1}{2m} \sum_{i=1}^m (A_i^{[out]} - Y_i)^2 \quad (2.3)$$

donde  $m$  es el número de ejemplos utilizados para el entrenamiento de la red.  $A_i^{[out]}$  es la función de salida de la red neuronal. Y  $Y_i$  es el valor de salida de la base de datos ya conocido.

## 2.1.2. Calentamiento solar

Un sistema de calentamiento solar es una configuración de diversos elementos, el cual está diseñado para captar energía solar la cual transfieren a un fluido de trabajo en forma de calor. A continuación, se describen algunos de los elementos de los sistemas de calentamiento solar.

### 2.1.2.1. Evaluación del recurso solar

El recurso solar se puede definir como la cantidad de irradiación solar que llega a un determinado lugar sobre una superficie plana. La irradiación es radiación por metro cuadrado. La radiación es la energía que se transfiere por ondas electromagnéticas emitidas por un cuerpo. La radiación solar varía su intensidad según su ángulo de entrada a la atmósfera, hora del día, estación del año y la latitud del lugar [de Energía INDAP-Nivel Central, 2018]. La radiación solar se puede dividir entre radiación directa y radiación difusa, la suma de estas dos radiaciones es la radiación global. La radiación solar directa es la radiación cuya onda electromagnética no ha sido alterada por las partículas en atmósfera. Mientras que la radiación solar difusa es la radiación que ha sido dispersada por la atmósfera. terrestre [Ramírez-Martínez, 2019]. El instrumento utilizado para medir la radiación incidente global sobre una superficie es el piramómetro.

En la actualidad existen varias bases de datos donde se registran los datos meteorológicos medidos a lo largo de los años. En éste trabajo se utilizó la base de datos de METEONORM para obtener los datos meteorológicos de los lugares de estudio, como se presenta en el anexo A.

### 2.1.2.2. Captador solar

De acuerdo a la definición de Duffie et al. [2013] “un captador solar es un tipo de intercambiador de calor que transforma energía solar radiante en energía térmica”. El captador solar absorbe la energía radiante proveniente del sol y la transfiere en forma de calor a un fluido. Existen diferentes tipos de captadores solares, sin embargo este trabajo se concentra en los captadores de placa plana. Éstos pueden usar tanto radiación directa como difusa, no tienen que seguir el movimiento del sol y requieren poco mantenimiento. Los captadores de placa plana pueden ser diseñados para procesos de temperatura baja.




Figura 2.3: Esquema de un captador solar [Cruz-Pinuelas, 2019].

El análisis del comportamiento térmico del captador se hace a partir de la Primera Ley de la Termodinámica (ecuación 2.4), como se muestra en la Figura 2.3 [Cruz-Pinuelas, 2019].

$$Q_{i1} = Q_{l1} + Q_{o1} \quad (2.4)$$

donde  $Q_{i1}$  es la radiación de entrada,  $Q_{l1}$  es la energía perdida al medio ambiente y  $Q_{o1}$  es la energía de salida del captador.

### 2.1.2.3. Termotanque

Un termotanque es un recipiente aislado térmicamente en el que se almacena el fluido calentado por los captadores solares para su posterior uso. El volumen del tanque de almacenamiento o termotanque depende de la demanda diaria del proceso y la temperatura requerida. Los termotanques se clasifican en presurizados y no presurizados [Ramírez-Martínez, 2019]. Los tanques presurizados al-

macenan fluidos a temperaturas mayores de  $90^{\circ}C$ , y los no presurizados manejan temperaturas menores a los  $90^{\circ}C$ . La Figura 2.4 presenta el modelo físico de un tanque estratificado. A partir de la primera ley de la termodinámica, el modelo matemático se representa con la ecuación 2.5 [Cruz-Pinuelas, 2019].

$$Q_a = Q_{i3} - Q_{l3} - Q_{o3} \quad (2.5)$$

donde  $Q_a$  es la energía almacenada,  $Q_{i3}$  es la energía de entrada,  $Q_{l3}$  es la energía perdida al ambiente,  $Q_{o3}$  es la energía de salida.

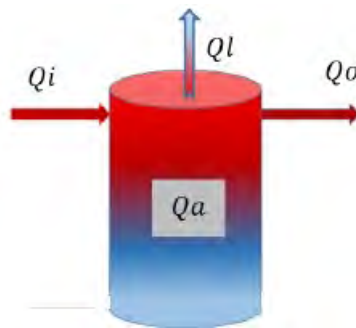


Figura 2.4: Esquema de un termotanque [Cruz-Pinuelas, 2019].

#### 2.1.2.4. Intercambiador de calor

Un intercambiador de calor es el dispositivo utilizado para transferir energía térmica de un fluido a otro sin mezclarlos. Existen diversos tipos de intercambiadores de calor, una de las clasificaciones es por el sentido de los flujos: flujo paralelo, cruzado o contra-flujo [Çengel and Boles, 2015]. Los intercambiadores utilizados en este trabajo son a contra-flujo cuyo esquema se presenta en la Figura 2.5 [Cruz-Pinuelas, 2019].




Figura 2.5: Esquema de un intercambiador de calor [Cruz-Pinuelas, 2019].

Las ecuaciones 2.6 y 2.7 representan el comportamiento de los intercambiadores de calor:

$$Q_{i_2} = Q_{o_2} + Q_{l_2} \quad (2.6)$$

$$Q_{i_4} = Q_{o_4} + Q_{l_4} \quad (2.7)$$

donde  $Q_{i_2}$  y  $Q_{i_4}$  son la energía de entrada a los intercambiadores,  $Q_{o_2}$  y  $Q_{o_4}$  son la energía de salida de los intercambiadores y  $Q_{l_2}$  y  $Q_{l_4}$  son las energías perdidas al ambiente.

### 2.1.2.5. Calentador auxiliar:

El calentador auxiliar es el dispositivo utilizado para calentar el fluido a la temperatura requerida, en caso de que no llegue a la temperatura deseada mediante energía solar [Arcos-Adame, 2018].

El balance termodinámico del calentador auxiliar se representa con la ecuación 2.8 [Cruz-Pinuelas, 2019].

$$Q_{i_5} = Q_g + Q_{o_5} \quad (2.8)$$

donde  $Q_{i_5}$  es la energía de entrada al calentador,  $Q_{o_5}$  es la energía de salida del calentador y  $Q_g$  es las energías generada.



Figura 2.6: Esquema de un calentador auxiliar [Cruz-Pinuelas, 2019].

### 2.1.2.6. Razón de uso

La razón de uso ( $R_u$ ) se define como la cantidad de agua que se calentará por día por unidad de área de colección, es decir la demanda sobre el área [Ramírez-Martínez, 2019]. Sus unidades son  $\frac{l}{m^2-día}$ .

$$R_u = \frac{D}{A_c} \quad (2.9)$$

donde  $A_c$  es el área de colección y  $D$  es la demanda de agua diaria.

### 2.1.2.7. Razón volumétrica

La razón volumétrica ( $R_v$ ) se define el volumen de almacenamiento térmico por cada unidad de área de colección, es decir la demanda sobre el área [Ramírez-Martínez, 2019]. Sus unidades son  $\frac{l}{m^2}$ .

$$R_v = \frac{V}{A_c} \quad (2.10)$$

donde  $A_c$  es el área de colección y  $V$  es el volumen de almacenamiento.

## 2.2. Caso de estudio

Con base a la revisión bibliográfica se determinó que los parámetros más importantes para el dimensionamiento óptimo de los SHIP, son el lugar de estudio, la configuración del sistema y la demanda térmica del proceso. También es necesario determinar los parámetros económicos, tales como el periodo de la inversión, precio del combustible, tasa de inflación, tasa de descuento de mercado, entre otros.

### 2.2.1. Localización de la planta solar

En este trabajo se consideraron tres diferentes ciudades para la localización de la planta solar. Las ciudades se seleccionaron con diferente clima y buscando un considerable desarrollo industrial, para esto se consideran los diferentes climas de México y el producto interno bruto,  $PIB$ , de actividades secundarias.

En la Figura 2.7 se muestran los diferentes climas prevalentes en el país; en orden descendente, son el cálido seco, templado y cálido semi-húmedo. El desarrollo industrial, en términos del PIB, se muestra en la Figura 2.8. En el 2017, la Entidades con mayor  $PIB$  son Nuevo León, Estado de México, Coahuila, Campeche, Guanajuato, Ciudad de México, Sonora, Chihuahua y Baja California. En Nuevo León, Coahuila y Sonora el clima predominante es cálido. Para el clima templado, las entidades con mayor PIB son el estado de México y la Ciudad de México. El clima cálido semi-húmedo es predominante en Campeche y Veracruz. Con lo anterior,

el mayor potencial de aplicación de calentamiento solar se observa en los climas cálido seco, templado y cálido sumi-húmedo [González-Osorio and Beele, 2016].



Figura 2.7: Distribución municipal de zonas climáticas [González-Osorio and Beele, 2016].

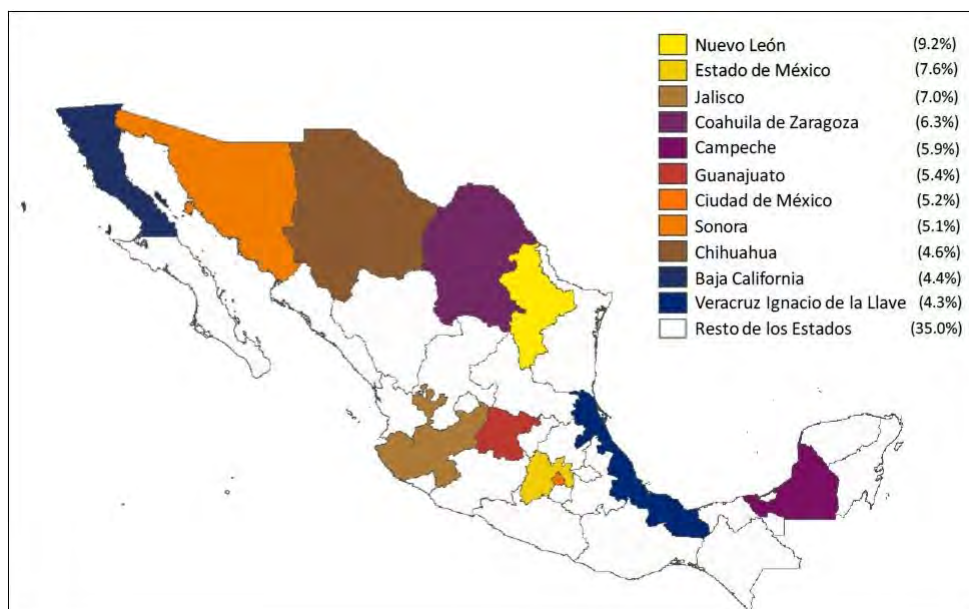


Figura 2.8: Producto Interno Bruto de las actividades secundarias en el 2017 [INEGI, 2018].

Tomando en cuenta el *PIB* en las actividades secundarias y las unidades eco-



nómicas se seleccionaron tres ciudades representativas de los estados previamente mencionados. Para el clima cálido seco se seleccionó a Monterrey, la cual cuenta con una irradiación global horizontal de  $5.22 \frac{kWh}{m^2-día}$  y 23,158 unidades económicas. Para el clima templado se seleccionó a Ecatepec de Morelos con una irradiación global horizontal de  $6.118 \frac{kWh}{m^2-día}$  y 31,341 unidades económicas. Y para el clima cálido semi-húmedo se seleccionó a la ciudad de Campeche que tiene una irradiación global horizontal de  $5.521 \frac{kWh}{m^2-día}$  y 5,442 unidades económicas [INEGI, 2018].

### 2.2.2. Demanda térmica

La industria de los alimentos, en particular de bebidas (tanto lecheras como cerveceras), textil, maquinaria y la industria del papel son los subsectores con mayor potencial para la implementación de sistemas de calentamiento solar. La Tabla 2.1 muestra los sectores industriales con sus respectivos procesos que tienen mayor potencial para usos térmicos solares con captadores de placa plana. Como se puede observar en la Tabla 2.1, estos sectores de la industria requieren de temperaturas, en su mayoría, entre los 30 y 90 °C, por lo que este rango de temperaturas son el enfoque de interés en este trabajo [Ortega, 2018].

Tabla 2.1: Rangos de temperatura de distintas ramas industriales [Ortega, 2018].

Ramo Industrial	Operación	Temperatura del proceso (°C)
Alimentos y bebidas	Secado	30-90
	Lavado	60-90
	Pasteurización	60-80
	Tratamiento térmico	40-60
Papel	Cocinado y secado	60-80
	Pre calentamiento de agua	60-90
Textil	Blanqueamiento	60-100
	Tintura	70-90
	Lavado	40-80
Ladrillos y bloques	Curado	60-140
Tratamiento de superficies metálicas	Tratamiento, Electro-pintado	30-80
Sub-productos de Flúor	Esterilización	60-90
Todas las ramas	Pre calentamiento de agua	30-100
	Calentamiento de espacios	30-80

Para la selección de la carga térmica a seleccionar, fueron tomados en cuenta los requerimientos térmicos para diferentes procesos industriales. Las Figura 2.9

y la Figura 2.10, muestran las temperaturas y las cargas térmicas requeridas para diferentes procesos industriales, respectivamente. Las cargas térmicas, en su mayoría van de 10 a 200  $kWh$  por día, sin embargo para los procesos que requieren temperaturas de 30 a 90°C, por lo que la carga térmica seleccionada para este trabajo va de 10 a 100  $kWh$ .




Figura 2.9: Temperatura en procesos industriales [Muster et al., 2015].

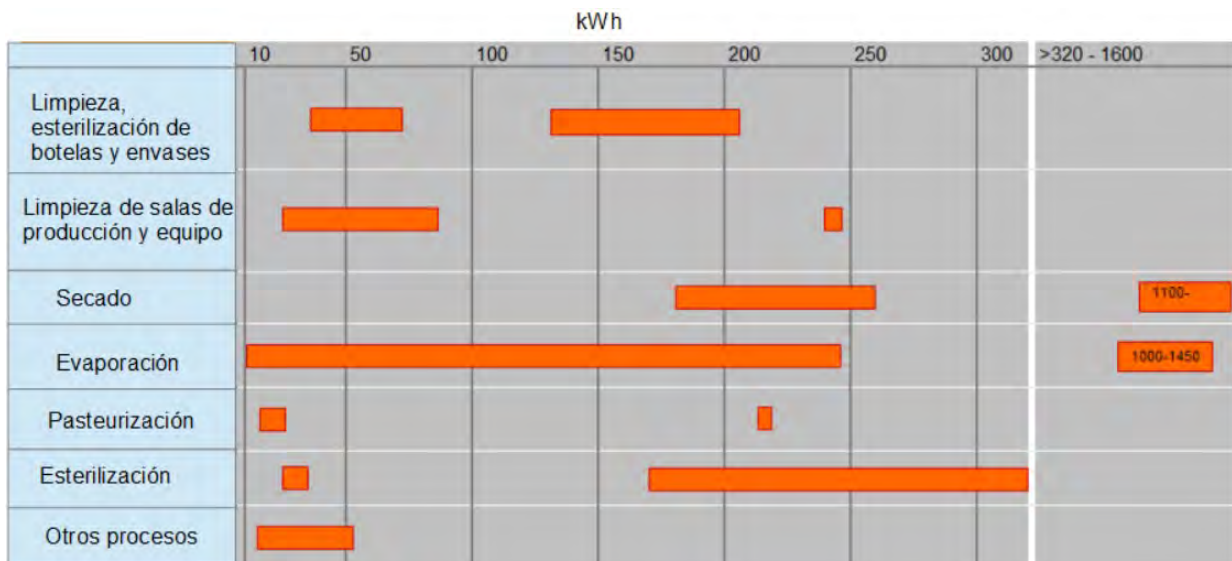


Figura 2.10: Demanda térmica en procesos industriales [Muster et al., 2015].

La selección los perfiles de carga se llevó a cabo tomando en cuenta la forma

de operación de plantas grandes y medianas. El 50% de las plantas tienen una operación de 8-15 h al día; la mayoría de las plantas grandes operan los 365 días del año, mientras que las medianas operan de 16 a 28 días al mes [Payback, 2018]. Por lo que se seleccionó un perfil de carga diario de 8 h continuo y de 5.5 h intermitente debido al caso base presentado por [Helmke et al., 2015]. También se seleccionó un perfil de carga continuo diario para todo el año y un perfil semanal de 5 días a la semana.

### 2.2.3. Configuración de sistema de calentamiento solar propuesto

El sistema de calentamiento solar propuesto, mostrado en la Figura 2.11, incorpora un arreglo de captadores de placa plana, dos intercambiadores de calor, almacenamiento térmico en un tanque estratificado, calentamiento auxiliar y cuatro bombas hidráulicas. La configuración se puede dividir en tres circuitos: el circuito de captación solar, el de almacenamiento térmico y el de integración al proceso.

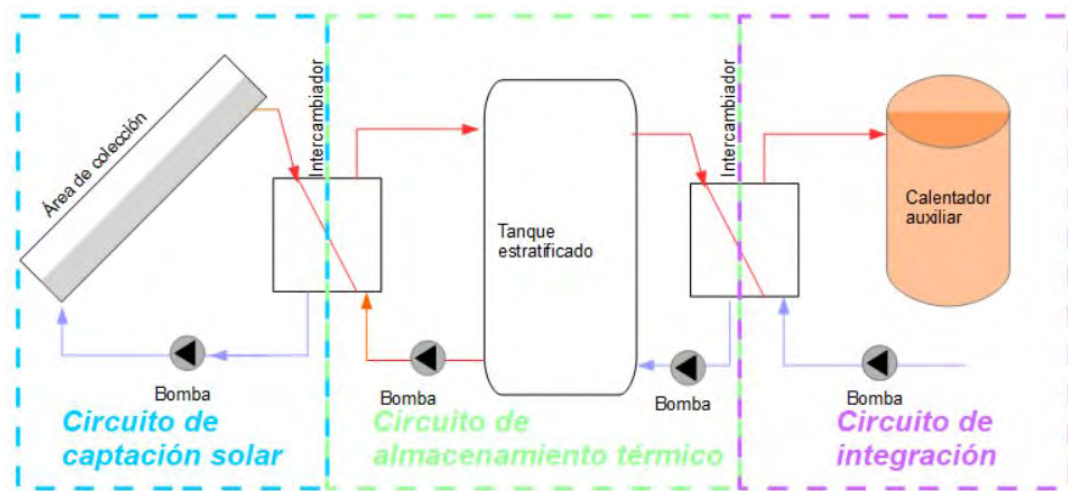


Figura 2.11: Modelo físico del sistema de referencia para calentamiento solar de agua.

El circuito de captación solar se compone de los captadores solares, una bomba hidráulica y un intercambiador de calor, como se presenta en la Figura 2.12. En el circuito de captación, los captadores captan la energía solar y la transfieren a un fluido 1, que es una mezcla agua-glicol, el cual es bombeado a un intercambiador de calor donde la energía térmica se transfiere al fluido 2, agua. El balance térmico de este circuito se obtiene de las ecuaciones 2.4- 2.6 como se presenta en la ecuación 2.11.

$$Q_{i1} = Q_{l1} + Q_{o2} + Q_{l2} \quad (2.11)$$

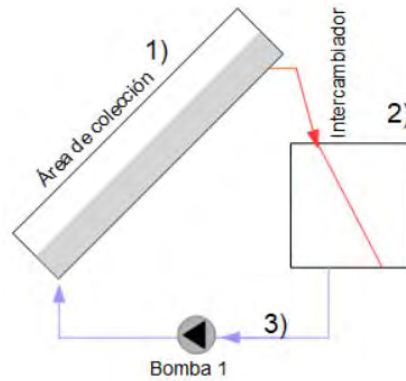


Figura 2.12: Modelo físico del circuito de captación.

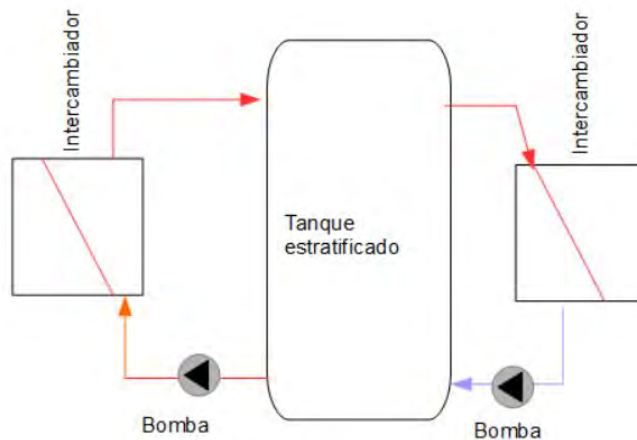


Figura 2.13: Modelo físico del circuito de almacenamiento.

El circuito de almacenamiento térmico se compone dos bombas hidráulicas, un tanque estratificado y dos intercambiadores de calor, uno glicol-agua y uno agua-agua. El fluido de trabajo 1, transfiere la energía térmica a un fluido 2 que se bombea al tanque de almacenamiento de donde se saca y se bombea a un segundo intercambiador de calor. El balance térmico de este circuito se obtiene de las ecuaciones 2.6, 2.5 y 2.7, como se presenta en la ecuación 2.12.

$$Q_{i2} = Q_{l2} + Q_a + Q_{l3} + Q_{o4} + Q_{l4} \quad (2.12)$$

El circuito de integración se encuentra conformado por una bomba, el calentador auxiliar, y un intercambiador de calor, como lo muestra la Figura 2.14. En este circuito, la energía térmica se transfiere a un fluido 3 y de ahí el fluido es bombeado al calentador auxiliar de donde se bombea para integrarse al proceso. El balance térmico de este circuito se obtiene de las ecuaciones 2.7 y 2.8, como se presenta en la ecuación 2.13.

$$Q_{i4} = Q_{l4} + Q_g + Q_{o5} \quad (2.13)$$




Figura 2.14: Modelo físico del circuito de integración.

### 2.3. Método de optimización de SHIPs con inteligencia artificial

El desarrollo del trabajo comienza con la especificación de las figuras de mérito y las variables a optimizar de los *SHIPs*, es decir las variables de entrada y de salida para la optimización, con base en la revisión bibliográfica. Una vez establecidas las variables a utilizar es necesario determinar los casos de estudio, en donde se establecen el tipo de sistemas a estudiar, sus características y los intervalos de las variables de entrada. También es necesario realizar un análisis y selección del tipo de inteligencia artificial a utilizar para la optimización de los *SHIPs*. Tras la selección de los casos de estudio e inteligencia artificial, es preciso realizar una selección de los softwares empleados para generar la base de datos y construir la arquitectura de inteligencia artificial, esta selección se realiza a partir de un análisis de los diferentes softwares utilizados comercialmente. A continuación, se prosigue con la selección del modelo matemático de la inteligencia artificial

a seleccionar. En esta parte se especificarán las herramientas y metodología de inteligencia artificial seleccionada. El siguiente paso a seguir es la definición del método de entrenamiento de inteligencia artificial, tomando en cuenta si el método seleccionado converge de manera efectiva. De manera paralela es necesario llevar a cabo la generación y el análisis de la base de datos utilizada para el entrenamiento. Una vez realizada la base de datos se procede con la construcción y entrenamiento de inteligencia artificial. Como paso siguiente se procede a la optimización de la herramienta de inteligencia artificial, en este paso se evalúa y se optimiza el desempeño de la inteligencia artificial al variar el número de datos para el entrenamiento y los parámetros de la arquitectura. Ya que se optimizó es necesario realizar una verificación de la herramienta de optimización con inteligencia artificial. Adicionalmente, con el fin de observar todas las ventajas y desventajas de la herramienta desarrollada, se procede con la comparación de la optimización de los SHIPs por método convencional con inteligencia artificial. Como paso final se determinan las conclusiones y recomendaciones para trabajos futuros.



Figura 2.15: Esquema del método planteado.

### 2.3.1. Selección de la inteligencia artificial

El campo de la inteligencia artificial se puede dividir en tres ramas: lógica difusa, redes neuronales artificiales y algoritmos genéticos:

- En la lógica difusa, la computadora analiza conceptos vagos (como caliente o húmedo). También puede definir o controlar un sistema con base a sentido común; sin embargo, al no manejar cantidades exactas se considera que no es la rama adecuada para este trabajo.
- Los algoritmos genéticos se basan en la evolución natural, y se utilizan principalmente para la optimización en general. Estos algoritmos tienen tres operaciones básicas: selección, cruzamiento y mutación.
- Las redes neuronales artificiales son una serie de regresiones sobre múltiples variables, las cuales se realizan de manera paralela y se encuentran interconectadas, lo cual permite que la red neuronal realice predicciones más precisas que una regresión normal.

Dado que los algoritmos genéticos requieren una base de datos considerablemente grande para hacer cada optimización, se consideraron las redes neuronales como la mejor opción, ya que una vez entrenada la red, ésta puede hacer las predicciones de las optimizaciones sin necesidad de proporcionar una base de datos cada vez que se quiera realizar una optimización [Russell and Norvig, 2016].

### 2.3.2. Figuras de mérito

Las figuras de mérito y las variables a optimizar fueron seleccionadas con base en la revisión bibliográfica. Las variables a optimizar son el área de colección y el volumen de almacenamiento. Las figuras de mérito se pueden dividir en térmicas y económicas, donde las térmicas son la fracción solar,  $FS$ , y la energía útil,  $Q_u$ , mientras que las económicas son los ahorros solares,  $LCS$  y el periodo de retorno,  $PB$ .

#### 2.3.2.1. Parámetros térmicos

Las figuras de mérito térmicas son la  $Q_u$  y la  $FS$ . La  $Q_u$  se refiere a la cantidad de energía que el sistema de calentamiento solar puede proveer al proceso, ecuación (2.14). La  $FS$  se puede definir como la razón de la contribución del sistema solar (la energía útil) a la demanda energética entre la demanda energética, ecuación (2.15).

$$Q_u = m_{proceso} C_p (T_{out} - T_{in}) \quad (2.14)$$

$$FS = \frac{Q_u}{Q_{req}} \quad (2.15)$$

Los valores de la  $FS$  van de 0 a 1.0 y estos dependen de diversos factores tales como las dimensiones del  $SHIP$ , su locación (debido a los datos meteorológicos) y los requerimientos de la industria (temperatura requerida, la demanda, el perfil de carga, entre otros).

### 2.3.2.2. Parámetros económicos

Las figuras de mérito económicas son  $LCS$  y  $PB$ . Los ahorros solares o  $LCS$  es la diferencia entre el valor neto de los gastos generados por un sistema de calentamiento convencional y el valor neto de los gastos generados por un  $SHIP$  durante su vida útil, el método se encuentra a mayor detalle en Duffie et al. [2013]. El  $PB$  es el tiempo en el que los ahorros generados por el  $SHIP$  equivalen a la inversión inicial y se obtiene con la ecuación 2.16.

$$PB = \frac{\ln \left[ \frac{C_s i_F}{FLC_{F1}} + 1 \right]}{\ln \left( \frac{1+i_F}{1+d} \right)} \quad (2.16)$$

donde  $C_s$  es la inversión inicial,  $i_F$  es la tasa de inflación,  $FLC_{F1}$  es el ahorro solar del primer año y  $d$  es la tasa de descuento.

Tabla 2.2: Entradas económicas [Ramírez-Martínez, 2019].

Parámetro económico/elemento	Unidad	Valor
Periodo de inversión.	años	20
Precio del combustible.	\$/kWh	1.4
Tasa de inflación.	%	5.83
Tasa de descuento del mercado.	%	7.25
Tasa de impuesto sobre la renta.	%	35
Impuesto sobre la propiedad.	%	2
Seguro, mantenimiento y costos parasitarios.	%	1.8
Tasa de interés hipotecario	%	10.4
Valor de reventa del sistema	%	33
Área de colección	\$/m2	3160
Tanque de almacenamiento	\$/m3	1380.16
Bombas hidráulicas	\$/kW	3275.88
Calentador auxiliar	\$	334097.5
Sistema de control	\$	6912.5
Equipamiento adicional	\$	10,000



Es de interés establecer las entradas económicas necesarias para obtener estas dos figuras. En el caso de *LCS* es necesario conocer la *FS*, el costo inicial del sistema y las tasas de interés del mercado de los lugares de estudio, en este caso México. En la Tabla 2.2 se muestran las entradas económicas que se utilizan en este trabajo.

### **2.3.2.3. Parámetros de desempeño de la red neuronal artificial**

En esta sección se determinan los parámetros de evaluación el desempeño de las redes neuronales al comparar este método con el método variacional. La evaluación se realiza tomando en cuenta la velocidad de cómputo, la versatilidad y la facilidad para llevar a cabo la optimización. La velocidad de optimización se puede expresar en términos del tiempo de cómputo. La versatilidad, se considera a partir del número de entradas y la facilidad de uso que se evalúa como el número de conocimientos requeridos. El tiempo de cómputo se determina a partir un cronómetro con resolución de segundo. El cronómetro se inicia a partir del momento en que se terminan a introducir las entradas respectivas de cada método y se detiene cuando se obtienen las variables de salida. El número de entradas a la cantidad de entradas necesarias para llevar a cabo cada método. El número de conocimientos requeridos se evalúa con la cantidad de conocimientos básicos necesarios para poder realizar la optimización con los dos métodos.

### **2.3.3. Generación de la base de datos**

La Figura 2.16 muestra la metodología establecida para la generación de la base de datos. La base de datos fue generada con base en trabajos previos y la optimización por medio de la simulación de los diferentes sistemas. Los datos obtenidos de la revisión bibliográfica se utilizan para la evaluación del desempeño de la red y su verificación, complementados con los datos obtenidos de las simulaciones. La optimización termo-económica de los sistemas se divide en dos rubros principalmente, en la térmica y en la económica.

La optimización térmica comienza seleccionando el caso de estudio, donde se determina el lugar, la demanda térmica y la configuración del sistema. Una vez determinado el caso de estudio se procede a la construcción de la plataforma térmica y su verificación. La verificación de la plataforma se realiza a partir de la comparación de los resultados obtenidos con los resultados reportados por [Helmke et al., 2015]. El siguiente paso a realizar es la obtención de las fracciones solares

( $FS$ ) y energías útiles ( $Q_u$ ) para las diversas  $A_c$  y  $V$ , en función de  $R_u$  y  $R_v$ , respectivamente. Los valores de las  $FS$  y  $Q_u$  se grafican, a partir de lo cual se genera la tabla de diseño térmico, cabe mencionar, que estos datos también son utilizados como entrada en la simulación económica.

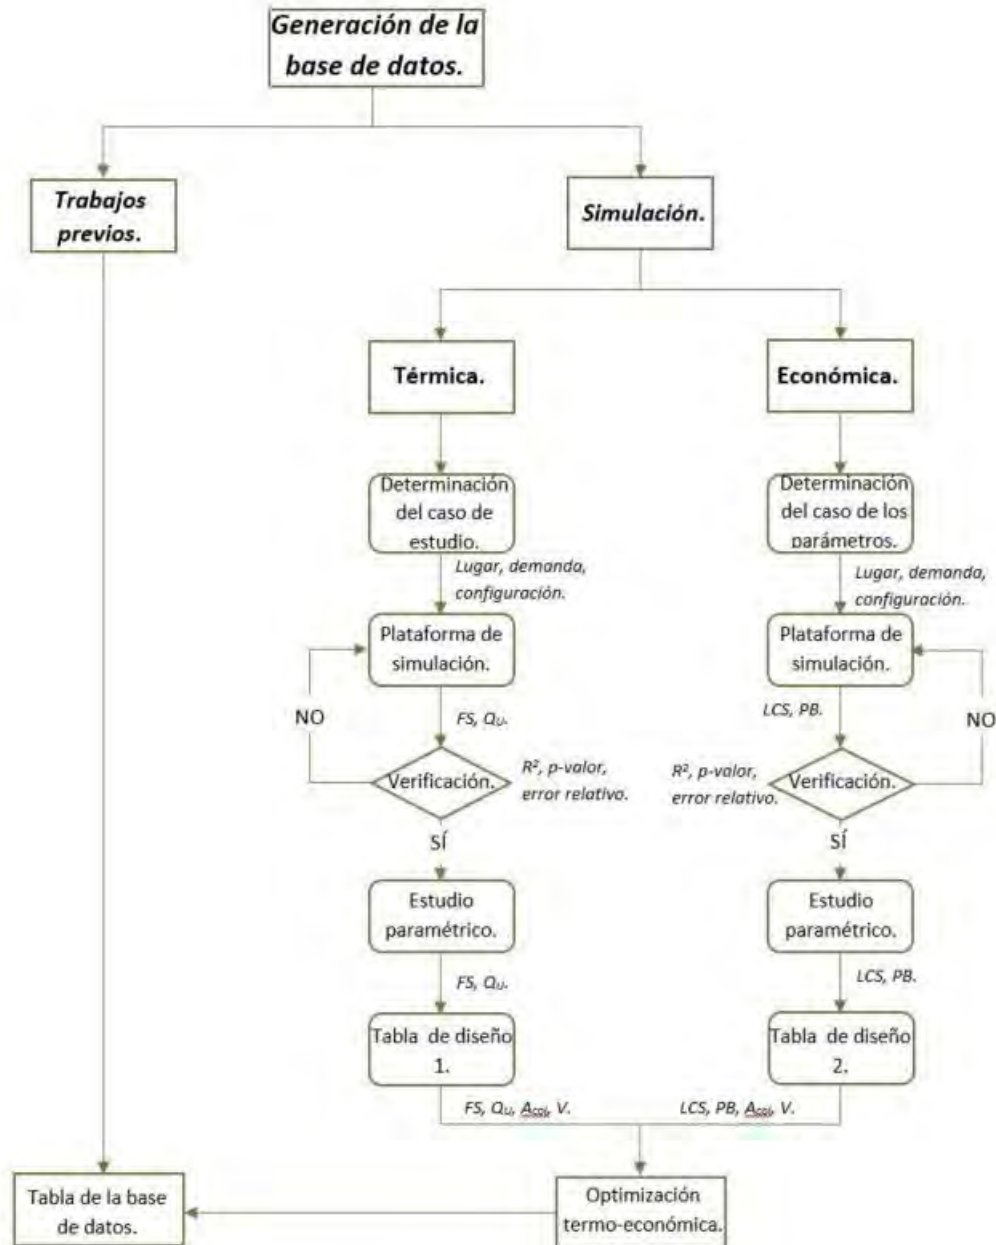


Figura 2.16: Metodología de la generación de la base de datos.

En la simulación económica en primer lugar se determinan los parámetros económicos tales como el financiamiento por el banco, los años de estudio, la inflación esperada del combustible, el impuesto a la propiedad, la inflación esperada de generación, la tasa de impuesto de ingreso efectivo, la tasa de descuento del mercado, así como, el costo por mantenimiento, dependiente del área, del volumen, de las bombas hidráulicas, del calentador auxiliar, del intercambiador de calor, del sistema de control, equipamiento auxiliar, de la electricidad y del combustible. Posteriormente, la plataforma económica es construida y verificada con base en lo reportado por [Duffie et al., 2013]. Los ahorros solares ( $LCS$ ) y el periodo de recuperación ( $PB$ ) son calculados mediante el método de ahorro de ciclo de vida, utilizando los parámetros económicos y los resultados obtenidos de la simulación energética. Con base a lo calculado, se genera la tabla de diseño económica. Las dos tablas de diseño, la térmica y la económica, son utilizadas para la optimización termo-económica, a partir de lo cual se obtienen los valores del área y volumen óptimos en función de la razón de uso y la razón volumétrica.

Los valores de  $R_u$ ,  $R_v$ ,  $FS$ ,  $Q_u$ ,  $LCS$  y  $PB$  se catalogan como las salidas y se colocan en una hoja de cálculo junto con las entradas del caso de estudio. Las entradas para el algoritmo son el lugar, la configuración del  $SHIP$ , la temperatura del proceso, el flujo másico, las horas de trabajo al día y a la semana, la tasa de interés, la reventa, el impuesto a la propiedad, la tasa de impuesto de entrada de efectivo, el descuento de mercado, el precio de la electricidad y el precio del combustible.

#### **2.3.4. Método de construcción de la red neuronal artificial**

El método utilizado para la construcción de la red neuronal se puede dividir en cinco rubros: la generación base de datos, el desarrollo de la arquitectura de la red neuronal artificial, su entrenamiento, optimización y verificación. En la generación base de datos se lleva a cabo la generación y su análisis, de manera cualitativa y estadística. En el desarrollo de la arquitectura de la red neuronal se determinan las funciones de activación, también se desarrolla el algoritmo de tal manera que permita la variación del número de capas ocultas, el número de neuronas en cada capa oculta y el parámetro de regularización. Para el entrenamiento de la red es necesario establecer el método de entrenamiento a emplear, así como desarrollar el algoritmo que lleve a cabo las operaciones correspondientes al método seleccionado; también es necesario revisar que el método converja adecuadamente. En

la optimización de la red neuronal se analiza el número de datos necesarios para el entrenamiento de la red, se establecen las dimensiones de la red neuronal y el valor del parámetro de regularización. Finalmente es necesario llevar a cabo una verificación de la herramienta de optimización para observar la precisión de esta herramienta.

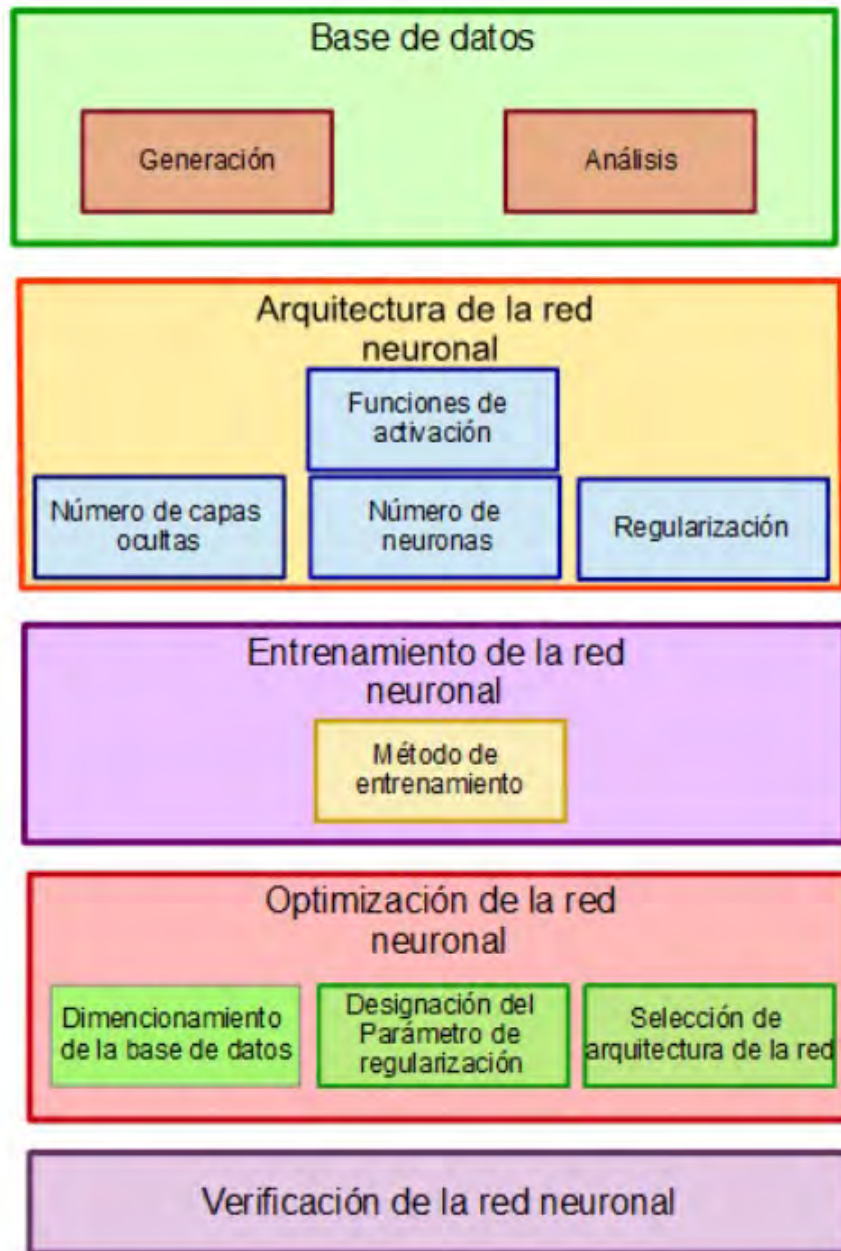


Figura 2.17: Metodología de la construcción de la red neuronal artificial.

# CAPÍTULO 3

## PLATAFORMAS DE SIMULACIÓN

En éste capítulo se presentan las dos plataformas de simulación utilizadas para la generación de la base de datos (la plataforma térmica y la económica) y su verificación.

### 3.1. Simulación Térmica

La plataforma de simulación térmica se construyó utilizando el software de simulación TRNSYS. La construcción de la plataforma consiste en la programación por bloques de TRNSYS. Esta manera de programación es intuitiva, ya que los componentes del sistema se conectan gráficamente por medio de la interfaz visual Simulation Studio. Cada componente (type) utilizado se encuentra previamente representado como un modelo matemático en Fortran, como una caja negra, en el cual es necesario establecer las entradas, salidas y parámetros específicos de cada componente.

Tabla 3.1: Características del captador de tubo evacuado [Helmke et al., 2015].

Colector Solar		
<b>Tipo</b>	Tubo evacuado	
<b>Fluido de trabajo</b>	Agua/Glicol	
	<i>Densidad (<math>\rho</math>)</i>	$1035 \frac{kg}{m^3}$
	<i>Calor específico (<math>C_p</math>)</i>	$3.7 \frac{kJ}{kg K}$
<b>Parámetros de eficiencia</b>	$a_0$	0.811
	$a_1$	2.71
	$a_2$	0.01
<b>Ubicación</b>	Graz, Austria	
<b>Ángulo Azimutal</b>	Frente al Ecuador	
<b>Ángulo de inclinación</b>	40°	

Las características de los componentes de los sistemas de calentamiento solar se tomaron del caso de estudio de la Agencia Internacional de Energía. Como ya se mencionó en la sección 2.2, los sistemas cuentan con captadores de tubos evacuados, tanque de almacenamiento, intercambiadores de calor, bombas hidráulicas, sistemas de control y calentador auxiliar. El captador solar utilizado es

de tubo evacuado con fluido de trabajo agua-glicol. Las características del captador se muestran en la Tabla 3.1.

Tabla 3.2: Características de los intercambiadores de calor [Helmke et al., 2015].

<b>Intercambiador de calor 1</b>		
<b>Tipo</b>	Contra-flujo	
<b>Fluidos de trabajo</b>	<i>Lado caliente</i>	
	Fluido	Agua/Glicol
	Calor específico ( $C_p$ )	$3.7 \frac{kJ}{kg K}$
	<i>Lado frío</i>	
	Fluido	Agua
	Calor específico ( $C_p$ )	$4.19 \frac{kJ}{kg K}$
<b>Coefficiente de transferencia de calor</b>	24000 W/K	
<b>Intercambiador de calor 2</b>		
<b>Tipo</b>	Contra-flujo	
<b>Fluidos de trabajo</b>	<i>Lado caliente</i>	
	Fluido	Agua
	Calor específico ( $C_p$ )	$4.19 \frac{kJ}{kg K}$
	<i>Lado frío</i>	
	Fluido	Agua tratada
	Calor específico ( $C_p$ )	$4.19 \frac{kJ}{kg K}$
<b>Coefficiente de transferencia de calor</b>	12000 W/K	

Los coeficientes de transferencia de calor para los intercambiadores son de  $24000 \frac{W}{K}$ , para el intercambiador uno, y  $12000 \frac{W}{K}$ , para el intercambiador dos. El intercambiador de calor uno trabaja con agua-glicol y agua como fluidos de trabajo, mientras que el intercambiador dos trabaja con agua normal y agua tratada. Las características del captador se muestran en la Tabla 3.2.

Tabla 3.3: Características de las bombas hidráulicas [Helmke et al., 2015].

<b>No. De bomba</b>	<b>Fluido de trabajo</b>	<b>Capacidad (<math>\frac{kg}{h}</math>)</b>	<b>Potencia nominal (kW)</b>	<b>Eficiencia total de la bomba</b>	<b>Eficiencia del motor</b>
1	Agua/Glicol	6000	6	0.6	0.9
2	Agua	6000	6	0.6	0.9
3	Agua	5000	5	0.6	0.9
4	Agua tratada	5000	5	0.6	0.9

La potencia de las bombas y su eficiencia total son dependientes del área de colección y el volumen de almacenamiento [Ramírez-Martínez, 2019]. Para el caso

de validación de la plataforma de simulación se toman las características establecidas en la Tabla 3.3.

Tabla 3.4: Características del tanque de almacenamiento [Helmke et al., 2015].

Termotanque	
Tipo	Estratificado
Volumen	12 m <sup>3</sup>
Altura	3 m
Fluido de trabajo	Agua
	Calor específico (C <sub>p</sub> )
UL	0.83 $\frac{kJ}{h m^2 °C}$
Secciones de estratificación	5

El termo-tanque utilizado es de tipo cilindro vertical estratificado con pérdidas uniformes con dos entradas y dos salidas, el volumen y dimensiones de este se establecen en función de la razón volumétrica, para la verificación se utilizaron los valores iniciales especificados en la Tabla 3.4. Para el perfil de carga se emplea un control On-Off que controla las bombas tres y cuatro.

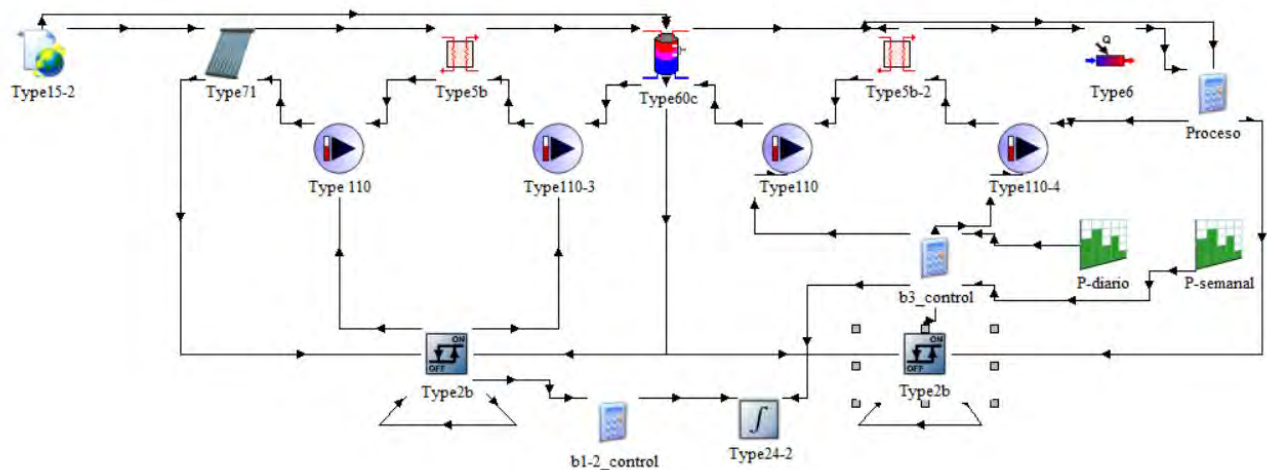


Figura 3.1: Sistema de calentamiento solar en la plataforma de simulación.

La Figura 3.1 presenta todos los elementos utilizados para la simulación del sistema de calentamiento solar de agua. El SHIP se puede dividir en tres el circuito de captación, el circuito de almacenamiento y el circuito de integración al proceso, por lo que el programa se fue construyendo a partir de cada uno de estos circuitos. El primer circuito, mostrado en la Figura 3.2, se conforma por captadores de tubo evacuado (Type 71), una bomba de desplazamiento positivo (Type 110) , el intercambiador

biador de calor a contraflujo uno (Type 5b) y un controlador (Type 2b). El circuito de almacenamiento, mostrado en la Figura 3.3, se encuentra integrado por los dos intercambiadores (Type 5b), dos bombas (Type 110), el tanque de almacenamiento (Type 60c) y un controlador (Type 2b). El circuito de integración (Figura 3.4) está formado por una bomba (Type 110), el intercambiador dos (Type 5b), el calentador auxiliar (Type 6), un control On-Off (Type 14h) y una calculadora en la cual se obtienen los valores de la  $FS$ ,  $Q_u$  y  $Q_{req}$ , y estos valores se mandan a imprimir a una hoja de cálculo.




Figura 3.2: Circuito de colección y datos meteorológicos.




Figura 3.3: Circuito de almacenamiento.




Figura 3.4: Circuito de integración.

En la Figura 3.5 se muestra los tiempos de encendido y apagado del perfil de carga utilizado para la validación. Que consiste en periodos de 30 *min* de prendido por 60 *min* de apagado de las 6:00 am a las 10:00 am y de la 1:30 pm a las 8:30 pm.



Y de periodos de 30 *min* de trabajo por 30 *min* de descanso de las 10:00 am a la 1:30 pm.



Figura 3.5: Perfil de carga.

### 3.2. Simulación Económica

En la Figura 3.6 se muestra un algoritmo del programa de simulación económica el cual se generó en el software Octave. El algoritmo permite determinar los valores de la fracción solar, energía útil, ahorros solares, periodo de recuperación, razón de uso y razón volumétrica óptimas para un sistema de calentamiento solar. El algoritmo utiliza las entradas enlistadas en la Tabla 3.5, para realizar la optimización.

Tabla 3.5: Entradas de la plataforma de simulación económica.

<b>Entradas del caso de estudio.</b>	<b>Entradas económicas.</b>
<ol style="list-style-type: none"> <li>1. Lugar de estudio.</li> <li>2. Demanda del proceso.</li> <li>3. Temperatura requerida.</li> <li>4. Horas de trabajo al día.</li> <li>5. Días de trabajo a la semana.</li> <li>6. Semanas de trabajo al año.</li> </ol>	<ol style="list-style-type: none"> <li>1. Horas de trabajo de las bombas.</li> <li>2. Potencia de las bombas.</li> <li>3. Porcentaje de préstamo de hipoteca.</li> <li>4. Tasas de interés, inflación y descuento.</li> <li>5. Porcentaje de reventa del sistema.</li> <li>6. Entrada efectiva de la tasa de impuesto.</li> <li>7. Costos de los elementos del sistema.</li> <li>8. Costos del combustible, electricidad y parasitarios.</li> </ol>
<b>Entradas térmicas.</b>	
<ol style="list-style-type: none"> <li>1. Razón volumétrica.</li> <li>2. Razón de uso.</li> <li>3. Fracción solar.</li> <li>4. Energía útil.</li> </ol>	

A partir de las entradas, se obtienen las ecuaciones de tendencia de las curvas de las fracciones solares y energías útiles a partir de una regresión polinómica. Una vez obtenida, la ecuación polinómica se utiliza para calcular los valores de la  $FS$  y  $Q_u$  para la razón de uso en el rango introducido al programa, con un incremento de 1. Las  $FS$  se utilizan para realizar el cálculo de los  $LCS$  y  $PB$ . Una vez obtenidos todos los valores de  $LCS$  y  $PB$ , se producen las tablas de diseño.



Figura 3.6: Algoritmo del programa económico.

Para realizar la optimización el algoritmo evalúa la diferencia porcentual de los valores de la  $FS$  y  $Q_u$  entre diferentes  $R_v$ s. La  $R_v$  óptima se obtiene cuando la diferencia porcentual de la  $FS$  y  $Q_u$ , para una  $R_v$ , es menor a 1% respecto a la siguiente,

en orden ascendente. Una vez determinada la  $R_v$  óptima se normalizan los valores de la  $FS$ ,  $Q_u$ ,  $LCS$  y  $PB$  para esa  $R_v$  y se grafican. A partir de estos valores se determina el punto de flexión de los  $LCS$ , el cual se considera como el valor óptimo para la  $R_u$ ,  $LCS$  y  $PB$ . Una vez obtenidos, los valores óptimos se exportan a un archivo de texto junto con  $D$ ,  $T$ ,  $C$ ,  $P - d$  y  $P - s$  (es decir las entradas de las redes neuronales) del caso estudiado. Las Figuras 3.7 y 3.8 presentan un ejemplo de la tabla de diseño térmico y económico respectivamente. La Figura 3.9 muestra los valores normalizados de  $FS$ ,  $Q_u$ ,  $LCS$  y  $PB$  de  $R_v$  óptima para las diferentes  $R_u$ . También se presenta el punto óptimo de estos valores, tomando en cuenta el punto máximo de los ahorros solares. Las tablas corresponden al caso con las siguientes entradas:

1. Ciudad: Monterrey.
2. Demanda de agua:  $25000 \frac{l}{día}$ .
3. Temperatura requerida:  $80^\circ C$ .
4. Perfil diario: 8 h continuas, de 9:00 am a 5:00 pm.
5. Perfil semanal: 5 días a la semana, de lunes a viernes.




Figura 3.7: Tabla de optimización térmica.




Figura 3.8: Tabla de optimización económica.




Figura 3.9: Tabla de optimización normalizada.

### 3.3. Verificación de los simuladores

Las verificaciones de las plataformas de simulación térmica y económica se realizaron comparando los resultados reportados de la *FS*, *Q<sub>u</sub>*, *LCS* y *PB* por [Helmke et al., 2015] y [Duffie et al., 2013] respectivamente, en términos del coeficiente de correlación  $R^2$ , un análisis de varianza *ANOVA* ( $p$  – *valor*) y error relativo. Las Tabla 3.6 y 3.7 muestran los valores obtenidos, los reportados y el error relativo, para la *FS*, *Q<sub>u</sub>* y *LCS*. El  $R^2$  fue de 0.9997, 0.9992, 1 y 1 para la *FS*, *Q<sub>u</sub>*, *LCS* y *PB*, respectivamente. El error relativo más alto fue de 2.36%, 1.70% y 0.04%, para la *FS*, *Q<sub>u</sub>* y *LCS*. El  $p$  – *valor* fue de 0.9757, para la *FS*, 0.9859 para la *Q<sub>u</sub>*, 0.9999 para el *LCS*, y 1 para el *PB*, con una significancia de 0.05. Los valores de  $R^2$ , los  $p$  – *valores* y error relativo determinados indican que no existe una diferencia significativa entre los resultados reportados y los obtenidos [Anderson et al., 2016, Gomila-Salas, 2020].

Tabla 3.6: Verificación térmica.

$R_v$	$R_u$	Reportado		Este trabajo		Error relativo (%)	
		FS	$Q_u$ ( $\frac{kWh}{m^2}$ )	FS	$Q_u$ ( $\frac{kWh}{m^2}$ )	FS	$Q_u$
10	50	0.235	380.7	0.234	381.09	0.427350	0.102338
	100	0.13	407.6	0.127	412.1	2.362205	1.091968
	150	0.086	419.2	0.087	423.8	1.149425	1.085418
20	100	0.19	628.1	0.192	623.3	1.041667	0.770095
30	50	0.353	573.3	0.348	564.5	1.436782	1.558902
	100	0.228	735.38	0.229	741.69	0.436681	0.850759
	150	0.162	787.4	0.159	774.2	1.886792	1.704986

Tabla 3.7: Verificación económica.

Área	FS	Costo inicial (\$)	Este trabajo	Reportado	Error relativo (%)
			Ahorros solares (\$)		
0.01	0	1002	-1036.39	-1036	0.037645
25	0.37	6000	4088.067	4088	0.001639
39	0.49	8800	4530.557	4531	0.009777
50	0.56	11000	4202.559	4203	0.010493
75	0.71	16000	3204.185	3204	0.005774
150	0.92	31000	-6468.135	-6468	0.002087

# CAPÍTULO 4

## DESARROLLO DE LA RED NEURONAL

La construcción de la red neuronal consiste en tres pasos, el análisis de la base de datos, la determinación de la arquitectura de la red neuronal y la determinación del método de entrenamiento. El análisis de la base de datos se divide en un análisis cualitativo y un análisis estadístico. En el análisis cualitativo se observa el comportamiento de las variables de salida con respecto las variables de entrada, mientras que el análisis estadístico se comparan entre sí los parámetros estadísticos y las gráficas de distribución. En la determinación de la arquitectura de la ANN, se establece la función de activación de la o las capas ocultas y la capa de salida. También se realiza el código con el fin de modificar el número de las capas ocultas y/o neuronas en cada capa. En la determinación del método de entrenamiento se establece el método iterativo empleado para el entrenamiento.

En este trabajo se realizaron cuatro redes neuronales cada una para calcular las variables de salida (variables dependientes):  $R_u$ ,  $R_v$ ,  $LCS$  y  $PB$  óptimos respectivamente para cada caso. Las variables de entrada (variables independientes) son: la ciudad ( $C$ ), la temperatura del proceso ( $T$ ), la demanda de agua diaria  $D$ , el número de horas de trabajo al día ( $P - d$ , perfil de carga diario) y el número de días de trabajo a la semana ( $P - s$ , perfil de carga semanal). Para la construcción de la red neuronal se seleccionó el software Octave. La selección se realizó con base en trabajos previos y la facilidad de uso de esta herramienta para el manejo de datos y paquetes para la generación de redes neuronales.

### 4.1. Análisis de la base de datos

La base de datos para la red neuronal se construyó variando la  $T$ ,  $D$ ,  $P - d$  y  $P - s$  para las ciudades de Campeche, Ecatepec y Monterrey. Los intervalos  $T$  y  $D$  fueron de  $60-90^{\circ}C$  con un incremento de  $1^{\circ}C$  y de  $1571-15714 \frac{l}{día}$ , con un incremento de  $1571 \frac{l}{día}$  respectivamente y un caso adicional de  $25,000 \frac{l}{día}$ . En la Figura 4.1 se representan los cuatro perfiles de carga, diferenciando el horario y semanal. La base de datos se generó con 229,162 corridas, que permitió obtener 4,005 casos optimizados.

Los perfiles mostrados en la Figura 4.1 son la representación de las señales de activación de las bombas hidráulicas.

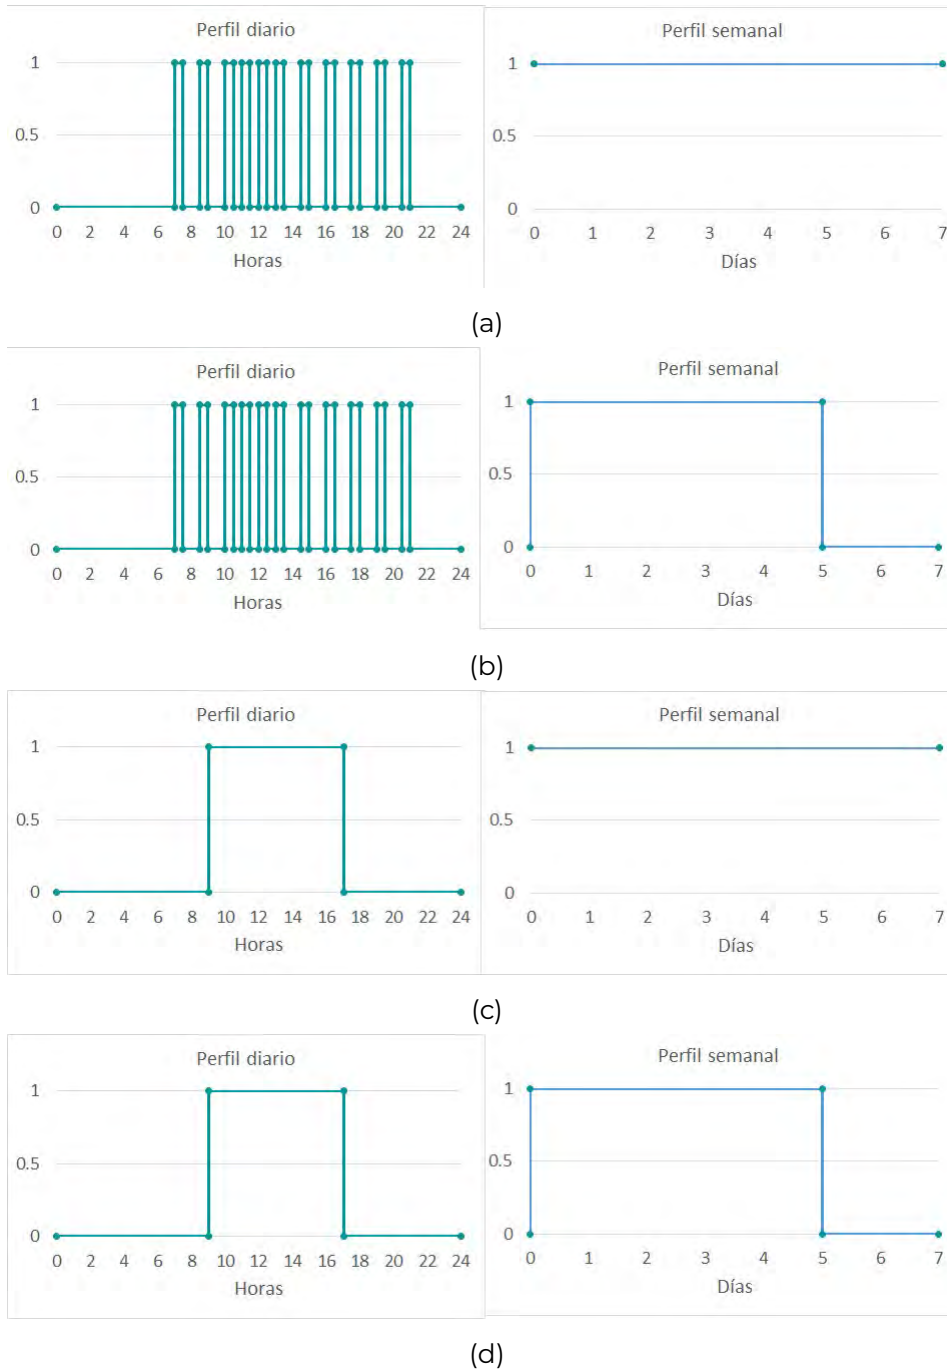


Figura 4.1: *Perfiles de carga utilizados para la generación de la base de datos.*

El análisis de la base de datos se realizó de manera estadística y de manera cua-


litativa. En el análisis estadístico consistió en la evaluación de los parámetros estadísticos (media, desviación estándar ( $SD$ ), valor mínimo, mediana y valor máximo) y los coeficientes de correlación entre las variables dependientes e independientes. El análisis cualitativo consistió en observar el comportamiento de las variables dependientes en función de las independientes, al graficar las en diagramas 3D considerando la  $T$  y la  $D$  para las tres ciudades y cuatro perfiles de carga.

En la Tabla 4.1 se presentan los valores de los parámetros estadísticos de los valores óptimos de  $R_u$  para las tres ciudades con los cuatro perfiles de carga. Los valores de la media varían en función de las ciudades y perfiles de carga. Los valores de la media pueden llegar a fluctuar hasta en un 26.44% al cambiar el perfil de carga. El perfil de carga 4.1b presenta los valores más altos de la media y  $SD$  para todos los parámetros en las tres ciudades y el perfil de carga 4.1c presenta los valores menores, igual para las tres ciudades. Por su parte, la  $SD$  presenta diferencias porcentuales de hasta el 50.44% en función a los perfiles de carga. Por lo que se deduce que la  $R_u$  varía considerablemente al variar el perfil de carga. Por otra parte, Monterrey presenta la media mayor seguida de Ecatepec y Campeche, sin embargo la diferencia porcentual entre la media mayor de Monterrey y la de Ecatepec es de 0.67% por lo que no es una diferencia significativa.


Tabla 4.1: *Parámetros estadísticos de la  $R_u$  para los casos optimizados en Campeche, Ecatepec y Monterrey para los perfiles de carga 4.1a, 4.1b, 4.1c y 4.1d.*

Ciudad	Perfil de demanda	Media ( $L/m^2$ -día)	SD ( $L/m^2$ -día)	Mínimo ( $L/m^2$ -día)	Mediana ( $L/m^2$ -día)	Máximo ( $L/m^2$ -día)
Campeche	(a)	55.4853	11.9288	40.0000	51.0000	85.0000
	(b)	<b>62.7786</b>	<b>13.1429</b>	<b>42.0000</b>	<b>59.0000</b>	<b>99.0000</b>
	(c)	<b>51.0953</b>	<b>10.3698</b>	<b>38.0000</b>	<b>48.0000</b>	<b>78.0000</b>
	(d)	57.9780	11.9806	40.0000	54.0000	91.0000
Ecatepec	(a)	50.3519	8.7343	40.0000	47.0000	73.0000
	(b)	<b>62.8094</b>	<b>13.1399</b>	<b>42.0000</b>	<b>59.0000</b>	<b>99.0000</b>
	(c)	<b>49.6726</b>	<b>8.4026</b>	<b>37.0000</b>	<b>48.0000</b>	<b>71.0000</b>
	(d)	58.3616	9.8772	42.0000	56.0000	83.0000
Monterrey	(a)	52.2815	10.5433	39.0000	48.0000	79.0000
	(b)	<b>63.2023</b>	<b>13.1007</b>	<b>42.0000</b>	<b>59.0000</b>	<b>95.0000</b>
	(c)	<b>50.5396</b>	<b>9.6115</b>	<b>37.0000</b>	<b>47.0000</b>	<b>76.0000</b>
	(d)	60.5154	12.2667	42.0000	57.0000	91.0000







(a) Razón de uso para el perfil de trabajo 4.1a



(b) Razón de uso para el perfil de trabajo 4.1b



(c) Razón de uso para el perfil de trabajo 4.1c



(d) Razón de uso para el perfil de trabajo 4.1d


Figura 4.2: Gráficas de la  $R_u$  en función de la  $T$  y la demanda.

En la Figura 4.2 se presentan las gráficas de la  $R_u$  con respecto a la  $D$  y la  $T$  para los casos de Campeche, Ecatepec y Monterrey para los cuatro perfiles de carga diferentes. Como se observa de manera cualitativa, las tendencias de las tres ciudades para los cuatro perfiles son semejantes. Las gráficas muestran que la razón de uso tiene un comportamiento sigmoideal con respecto a la  $D$  y un comportamiento logarítmico con respecto a la  $T$ . Así como que los valores de la  $R_u$  varían con la ciudad y con el perfil de carga.


En la Tabla 4.2 se presentan los valores de los parámetros estadísticos de la  $R_v$  para las diferentes ciudades con los cuatro perfiles de carga. El perfil de carga 4.1b presenta los valores más altos para todos los parámetros en las tres ciudades y el perfil de carga 4.1c presenta los valores menores, para todos los parámetros en las tres ciudades, con diferencias porcentuales hasta el 60.64% y 109,18% de la media y la desviación estándar. Monterrey presenta la media mayor seguido de Ecatepec y Campeche, con una diferencia porcentual de la media entre Monterrey y Campeche de 14.47%.

Tabla 4.2: *Parámetros estadísticos de la  $R_v$  óptima en Campeche, Ecatepec y Monterrey para los perfiles de carga 4.1a, 4.1b, 4.1c y 4.1d.*


Ciudad	Perfil de demanda	Media (L/m <sup>2</sup> )	SD (L/m <sup>2</sup> )	Mínimo (L/m <sup>2</sup> )	Mediana (L/m <sup>2</sup> )	Máximo (L/m <sup>2</sup> )
Campeche	(a)	45.5132	8.9501	20.0000	50.0000	60.0000
	(b)	<b>46.2170</b>	<b>15.2257</b>	<b>20.0000</b>	<b>50.0000</b>	<b>60.0000</b>
	(c)	<b>31.7009</b>	<b>7.2788</b>	<b>20.0000</b>	<b>30.0000</b>	<b>40.0000</b>
	(d)	39.2962	15.2219	20.0000	40.0000	60.0000
Ecatepec	(a)	44.9853	11.5204	20.0000	50.0000	60.0000
	(b)	<b>46.3929</b>	<b>15.1136</b>	<b>20.0000</b>	<b>50.0000</b>	<b>60.0000</b>
	(c)	<b>34.4839</b>	<b>7.4319</b>	<b>20.0000</b>	<b>40.0000</b>	<b>40.0000</b>
	(d)	46.4779	15.7319	20.0000	50.0000	60.0000
Monterrey	(a)	46.5689	12.7286	20.0000	50.0000	60.0000
	(b)	<b>52.9032</b>	<b>13.9775</b>	<b>20.0000</b>	<b>60.0000</b>	<b>60.0000</b>
	(c)	<b>32.9326</b>	<b>8.4484</b>	<b>20.0000</b>	<b>40.0000</b>	<b>40.0000</b>
	(d)	43.3442	16.1281	20.0000	50.0000	60.0000




(a) Razón volumétrica para el perfil de trabajo 4.1a



(b) Razón volumétrica para el perfil de trabajo 4.1b



(c) Razón volumétrica para el perfil de trabajo 4.1c



(d) Razón volumétrica para el perfil de trabajo 4.1d


Figura 4.3: Gráficas de la  $R_v$  en función de la  $T$  y la demanda.

Las  $R_v$  óptimas en función de las variables de entrada son presentadas en la Figura 4.3. En las gráficas se aprecia un comportamiento escalonado de la  $R_v$  con respecto a la demanda, mientras que con relación a la  $T$  se encuentra un comportamiento cuasi lineal. También se observa que a mayor  $D$  mayor  $R_v$ , sin embargo, a partir de cierto valor la  $R_v$  no aumenta de  $60 \frac{l}{m^2}$ .


En la Tabla 4.3 se presentan los valores de los parámetros estadísticos de los  $LCS$  para las diferentes ciudades con los cuatro perfiles de carga. Las mayores medias de los  $LCS$  optimizados se obtienen con el perfil 4.1a en Campeche, seguido de Monterrey y el perfil 4.1c para Ecatepec. Los mayores valores de las  $SD$  se obtuvieron con el perfil 4.1a para las tres ciudades. Las diferencias porcentuales entre los diferentes perfiles llega a ser de hasta un 305.23 %, para la media, y 81.45 %, para la desviación estándar. La diferencia porcentual entre las ciudades llega hasta 27.58 % y 14.02 % para la media y la desviación estándar respectivamente, al comparar cada uno de los perfiles de carga.

Tabla 4.3: Parámetros estadísticos de los  $LCS$  óptimos en Campeche, Ecatepec y Monterrey para los perfiles de carga 4.1a, 4.1b, 4.1c y 4.1d.


Ciudad	Perfil de demanda	Media \$ (x10 <sup>5</sup> )	SD \$ (x10 <sup>5</sup> )	Mínimo \$ (x10 <sup>5</sup> )	Mediana \$ (x10 <sup>5</sup> )	Máximo \$ (x10 <sup>5</sup> )
Campeche	(a)	16.0981	14.2752	-5.1145	14.3806	50.5737
	(b)	6.9219	8.8741	-6.1344	6.0563	27.4663
	(c)	15.3687	13.5096	-4.9543	13.9687	46.1271
	(d)	6.1945	8.1529	-6.0366	5.4919	25.0969
Ecatepec	(a)	10.7674	10.9325	-5.5285	9.7008	36.1962
	(b)	6.9191	8.8749	-6.1344	6.0560	27.4663
	(c)	11.1364	9.8664	-5.4680	10.8222	32.5098
	(d)	2.7481	6.0250	-6.3758	2.3192	16.3192
Monterrey	(a)	12.7409	12.2693	-5.3414	11.3193	42.7077
	(b)	5.0125	7.6303	-6.2880	4.2068	22.8185
	(c)	12.3039	11.6689	-5.2739	11.0924	38.4729
	(d)	4.1605	6.9987	-6.2530	3.6259	20.4917




(a) Ahorros solares para el perfil de trabajo 4.1a



(b) Ahorros solares para el perfil de trabajo 4.1b



(c) Ahorros solares para el perfil de trabajo 4.1c



(d) Ahorros solares para el perfil de trabajo 4.1d


Figura 4.4: Gráficas de los LCS en función de la T y la demanda.

En la Figura 4.4 se presentan las gráficas de los ahorros solares, *LCS*, en función de la *T* y la *D* para las tres diferentes ciudades y los cuatro perfiles de trabajo. Al igual que en las gráficas de la razón de uso y la razón volumétrica, las doce gráficas siguen el mismo patrón. En las Figura, se observa que el comportamiento de los *LCS* es cuasi lineal con respecto a la *T* y a la *D*, donde a mayor demanda ya mayor temperatura se tienen mayores ahorros solares.


En la Tabla 4.4 se presentan los valores de los parámetros estadísticos del *PB*. Los valores del *PB*, en su mayoría, fluctúan entre 6-9 años para todos los casos. Campeche presenta la media menor del *PB* en el perfil 4.1a y Ecatepec y Monterrey presentan los valores menores de la media del *PB* en el perfil 4.1d. Las diferencias porcentuales entre las medias al variar el perfil de carga llegan hasta el 41.78%, mientras que la diferencia porcentual de la desviación estándar entre los perfiles de carga llega hasta un 69.61%. Mientras que la variación porcentual al cambiar la ciudad de la media llega a valores de hasta un 8.32%.

Tabla 4.4: *Parámetros estadísticos del PB óptimos en Campeche, Ecatepec y Monterrey para los perfiles de carga 4.1a, 4.1b, 4.1c y 4.1d.*


Ciudad	Perfil de demanda	Media (años)	SD (años)	Mínimo (años)	Mediana (años)	Máximo (años)
Campeche	(a)	<b>9.8449</b>	<b>5.4569</b>	<b>6.0499</b>	<b>7.6166</b>	<b>35.2877</b>
	(b)	<b>13.6317</b>	<b>8.9811</b>	<b>7.5021</b>	<b>9.9039</b>	<b>56.4134</b>
	(c)	10.0733	5.1945	6.2963	7.7837	33.7242
	(d)	13.7549	8.3709	8.0732	10.3256	53.7543
Ecatepec	(a)	<b>11.6802</b>	<b>6.25089</b>	<b>7.3562</b>	<b>9.0772</b>	<b>39.6221</b>
	(b)	13.6352	8.9867	7.5021	9.9039	56.4134
	(c)	11.2797	6.0712	7.5317	9.0281	38.3724
	(d)	<b>15.9929</b>	<b>9.6679</b>	<b>9.3184</b>	<b>12.0584</b>	<b>60.8212</b>
Monterrey	(a)	<b>10.9572</b>	<b>5.9121</b>	<b>6.7753</b>	<b>8.5087</b>	<b>37.5938</b>
	(b)	<b>14.7656</b>	<b>9.6822</b>	<b>8.2032</b>	<b>10.8728</b>	<b>60.8524</b>
	(c)	10.9364	5.7086	6.8443	8.5792	36.8187
	(d)	15.1601	9.5580	8.6527	11.3027	59.4780




(a) Tiempo de retorno para el perfil de trabajo 4.1a



(b) Tiempo de retorno para el perfil de trabajo 4.1b



(c) Tiempo de retorno para el perfil de trabajo 4.1c



(d) Tiempo de retorno para el perfil de trabajo 4.1d

Figura 4.5: Gráficas del PB en función de la T y la demanda.

En la Figura 4.5 se muestran los tiempos de retorno de los sistemas en función de la  $T$  y la  $D$ . Del mismo modo que en los casos anteriores, las tres figuras presentan un comportamiento similar. En la Figura se observa un comportamiento logarítmico en la forma  $y = a + \frac{b}{x^2}$  del  $PB$  con respecto a  $T$ . También se puede ver que la variación del  $PB$  con respecto a  $D$  es prácticamente lineal. Por su parte, la variación del  $PB$  en función de la ciudad, Ecatepec muestra los mayores valores, seguido de Monterrey y Campeche.

El coeficiente de correlación de Pearson fue utilizado como el parámetro para determinar la correlación entre las variables dependientes y las variables independientes, presentados en la Tabla 4.5.  $R_u$  presenta una mayor correlación con la temperatura del proceso mientras que  $R_v$ ,  $LCS$  y  $PB$  presentan una mayor correlación con  $D$ . Las cuatro variables dependientes presentan la menor correlación con  $C$ , lo cual quiere decir que de las cinco variables independientes la ciudad es la variable con menor influencia en las variables independiente.

Tabla 4.5: Coeficientes de correlación entre las variables dependientes y las variables independientes.

<b>Dependiente / Independiente</b>	<b><math>R_u</math></b>	<b><math>R_v</math></b>	<b><math>LCS</math></b>	<b><math>PB</math></b>
<i>Ciudad</i>	0.0102	-0.0949	0.0922	-0.0559
<i>T</i>	-0.7411	0.0959	0.1679	-0.1319
<i>Demanda</i>	0.2657	0.6870	0.8745	-0.6152
<i>Perfil diario</i>	-0.1292	-0.3242	-0.0443	0.0251
<i>Perfil semanal</i>	-0.3804	-0.2246	0.3476	-0.2319

Tomando en cuenta lo anterior, se observa que cada variable muestra similar comportamiento en función de  $D$  y  $T$  para la tres ciudad y los cuatro perfiles de carga. Las cuatro variables dependientes presentan la menor correlación con la ciudad; la  $R_u$  presenta una mayor correlación con  $T$  mientras que  $R_v$ ,  $LCS$  y  $PB$  presentan una mayor correlación con  $D$ . Lo que implica que las variables independientes con mayor importancia para el cálculo de las variables dependientes son la  $T$  y la  $D$ . Los valores de las medias llegan a tener diferencias porcentuales al variar el perfil de carga de hasta 26.44 %, para las  $R_u$ , 60.64 %, para las  $R_v$ , 305.23 %, para los  $LCS$  y 41.78 %, para el  $PB$ . También se observa que Campeche es la ciudad con los mayores ahorros solares y Ecatepec la ciudad con los menores. Asimismo, los



casos en el que se trabajan todos los días del año muestran mejores resultados de *LCS* y *PB* que los casos en los que sólo se trabajan 5 días a la semana.

## 4.2. Desarrollo de la arquitectura de la red neuronal

El algoritmo de las *ANN* presentadas a lo largo de éste trabajo fueron desarrollados en el programa Octave. En del desarrollo de la arquitectura de la red neuronal se plantearon tres arquitecturas. En esta sección se explicaran las tres arquitecturas y se expondrá la arquitectura seleccionada y las razones por las que se seleccionó dicha arquitectura.

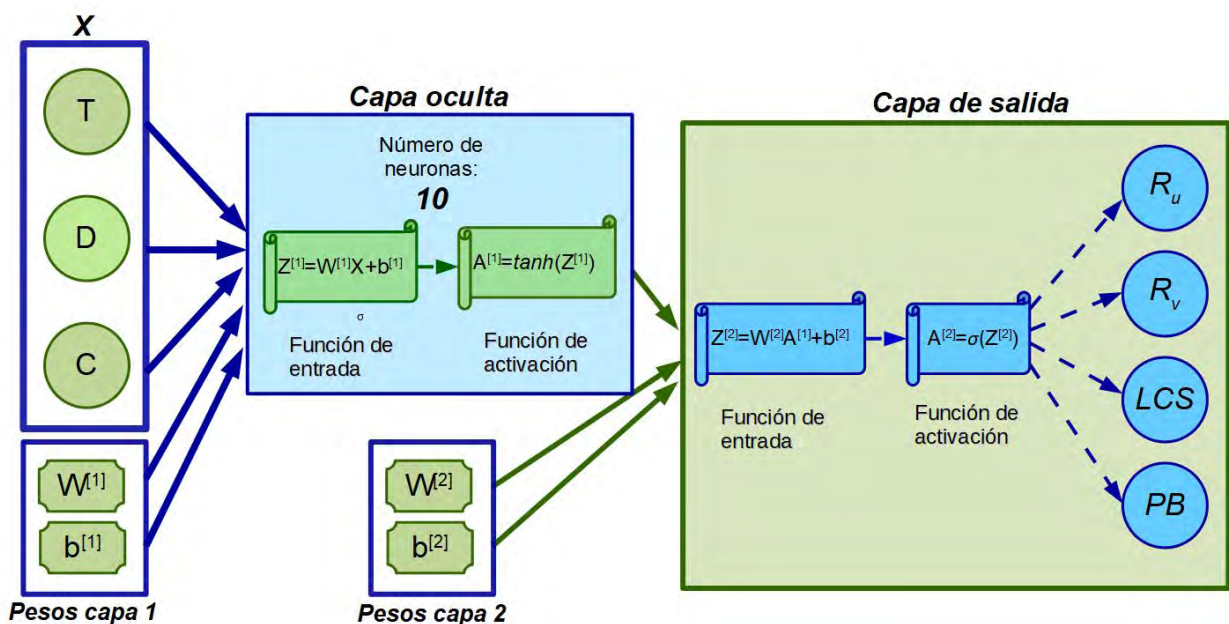


Figura 4.6: Esquema de la primera propuesta de arquitectura

Una primera propuesta de la arquitectura de la red neuronal se muestra en la Figura 4.6, basada en los trabajos previos de [Kalogirou, 2005]. En la primer versión, el error se determina con la ecuación 4.1, con la función de activación de salida sigmoide y solo se consideran tres entradas. Sin embargo, una vez que se realizó el primer experimento, se observó que el error presentado en la ecuación (4.1) tiende a infinito, después de la tercera iteración, para las cuatro variables de salida. Tomando esto en cuenta se realizó un análisis para encontrar la razón de la divergencia. Para esto se comenzó con el análisis de la función de activación de salida ( $A^{[2]}$ ), es decir, la función sigmoide. La función sigmoide tiene un pequeño rango en la que sus valores son diferentes a cero o uno (Figura 4.7), por lo tanto no es una función

adecuada de salida para lo fines de este trabajo. Tomando esto en cuenta se realizó una investigación y se corroboró que esta función es utilizada en su mayoría para la realización de clasificaciones, debido a su comportamiento [Gomila-Salas, 2020, Andrew, 2019, Andrew et al., 2019b]. Con base a lo anterior se llegó a la conclusión de que esta función no es la óptima para el cálculo de las variables dependientes, por lo que se propuso una segunda arquitectura.




Figura 4.7: Función sigmoidea [Mathworld, 2020].

$$J = -\frac{1}{m} \sum_{i=0}^m \sum_{j=0}^K (y_i \log(a_i^{[L]}) + (1 - y_i) \log(1 - (a_i^{[L]}))) \quad (4.1)$$

donde  $m$  es el número de ejemplos de la base de datos y  $K$  es el número de salidas de la red neuronal,  $a_i^{[L]}$  la función de activación de la capa de salida,  $y_i$  la salida de la base de datos.

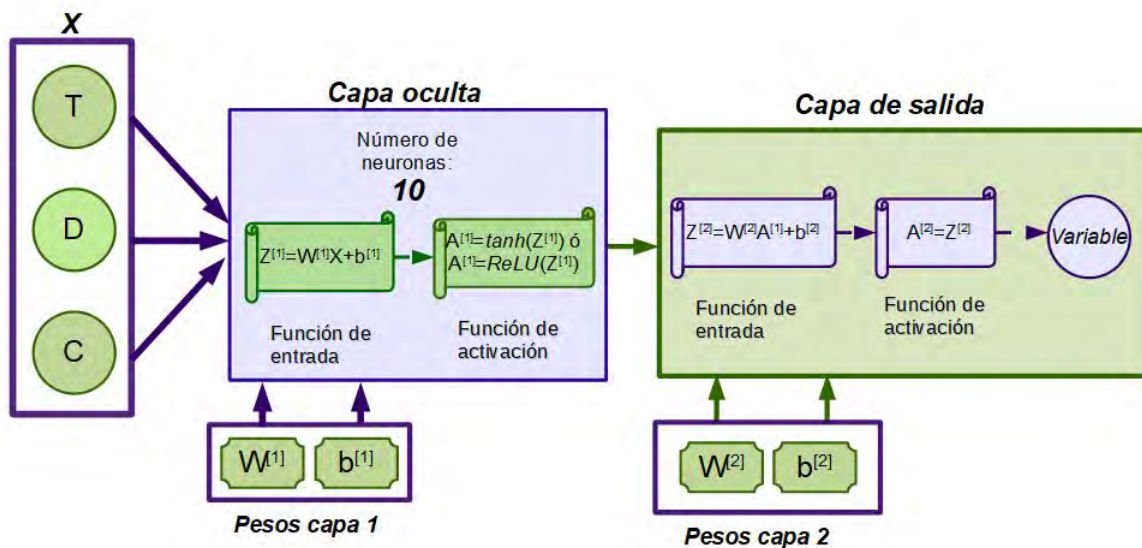


Figura 4.8: Esquema de la segunda propuesta de arquitectura

La segunda arquitectura propuesta presenta tres diferencias substanciales respecto a la primera versión. La primera diferencia es que en esta arquitectura sólo tiene una salida, es decir, que se va a desarrollar una red neuronal para cada salida. La segunda diferencia es que la función de activación de la capa de salida pasó de ser sigmoïdal a ser lineal. La tercera diferencia es que se planea probar dos funciones de activaciones en la capa oculta, la función de tangente hiperbólica y la de rectificador lineal unitario (*ReLU*), con el fin de encontrar la que tiene mejor desempeño.

En la Figura 4.8, “variable” representa la variable de salida, es decir, la  $R_u$ ,  $R_v$ ,  $LCS$  ó  $PB$ .  $W^{[1]}$ ,  $W^{[2]}$  son las matrices de pesos de la capa escondida y de salida, respectivamente.  $b^{[1]}$  es el vector de bias de la capa escondida y  $b^{[2]}$  es el vector de bias de la capa de salida.  $X$  es el vector de las entradas de la red neuronal.  $Z^{[1]}$  y  $Z^{[2]}$  son los vectores de entrada para las funciones de activación para la capa oculta y de salida, respectivamente.  $A^{[1]}(Z^{[1]})$  es la función de activación de tangente hiperbólico para las neuronas de la capa oculta y  $A^{[n]}(Z^{[n]})$  es la función de activación para la neurona de la capa de salida. Las ecuaciones (4.2) y (4.3) representan la función de activación de la tangente hiperbólica y *ReLU* respectivamente.

$$\tanh(Z^{[1]}) = \frac{e^{Z^{[1]}} - e^{-Z^{[1]}}}{e^{Z^{[1]}} + e^{-Z^{[1]}}} \quad (4.2)$$

$$\begin{cases} ReLU = 0 & si \quad Z^{[1]} \leq 0 \\ ReLU = Z^{[1]} & si \quad Z^{[1]} > 0 \end{cases} \quad (4.3)$$

La ecuación de error ( $J$ ) utilizada para estas redes neuronales es el error medio cuadrático (ecuación (4.4)).

$$J = -\frac{1}{2m} \sum_{i=0}^m (A_i^{[2]} - Y_i)^2 \quad (4.4)$$

donde  $m$  es el número de ejemplos de la base de datos.

Con el fin de determinar la función de activación en la capa oculta, se corrieron las cuatro redes neuronales para el caso en que la función es la tangente hiperbólica y para el caso en que la función es ReLU. Para esto, el 70 % de esa base de datos se utilizó para el entrenamiento mientras que el 30 % se utilizó para la verificación. A lo largo del entrenamiento se buscó sacar el error medio cuadrático mínimo entre lo calculado por la red y lo reportado en la base de datos. Una vez entrenada

la red se utilizó el 30% de la base de datos restantes para sacar un nuevo error medio cuadrático. El error obtenido en el entrenamiento se llamó  $J_{train}$  y el error obtenido en la verificación se llamó  $J_{test}$ . La Tabla 4.6 muestra los errores obtenidos para la función de activación de la tangente hiperbólica y la función  $ReLU$  para las cuatro redes neuronales. Dado que la mayor diferencia porcentual es de 0.008%, se considera que no hay diferencia al utilizar cualquiera de las dos funciones de activación, por lo que se escogió la  $tanh$  debido a su simplicidad de programación.

Tabla 4.6: Diferencias porcentuales entre los errores para las funciones de  $tanh$  y  $ReLU$ .

Variable de salida	tanh		ReLU		Diferencia porcentual (%)	
	$J_{train}$	$J_{test}$	$J_{train}$	$J_{test}$	$J_{train}$	$J_{test}$
Ru	0.027239	0.022678	0.027240	0.022676	0.006	0.008
Rv	0.039584	0.037867	0.039583	0.037867	0.003	0.001
LCS	0.035893	0.025593	0.025894	0.025594	0.004	0.003
PB	0.016725	0.012787	0.016725	0.012787	0.001	0.002

La tercera versión de la arquitectura presenta tres diferencias con respecto a la segunda versión de la arquitectura de la red neuronal. La primera diferencia radica en que la función de activación en las capas ocultas es la tangente hiperbólica, como ya se explicó anteriormente. La segunda diferencia es la versatilidad del código para aumentar el número de neuronas y capas ocultas de la red neuronal. La tercera diferencia es el número de entradas de la red neuronal, ya que la versión final de la arquitectura aumenta su número de entradas de tres a cinco al contemplar el perfil de trabajo diario y semanal. Un diagrama de flujo del programa que representa la arquitectura de las redes neuronales se exhibe en la Figura 4.9. Donde, “variable” representa la variable de salida, es decir, la  $R_u$ ,  $R_v$ ,  $LCS$  ó  $PB$ .  $T$  es la temperatura del proceso,  $D$  es la demanda de agua diaria,  $C$  es la ciudad,  $P - d$  es el perfil diario y  $P - s$  es el perfil semanal.  $L$  es el número de capas, incluyendo la de salida e  $i$  es el número de neuronas en las capas.  $W^{[1]} - W^{[l-1]}$ ,  $W^{[l]}$  son las matrices de pesos de las capas escondidas y de salida.  $b^{[1]} - b^{[l-1]}$  son los vectores de bias de las capas escondidas y  $b^{[l]}$  es el vector de bias de la capa de salida.  $X$  es el vector de las entradas de la red neuronal.  $Z^{[1]} - Z^{[l-1]}$  y  $Z^{[l]}$  son los vectores de entrada para las funciones de activación para las capas ocultas y de salida, respectivamen-

te.  $A^{[1]}(Z^{[1]}) - A^{[l-1]}(Z^{[l-1]})$  son las funciones de activación de tangente hiperbólico para las neuronas de las capas ocultas y  $A^{[n]}(Z^{[n]})$  es la función de activación para la neurona de la capa de salida. Cabe mencionar que todas las funciones de entrada y de activación de todas las capas ocultas son iguales y el número de neuronas permanece constante en las capas ocultas.

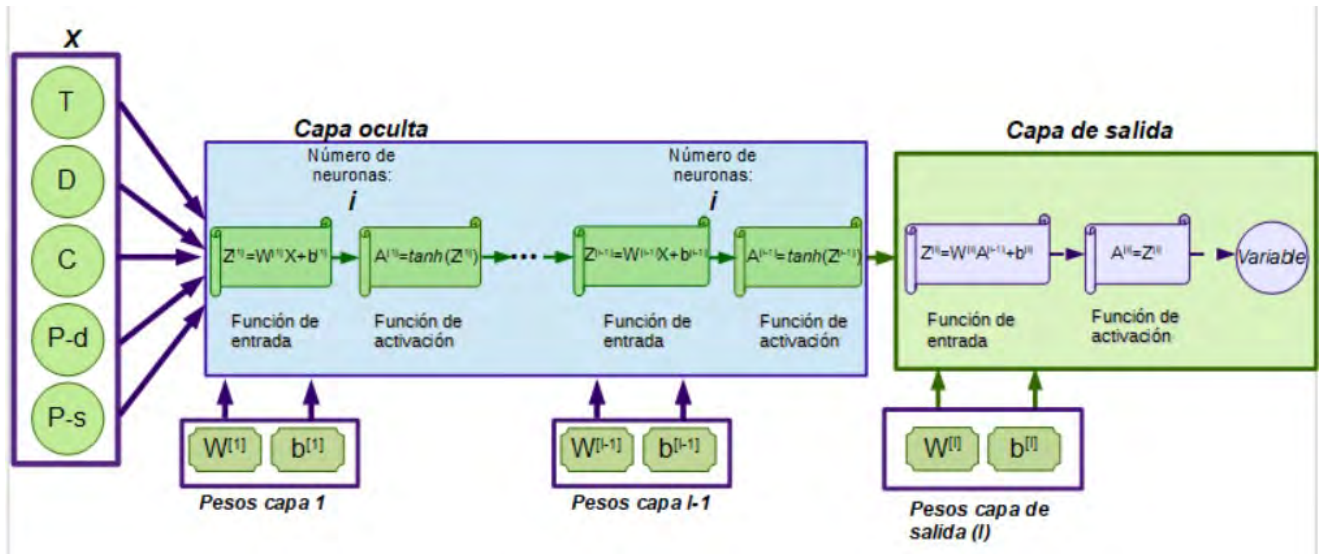


Figura 4.9: Esquema de la propuesta de arquitectura final.

### 4.3. Método de entrenamiento de la red

El algoritmo de entrenamiento de la red utilizando es el método de retroalimentación hacia atrás con el método iterativo “descenso por gradiente” [Andrew, 2019, Andrew et al., 2019c]. Este método hace uso de las derivadas parciales de la función de error con respecto a los parámetros de peso utilizados en la red. Asimismo, este método toma los resultados obtenidos de la propagación hacia delante (Figura 4.9) y utiliza las derivadas para obtener los nuevos valores de las matrices de peso ( $W^{[n]}$ ) y los vectores bias ( $b^{[n]}$ ). En la Figura 4.10 se muestra el diagrama de flujo utilizado para el entrenamiento de la segunda versión de la arquitectura, mientras que la Figura 4.11 presenta el diagrama de flujo del entrenamiento utilizado para la tercera versión arquitectura.

En la Figura 4.11 se pueden observar dos diferencias con respecto a la Figura 4.10. La primer diferencia es que se agregó el término de regularización en la función de error, lo cual se debe a que esta es una medida que puede reducir un sub-ajuste

de la red neuronal. La segunda diferencia es que se agregaron los términos para cuando se tiene más de una capa oculta.

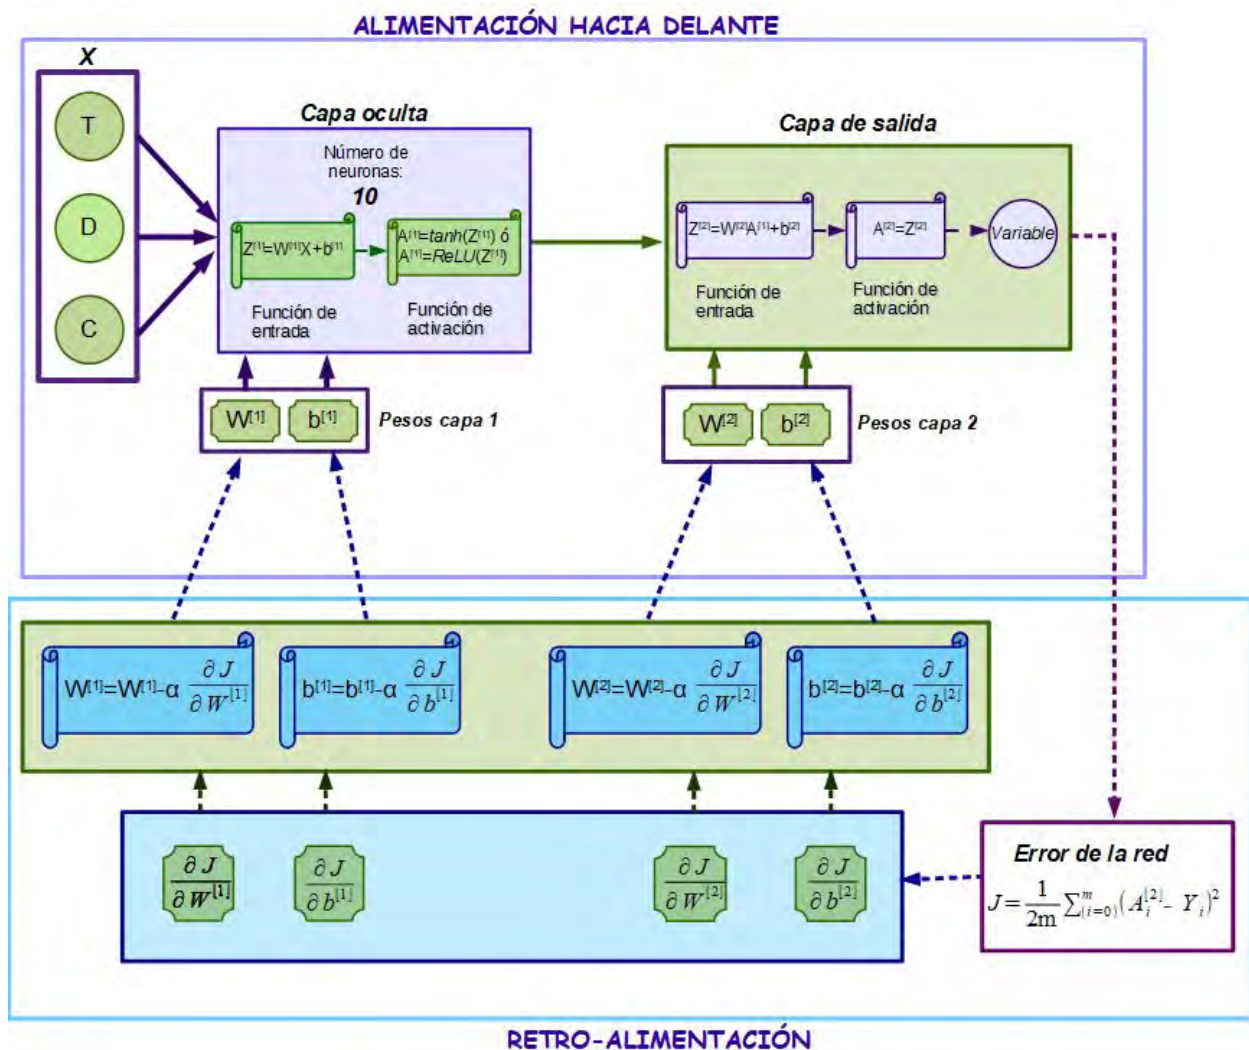


Figura 4.10: Diagrama de flujo del entrenamiento de la red para la segunda versión de la arquitectura.

Como ya se mencionó anteriormente, el método iterativo utilizado para el entrenamiento de la red es el de descenso de gradiente, el cual utiliza derivadas de la función de error ( $J$ ) con respecto a los pesos ( $W^{(2)}$ ) y los bias ( $b^{(2)}$ ). Las derivadas se obtienen utilizando la regla de la cadena. Las ecuaciones (4.5)-(4.13) representan las derivadas empleadas en el entrenamiento [Andrew, 2019, Andrew et al., 2019c].

$$\frac{\partial J}{\partial Z^{[l+1]}} = dZ^{[l+1]} = \sum_{i=0}^m [(A^{[l+1]} - Y)] \quad (4.5)$$

$$\begin{aligned} \frac{\partial J}{\partial W^{[l+1]}} &= \frac{\partial J}{\partial Z^{[l+1]}} \frac{\partial Z^{[l+1]}}{\partial W^{[l+1]}} + \frac{\lambda}{2m} \frac{\partial}{\partial W^{[l+1]}} \left[ \sum_i \sum_j \sum_k W_{j,k}^{[i]^2} \right] = \\ &= \frac{1}{m} \left\{ dZ^{[l+1]} A^{[l]} + \lambda \sum_j \sum_k W_{j,k}^{[l+1]} \right\} \end{aligned} \quad (4.6)$$

$$\frac{\partial J}{\partial b^{[l+1]}} = \frac{1}{m} \left\{ dZ^{[l+1]} \right\} \quad (4.7)$$

$$\frac{\partial J}{\partial Z^{[l]}} = dZ^{[l]} = dZ^{[l+1]} \frac{\partial Z^{[l+1]}}{\partial A^{[l]}} \frac{\partial A^{[l]}}{\partial Z^{[l]}} = dZ^{[l+1]} W^{[l+1]} (1 - A^{[l]^2}) \quad (4.8)$$

$$\begin{aligned} \frac{\partial J}{\partial W^{[l]}} &= \frac{\partial J}{\partial Z^{[l]}} \frac{\partial Z^{[l]}}{\partial W^{[l]}} + \frac{\lambda}{2m} \frac{\partial}{\partial W^{[l]}} \left[ \sum_i \sum_j \sum_k W_{j,k}^{[i]^2} \right] = \\ &= \frac{1}{m} \left\{ dZ^{[l]} A^{[l-1]} + \lambda \sum_j \sum_k W_{j,k}^{[l]} \right\} \end{aligned} \quad (4.9)$$

$$\frac{\partial J}{\partial b^{[l+1]}} = \frac{1}{m} \left\{ dZ^{[l]} \right\} \quad (4.10)$$

⋮

$$\frac{\partial J}{\partial Z^{[1]}} = dZ^{[1]} = dZ^{[2]} \frac{\partial Z^{[2]}}{\partial A^{[1]}} \frac{\partial A^{[1]}}{\partial Z^{[1]}} = dZ^{[2]} W^{[2]} (1 - A^{[1]^2}) \quad (4.11)$$

$$\frac{\partial J}{\partial W^{[1]}} = \frac{\partial J}{\partial Z^{[1]}} \frac{\partial Z^{[1]}}{\partial W^{[1]}} + \frac{\lambda}{2m} \frac{\partial}{\partial W^{[1]}} \left[ \sum_i \sum_j \sum_k W_{j,k}^{[i]2} \right] =$$

$$= \frac{1}{m} \left\{ dZ^{[1]} X + \lambda \sum_j \sum_k W_{j,k}^{[1]} \right\} \quad (4.12)$$

$$\frac{\partial J}{\partial b^{[1]}} = \frac{1}{m} \left\{ dZ^{[1]} \right\} \quad (4.13)$$

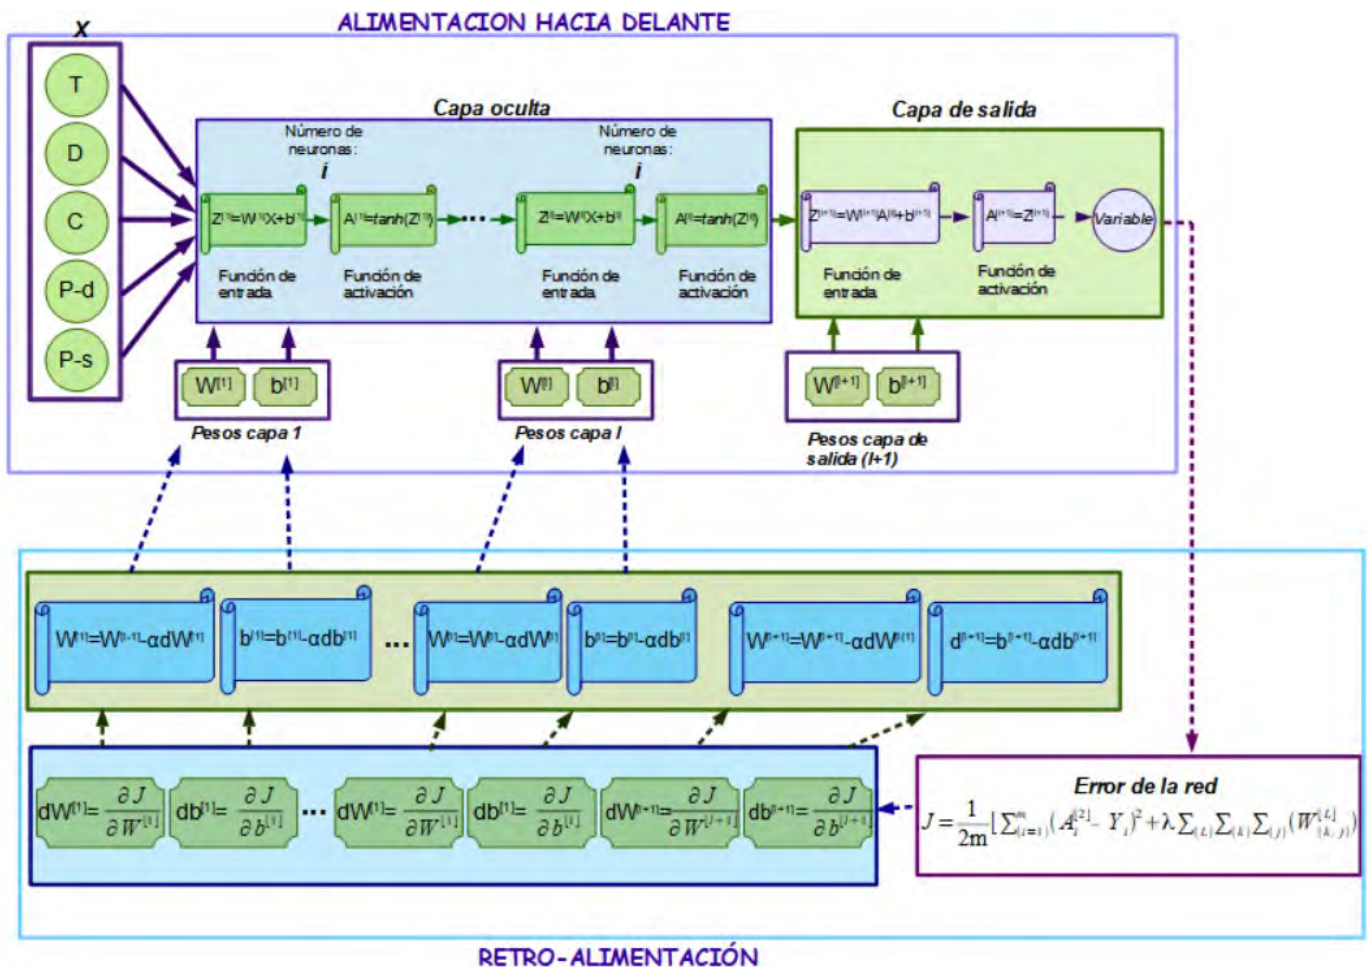


Figura 4.11: Diagrama de flujo del entrenamiento de la red para la arquitectura final.

En la Figura 4.12 se muestra la función de error de las cuatro redes neuronales



en función del número de iteraciones, con el fin de ver si el método converge. El método necesita menos de 100 iteraciones para converger en las cuatro redes, por lo que se considera que es el método adecuado para este trabajo.




Figura 4.12: Gráficas de convergencia el método de entrenamiento para (a)  $R_w$ , (b)  $R_v$ , (c)  $LCS$  y (d)  $PB$ .

# CAPÍTULO 5

## DESEMPEÑO DE LAS REDES NEURONALES

En éste capítulo se optimizan las cuatro redes neuronales tomando en cuenta el dimensionamiento de la base de datos, el valor del parámetro de regularización y la arquitectura de las redes. También se presentan las verificaciones de las *ANN* y su desempeño al compararlas con el método de optimización variacional.

### 5.1. Optimización de las redes neuronales

Con el fin de encontrar las redes neuronales adecuadas para las cuatro variables se realizaron tres análisis:

1. El dimensionamiento de la base de datos, que evalúa las curvas de error vs número de datos para determinar si es necesario o no aumentar los ejemplos para el entrenamiento.
2. La designación del parámetro de regularización( $\lambda$ ), en este análisis se evalúa el desempeño de la red con diferentes valores del parámetro de regularización.
3. La selección de la arquitectura de la red neuronal, donde se realiza una evaluación del desempeño de las redes al variar el número de neuronas por capa oculta y el número de capas ocultas.

Una vez realizados los puntos anteriores se procede a la validación de las *ANN* seleccionadas, seguido de la evaluación del desempeño de las redes con respecto a un método convencional.

#### 5.1.1. Dimensionamiento de la base de datos

La determinación de las dimensiones de la base de datos para entrenar las cuatro *ANN* se realizó con el método de curvas de aprendizaje, que consiste en observar y evaluar el comportamiento de los errores obtenidos en el entrenamiento y en la prueba al variar  $m$  (número de ejemplos utilizado en la base de datos) [Andrew, 2019, Andrew et al., 2019c].

En la Figura 5.11 se presentan las curvas de aprendizaje para las cuatro *ANN*. En las cuatro redes el valor del parámetro de regularización se designó como cero y se estableció una arquitectura con una capa oculta y diez neuronas. A partir de las gráficas mostradas en la Figura, se determinó que el aumento de número de ejemplos a partir de los 1000 datos no afecta de manera significativa el desempeño de las redes neuronales. También se observa que los valores del error en el entrenamiento y en la prueba son prácticamente iguales, con diferencias menores a 0.005. Por lo tanto, el aumento de datos utilizados en el entrenamiento no tiene un efecto significativo en el desempeño de la red. Por otra parte, los valores de  $J_{train}$  y  $J_{test}$  son similares para las cuatro redes a partir de los 1000 ejemplos, lo que implica un sub-ajuste de las redes neuronales a la base de datos. Este sub-ajuste puede ser reducido con una regularización o aumentando el número de neuronas y/o capas ocultas de las redes neuronales [Andrew et al., 2019a].




Figura 5.1: Gráficas dimensionamiento de la base de datos para las redes neuronales de (a)  $R_w$ , (b)  $R_v$ , (c)  $LCS$  y (d)  $PB$ .

### 5.1.2. Designación del parámetro de regularización

El uso de la regularización en el entrenamiento de la red puede ayudar a mejorar el desempeño de la red, sin embargo, también puede tener un impacto negativo [Andrew et al., 2019c,a]. Es importante hacer un análisis gráfico para determinar  $\lambda$  y obtener la red neuronal adecuada para nuestro problema. Teniendo esto en cuenta, los valores de los errores  $J_{train}$  y  $J_{test}$  fueron graficados al variar el valor de  $\lambda$ .

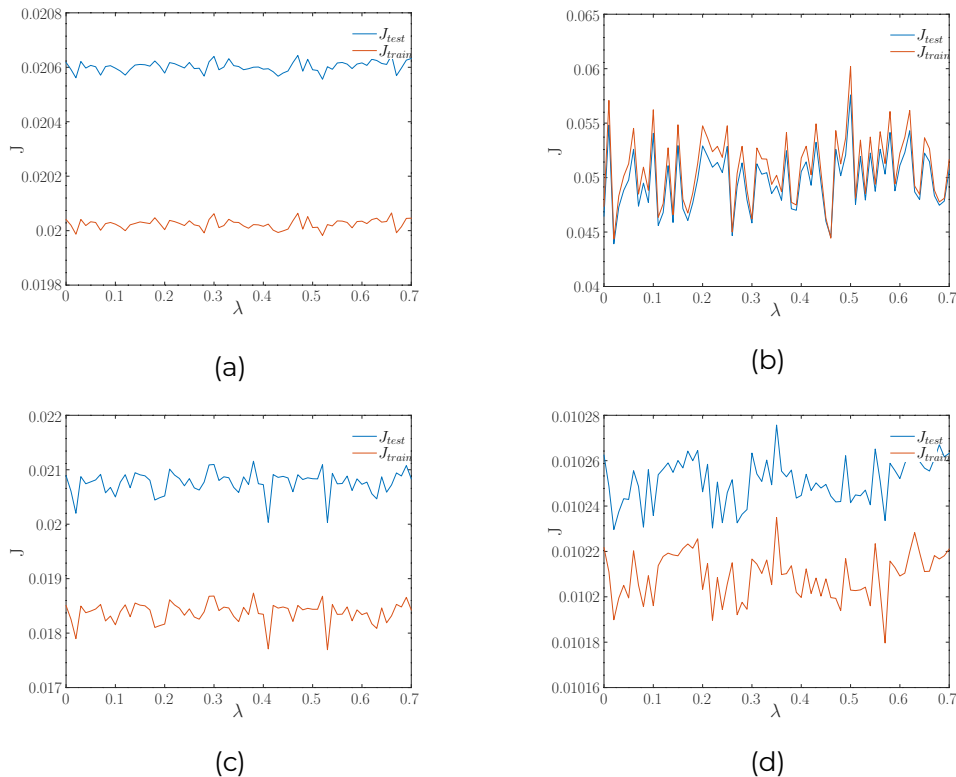


Figura 5.2: Gráficas de  $\lambda$  vs  $J_{train}$  y  $J_{test}$  para las redes neuronales de (a)  $R_u$ , (b)  $R_v$ , (c)  $LCS$  y (d)  $PB$ .

En la Figura 5.2 se muestran las gráficas de los errores  $J_{train}$  y  $J_{test}$  en función de  $\lambda$  para las cuatro redes neuronales, con una arquitectura con 10 neuronas en una capa oculta. En las cuatro gráficas los valores de los parámetros fluctúan al variar  $\lambda$ , sin embargo, en estas redes el impacto proporcionado por la regularización es despreciable. Por lo tanto, se determinó que el valor óptimo de  $\lambda$  es cero, ya que la regularización implica el aumento de tiempo de cómputo y dado que no se encontró un efecto positivo considerable.

### 5.1.3. Selección de la arquitectura de la red neuronal

La selección de la arquitectura de la red neuronal, al igual que en las secciones anteriores, implicó el uso del método gráfico. En esta sección los errores  $J_{train}$  y  $J_{test}$  fueron graficados al variar el número de neuronas. Al inicio del análisis se observó que el aumento del número de capas no afecta de manera significativa el desempeño de las redes. Sin embargo, sí aumenta considerablemente el tiempo de cómputo, por lo que se determinó una capa oculta para realizar las gráficas.

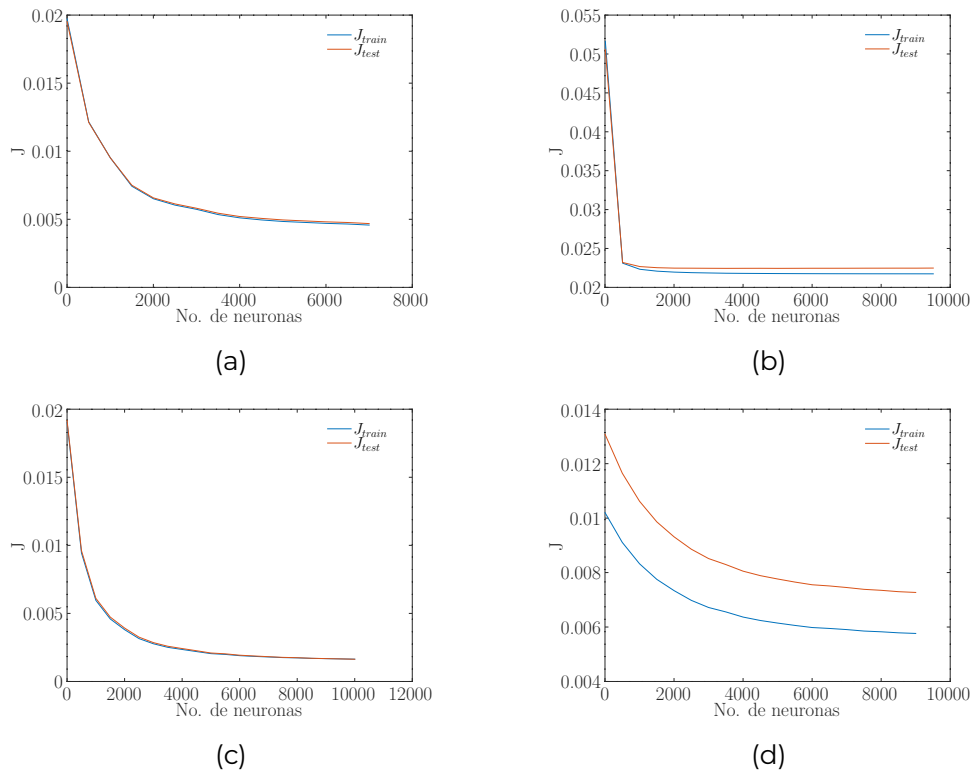


Figura 5.3: Gráficas de número de neuronas vs  $J_{train}$  y  $J_{test}$  para las redes neuronales de (a)  $R_w$ , (b)  $R_v$ , (c)  $LCS$  y (d)  $PB$ .

En la Figura 5.3 se muestran las gráficas de los errores  $J_{train}$  y  $J_{test}$  en función del número de neuronas en una capa oculta. Las gráficas presentaron un comportamiento de  $J_{train}$  y  $J_{test}$  de la forma  $y = a + \frac{b}{x^2}$  en función al número de neuronas. En las gráficas 5.3c y 5.3d los valores de los errores dejan de cambiar de manera significativa a partir de las 6000 neuronas. Por lo que para los  $LCS$  y el  $PB$  la arquitectura resultante es de una capa oculta con 6000 neuronas, sin regularización. En la gráfica 5.3b se muestra el comportamiento de la red neuronal para la salida de

la razón volumétrica, a partir de la cual se determina que la red neuronal para  $R_v$  es de una capa oculta con 1000 neuronas sin regularización. A partir de la Figura 5.3a se determinó la arquitectura de 4,000 neuronas con una capa oculta sin regularización para la  $R_u$ . Es de resaltar que la optimización del número de neuronas tiene un impacto de hasta el 128 % en el desempeño de las neuronas.

## 5.2. Verificación de la red neuronal mediante análisis estadísticos

El  $MSE$  se utilizó como parámetro comparativo entre los datos de salida de las  $ANN$  y los datos asignados de la base de datos, para la verificación de las cuatro  $ANN$ . La verificación de las cuatro  $ANN$  implicó el uso del 5 % de la base de datos generada, en concordancia con [Russell and Norvig, 2016, Andrew et al., 2019a, Andrew, 2019, Andrew et al., 2019b,c]. Los datos de verificación corresponden a ejemplos que la  $ANN$  no conoce, ya que no se utilizaron en ninguna de las tres etapas de optimización, (dimensionamiento, designación de parámetro de regularización y selección de arquitectura de la red). En la Figura 5.4 se presenta el comparativo de los datos de salida de las redes y los datos asignados de la base de datos, el comparativo corresponde a las cuatro  $ANN$ , el inciso (a) para la  $R_u$ , (b) para  $R_v$ , (c) para los  $LCS$  y el (d) para el  $PB$ , donde los puntos azules son los valores de la base de datos y los rojos son los determinados con la respectiva red neuronal. Los datos presentados en la columna de entrenamiento corresponden a los utilizados en esta etapa del desarrollo de las  $ANN$ , que corresponde al 90 % de la base de datos. Cabe resaltar que todos los valores de las variables, tanto dependientes como independientes, fueron normalizados con el fin de entrenar las  $ANN$ , por lo que la Figura los presenta de esta manera.

El  $MSE$  de la  $R_u$  para el entrenamiento, prueba y verificación fue de 0.010002, 0.011025 y 0.011275 respectivamente; para la  $R_v$  de 0.046645, 0.056421 y 0.047555; para los  $LCS$  de 0.003844, 0.003750 y 0.003756; mientras que para el  $PB$  de 0.012412, 0.013032 y 0.0074209. La  $ANN$  de la  $R_v$  resultó con el menor desempeño, que se puede deber al carácter discontinuo de los datos ya que únicamente la base de datos presenta cinco valores de  $R_v$ , como se muestra en 5.4b. En general, las cuatro  $ANN$  presentan valores de  $MSE$  similares en el entrenamiento, prueba y verificación, con diferencias menores a 0.001 considerándose así que el modelo de  $ANN$  es adecuado.

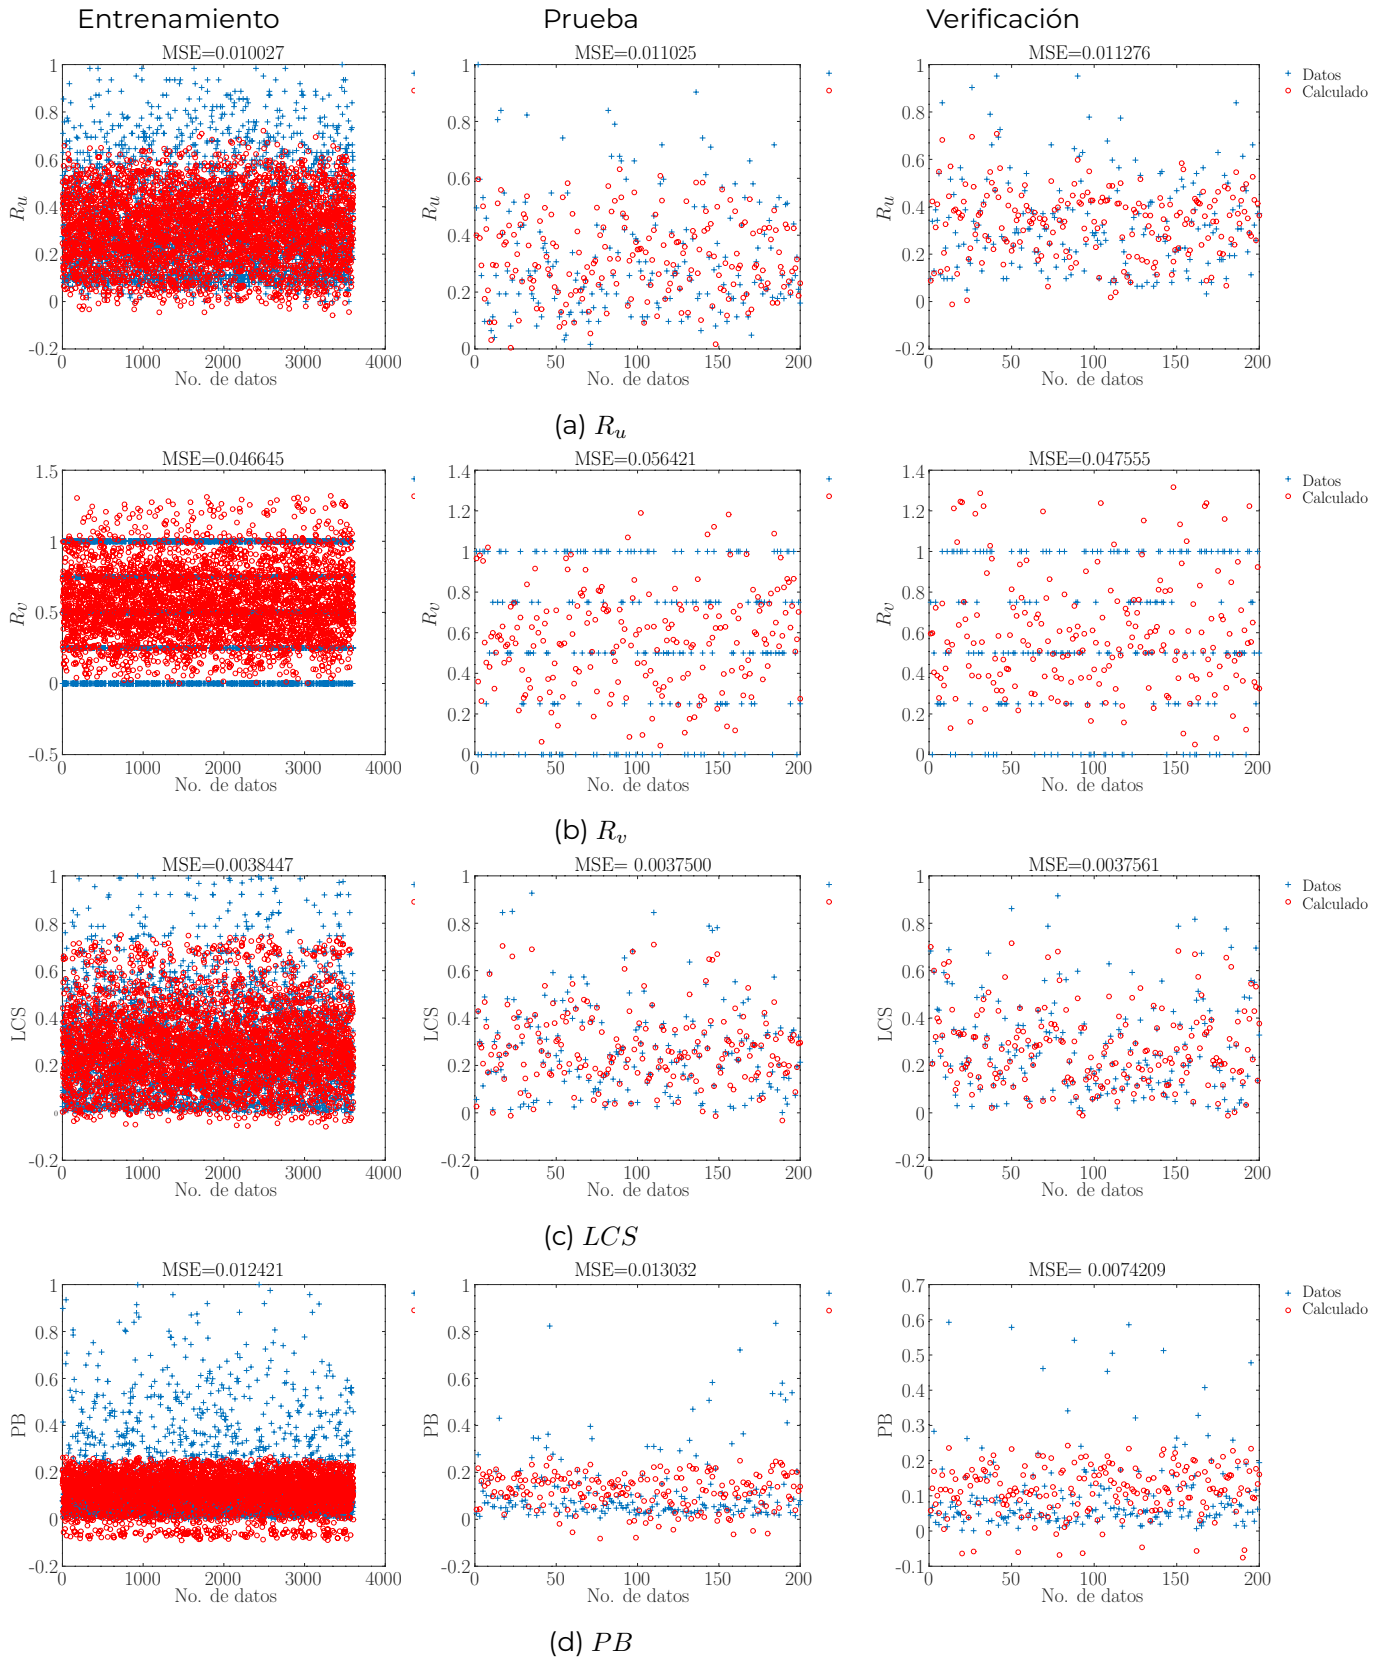


Figura 5.4: Comparación de la base de datos vs los datos calculados por las redes neuronales.

### 5.3. Desempeño de la red neuronal

El desempeño de la red neuronal se evalúa con el tiempo de cómputo, el número de entradas y la cantidad de conocimientos necesarios para llevar a cabo la optimización.

#### 5.3.1. Tiempo de cómputo

En la Tabla 5.1 se presentan los valores obtenidos del tiempo de cómputo de los dos métodos. El tiempo empleado en la simulación para la construcción de la base de datos que se utilizó en el entrenamiento, optimización y verificación de las redes fue de 13 *semanas*, exceptuando el tiempo empleado en la construcción y verificación de las plataformas de simulación térmica y económica utilizados en el método variacional. El tiempo empleado para la construcción y verificación de estas plataformas fue de 9 *semanas*, mientras que para las redes neuronales fue de 7 *semanas*, lo que representa un 78 % del tiempo empleado respecto al método variacional.

Tabla 5.1: Comparación de tiempo de cómputo para la optimización del método de redes neuronales con el método variacional.

	Redes neuronales	Método Variacional	Equivalencia porcentual
Tiempo de construcción y verificación	7 <i>semanas</i>	9 <i>semanas</i>	78
Tiempo de optimización del método	5 h 13 min 47 s	-	-
Tiempo de entrenamiento	1 h 20 min 4 s	-	-
Tiempo de optimización de un sistema	2 s	1683 s	0.12

El tiempo de optimización de cada una de las cuatro redes neuronales fue de 5 h con 13 min con 47 s. Cada una de las cuatro redes neuronales tomaron 1 hora, 20 minutos y 4 segundos en ser entrenadas. El tiempo de cómputo empleado para cada posible condición de diseño fue de 28 minutos con 3 segundos, sin considerar los errores en el suministro de datos al programa. Mientras que el tiempo de cómputo



empleado con redes neuronales fue de cuatro segundos, lo que representa únicamente el 0.12 % del tiempo requerido para realizar la optimización utilizando el método variacional. Con lo anterior, se observa que el uso de redes neuronales reduce considerablemente el tiempo de cómputo para hacer la optimización de un sistema de calentamiento solar, una vez ya entrenada la red.

### **5.3.2. Número de entradas**

En la optimización con redes neuronales, el número de entradas es el 26 % respecto al método variacional, donde se requieren 19 entradas, que son: datos meteorológicos de la ciudad de estudio, características del colector, bombas hidráulicas, tanque de almacenamiento e intercambiadores de calor seleccionados, la temperatura requerida, la demanda de agua diaria del proceso, el perfil de carga diario y semanal, así como también las entradas económicas presentadas en la Tabla 3.5. Por su parte, el cálculo con redes neuronales requiere sólo de 5 entradas, que son el lugar de estudio, la temperatura requerida, la demanda de agua, el perfil diario y el perfil semanal. Así, se puede decir que la optimización de un sistema de calentamiento solar con redes neuronales requiere considerablemente menos entradas que el método de optimización variacional.

### **5.3.3. Habilidades para la optimización**

Una vez ya entrenadas las redes neuronales, la cantidad de habilidades requeridas para realizar la optimización del sistema de calentamiento solar son el manejo de requerimientos en la industria, y el manejo básico de sistemas de cómputo. Por su parte, el método variacional requiere de conocimiento de energía solar, generación de calor, transferencia de calor, termodinámica, programación, optimización, análisis económico y los requerimientos de la industria, además de alto grado de *expertise* en programación y manejo de sistemas de cómputo. Es hacer notar que el método de optimización con redes neuronales requiere de personal con nivel técnico, mientras que el uso del método variacional requiere de personal altamente capacitado de nivel maestría o mayor.

# CAPÍTULO 6

## CONCLUSIONES Y RECOMENDACIONES PARA TRABAJOS FUTUROS

### 6.1. Conclusiones

#### ***Método de optimización con la red neuronal:***

- \* Una vez ya entrenada la red neuronal, el tiempo de cómputo para la optimización de sistemas de calentamiento solar con redes neuronales representa únicamente el 0.12% del tiempo de cómputo utilizado con el método variacional.
- \* La optimización con redes neuronales requiere del 26% de las entradas requeridas para el cálculo con el método variacional.
- \* El método de optimización con redes neuronales requiere de personal con nivel técnico, mientras que el uso del método variacional requiere de personal altamente capacitado de nivel maestría o mayor.
- \* El uso de redes neuronales para la optimización de sistemas de calentamiento solar presenta un desempeño adecuado para el cálculo de la  $R_u$ , la  $R_v$ , los  $LCS$ , y el  $PB$ , al utilizar una red neuronal para calcular cada variable. El error medio cuadrático de los  $LCS$  para el entrenamiento, prueba y verificación fue de 0.003844, 0.003750 y 0.003756 respectivamente; para el  $PB$  de 0.012412, 0.013032 y 0.0074209; para  $R_u$  de 0.010002, 0.011025 y 0.011275; mientras que para el  $R_v$  fueron de 0.046645, 0.056421 y 0.047555.
- \* Campeche es la ciudad con mayores ahorros solares y Ecatepec la ciudad con los menores. Asimismo, los casos en el que se trabajan todos los días del año muestran mejores resultados de LCS y PB, que los casos en los que sólo se trabajan 5 días a la semana.

### **Base de datos:**

- \* La  $R_u$ , la  $R_v$ , los  $LCS$  y el  $PB$  muestran similar comportamiento cuando se cambia  $D$ ,  $T$ ,  $C$  y el perfil de carga.
- \* Las cuatro variables dependientes tienen la menor correlación con la ciudad. La  $R_u$  muestra una mayor correlación con la temperatura del proceso mientras que la  $R_v$ , los  $LCS$  y el  $PB$  presentan una mayor correlación con la demanda diaria de agua. Lo que implica que  $T$  y la  $D$  son las variables independientes con mayor importancia para el cálculo de las variables dependientes.
- \* Los valores de las medias llegan a tener diferencias porcentuales al variar el perfil de carga de hasta 26.44 % para las  $R_u$ , 60.64 % para las  $R_v$ , 305.23 %, para los  $LCS$  y 41.78 % para el  $PB$ .

### **Optimización de la Red neuronales:**

- \* La cantidad mínima de datos es de mil ejemplos, para asegurar el desempeño adecuado de la red.
- \* La optimización de la arquitectura de la red neuronal afecta hasta en un 128 % el desempeño de la red neuronal. La arquitectura óptima de las redes neuronales es de una capa oculta sin regularización con 4000 neuronas para la  $R_u$ , 1000 neuronas para la  $R_v$  y 6000 neuronas para los  $LCS$  y el  $PB$ .
- \* El método de entrenamiento de propagación hacia atrás, con el método iterativo de gradiente de descenso, es adecuado para este problema ya que converge con menos de 600 iteraciones.

## **6.2. Recomendaciones para trabajos futuros**

1. Utilizar y comparar el desempeño de las redes neuronales con ejemplos optimizados existentes.
2. Hacer uso del algoritmo genético para mejorar el desempeño de las redes neuronales.
3. Aumentar el número de ciudades y perfiles de carga para entrenar la red neuronal.
4. Aumentar el tipo de tecnologías utilizadas en la generación de la base de datos, y agregar esta variable como variable de entrada.

5. Probar el desempeño de una red neuronal de selección múltiple para el cálculo de la  $R_v$ .
6. Generar una base de datos con datos experimentales para la validación de las redes neuronales.
7. Proponer diferentes parámetros económicos, haciendo uso de métodos estadísticos, para la predicción de años futuros del costo de combustible fósil, inflación, etc.

- MJR Abdunnabi, KMA Alakder, NA Alkishriwi, and SM Abughres. Experimental validation of forced circulation of solar water heating systems in trnsys. *Energy Procedia*, 57:2477–2486, 2014.
- A Acir, ME Canlı, İ Ata, and R Çakıroğlu. Parametric optimization of energy and exergy analyses of a novel solar air heater with grey relational analysis. *Applied Thermal Engineering*, 122:330–338, 2017.
- AEE. Ship plants database. <http://ship-plants.info>, Accesado: 2019-04, 2019.
- A Allouhi, Y Agrouaz, Mohammed Benzakour Amine, S Rehman, MS Buker, T Kousksou, A Jamil, and A Benbassou. Design optimization of a multi-temperature solar thermal heating system for an industrial process. *Applied Energy*, 206:382–392, 2017.
- MB Ammar, M Chaabene, and Z Chtourou. Artificial neural network based control for pv/t panel to track optimum thermal and electrical power. *Energy conversion and management*, 65:372–380, 2013.
- DR Anderson, DJ Sweeney, and TA Williams. *Estadística para negocios y economía*. Cengage Learning, 2016.
- N Andrew. Machine learning. <https://www.coursera.org/learn/machine-learning/home/welcome>, Accesado: 2019-11, 2019.
- N Andrew, K Katanforoosh, and BY Mourri. Improving deep neural networks: Hyperparameter tuning, regularization and optimization. <https://www.coursera.org/learn/deep-neural-network/home/welcome>, Accesado: 2019-12, 2019a.
- N Andrew, K Katanforoosh, and BY Mourri. Neural networks and deep learning. <https://www.coursera.org/learn/neural-networks-deep-learning/home/welcome>, Accesado: 2019-11, 2019b.

- N Andrew, K Katanforoosh, and BY Mourri. Structuring machine learning projects. <https://www.coursera.org/learn/machine-learning-projects/home/welcome>, Accesado: 2019-12, 2019c.
- JG Arcos-Adame. Dimensionamiento de sistemas de precalentamiento solar de agua para calderas utilizando energía solar y almacenamiento térmico. Tesis de Maestría en Ciencias en Ingeniería Mecánica, Cuernavaca, Mor, Centro Nacional de Investigación y Desarrollo Tecnológico, 2018.
- LM Ayompe, A Duffy, SJ McCormack, and M Conlon. Validated trnsys model for forced circulation solar water heating systems with flat plate and heat pipe evacuated tube collectors. *Applied Thermal Engineering*, 31(8-9):1536–1542, 2011.
- A Baniassadi, M Momen, and M Amidpour. A new method for optimization of solar heat integration and solar fraction targeting in low temperature process industries. *Energy*, 90:1674–1681, 2015.
- R Banos, F Manzano-Agugliaro, FG Montoya, C Gil, A Alcayde, and J Gómez. Optimization methods applied to renewable and sustainable energy: A review. *Renewable and Sustainable Energy Reviews*, 15(4):1753–1766, 2011.
- R Barrera-Ayar. Diseño de un sistema de captación solar de mediana temperatura. Tesis de Maestría en Ciencias en Ingeniería Mecánica, Cuernavaca, Mor, Centro Nacional de Investigación y Desarrollo Tecnológico, 2017.
- T Bouhal, Y Agrouaz, A Allouhi, A Kousksou, y; Jamil, Rhafiki T El, and Y Zeraouli. Impact of load profile and collector technology on the fractional savings of solar domestic water heaters under various climatic conditions. *International Journal of Hydrogen Energy*, 42(18):13245–13258, 2017.
- T Bouhal, F Gargab, A Jamil, T Kousksou, and A Benbassou. Design and thermal performance optimization of a forced collective solar hot water production system in morocco for energy saving in residential buildings. *Solar Energy*, 160: 260–274, 2018.
- TE Boukelia, O Arslan, and MS Mecibah. Ann-based optimization of a parabolic trough solar thermal power plant. *Applied Thermal Engineering*, 107:1210–1218, 2016.
- Y A Çengel and MA Boles. *Termodinámica (8a.* McGraw Hill Mexico, 2015.

- LA Cruz-Pinuelas. Perfiles de carga en el desempeño de sistemas de precalentamiento solar de agua para calderas. Tesis de Maestría en Ciencias en Ingeniería Mecánica, Cuernavaca, Mor, Centro Nacional de Investigación y Desarrollo Tecnológico, 2019.
- Equipo de Energía INDAP-Nivel Central. Recurso solar y uso del explorador solar. Reporte del taller de sistemas fotovoltaicos-equipos técnicos <https://www.indap.gob.cl/docs/default-source/default-document-library/ppt-3-recurso-solar.pdf?sfvrsn=0>, Accesado: 2020-07, 2018.
- JA Duffie, WA Beckman, and WM Worek. *Solar engineering of thermal processes*, volume 3. Wiley Online Library, 2013.
- HK Ghrilahre and RK Prasad. Application of ann technique to predict the performance of solar collector systems-a review. *Renewable and Sustainable Energy Reviews*, 84:75–88, 2018.
- JG Gomila-Salas. Curso completo de machine learning: Data science en python. <https://www.udemy.com/course/machinelearningpython/>, Accesado: 2020-4, 2020.
- ML González-Osorio and A Beele. Estudio de caracterización del uso de aire acondicionado en vivienda de interés social, 2016.
- M Hazami, N Naili, I Attar, and A Farhat. Solar water heating systems feasibility for domestic requests in tunisia: Thermal potential and economic analysis. *Energy Conversion and Management*, 76:599–608, 2013.
- YL He, DH Mei, WQ Tao, WW Yang, and HL Liu. Simulation of the parabolic trough solar energy generation system with organic rankine cycle. *Applied Energy*, 97: 630–641, 2012.
- A Helmke, S Hess, and W Platzer. Suggestion for Reference Cases Subtask C2 Simulation. *Integration Guideline. IEA SHC Task*, 49:1–16, 2015.
- A Hobbi and K Siddiqui. Optimal design of a forced circulation solar water heating system for a residential unit in cold climate using trnsys. *Solar Energy*, 83: 700–714, 2009.
- INEGI. Producto interno bruto por entidad federativa 2017. <https://www.inegi.org.mx/contenidos/saladeprensa/boletines/2018/0trTemEcon/PIBEntFed2017.pdf>, Accesado: 2019-03, 2018.

- H Jannesari and B Babaei. Optimization of solar assisted heating system for electro-winning process in the copper complex. *Energy*, 158:957–966, 2018.
- SA Kalogirou. Artificial neural networks for predicting the local concentration ratio of parabolic trough collectors. *EuroSun Conference*, 1996.
- SA Kalogirou. Optimization of solar systems using artificial neural-networks and genetic algorithms. *Applied Energy*, 77(4):383–405, 2004.
- SA Kalogirou. Use of artificial intelligence for the optimal design of solar systems. *International Journal of Computer Applications in Technology*, 22(2/3):90–103, 2005.
- SA Kalogirou, S Panteliou, and A Dentsoras. Modeling of solar domestic water heating systems using artificial neural networks. *Solar Energy*, 65(6):335–342, 1999.
- SA Kalogirou, S Lalot, G Florides, and B Desmet. Development of a neural network-based fault diagnostic system for solar thermal applications. *Solar Energy*, 82(2):164–172, 2008.
- SA Kalogirou, E Mathioulakis, and V Belessiotis. Artificial neural networks for the performance prediction of large solar systems. *Renewable Energy*, 63:90–97, 2014.
- S Lugo, O García-Valladares, R Best, J Hernández, and F Hernández. Numerical simulation and experimental validation of an evacuated solar collector heating system with gas boiler backup for industrial process heating in warm climates. *Renewable Energy*, 139:1120–1132, 2019.
- Wolfram Mathworld. Sigmoid function. <http://mathworld.wolfram.com/SigmoidFunction.html>, Accesado: 2020-02, 2020.
- B Muster, IB Hassine, A Helmke, S Heß, P Krummenacher, B Schmitt, and H Schnitzer. Solar process heat for production and advanced applications. *Integration Guideline. IEA SHC Task*, 49, 2015.
- H Ortega. Energía solar térmica para procesos industriales en México, estudio de mercado. Reporte de trabajo, [https://www.giz.de/en/downloads/EnergiaSolarTermica\\_02\\_LOWRES.pdf](https://www.giz.de/en/downloads/EnergiaSolarTermica_02_LOWRES.pdf), Accesado: 2018-08, SENER, CONUEE, ANES, cooperación akemana, 2018.



- Solar Payback. Calor solar para la industria México. Reporte de trabajo, [https://www.solar-payback.com/wp-content/uploads/2018/06/Solar-Payback\\_Calor-Solar-para-la-Industria\\_Mexico.pdf](https://www.solar-payback.com/wp-content/uploads/2018/06/Solar-Payback_Calor-Solar-para-la-Industria_Mexico.pdf), Accesado: 2018-09, 2018.
- EV Pérez-Grajales. Simulación de sistemas de aprovechamiento de la energía solar. Reporte de residencias en Centro Nacional de Investigación y Desarrollo Tecnológico, Instituto Tecnológico de Tuxtla Gutiérrez, 2015.
- W Platzer. Overview and description of simulation tools for solar industrial process heat systems. *Integration Guideline. IEA SHC Task, 49*, 2015.
- JA Quijera, M Alriols-González, and Labidi J. Integration of a solar thermal system in canned fish factory. *Applied Thermal Engineering*, 70(2):1062–1072, 2014. ISSN 13594311.
- SJ Ramírez-Martínez. Precalentamiento de agua solar para suministro de agua en calderas. Tesis de Maestría en Ciencias en Ingeniería Mecánica, Cuernavaca, Mor, Centro Nacional de Investigación y Desarrollo Tecnológico, 2019.
- SJ Russell and P Norvig. *Artificial intelligence: a modern approach*. Malaysia; Pearson Education Limited, 2016.
- R Silva, M Berenguel, M Pérez, and A Fernández-García. Thermo-economic design optimization of parabolic trough solar plants for industrial process heat applications with memetic algorithms. *Applied Energy*, 113:603–614, 2014.
- R Tang, Y Yang, and W Gao. Comparative studies on thermal performance of water-in-glass evacuated tube solar water heaters with different collector tilt-angles. *Solar Energy*, 85(7):1381–1389, 2011.
- Z Tian, B Perers, S Furbo, and J Fan. Thermo-economic optimization of a hybrid solar district heating plant with flat plate collectors and parabolic trough collectors in series. *Energy Conversion and Management*, 165:92–101, 2018.
- JP Vargas-Bautista, AJ García-Cuéllar, SL Pérez-García, and CI Rivera-Solorio. Transient simulation of a solar heating system for a small-scale ethanol-water distillation plant: Thermal, environmental and economic performance. *Energy Conversion and Management*, 134:347–360, 2017.
- W Yaïci and E Entchev. Performance prediction of a solar thermal energy system using artificial neural networks. *Applied Thermal Engineering*, 73(1):1348–1359, 2014.

W Yaïci and E Entchev. Adaptive neuro-fuzzy inference system modelling for performance prediction of solar thermal energy system. *Renewable Energy*, 86: 302–315, 2016.

# Anexo A

## Recurso solar

La temperatura promedio y la irradiación solar promedio diario directa, difusa y global fueron calculadas y evaluadas para Ecatepec de Morelos, Monterrey y Campeche. La evaluación se realizó manejando los datos meteorológicos, obtenidos a partir de METEONORM, con el software TRNSYS, las variables se consideraron de manera horaria y se integraron anual y mensualmente. Las irradiaciones promedio diaria directas de las diferentes localidades fueron comparadas con el espectro de irradiación total en México, el cual se muestra en la Figura A.1.

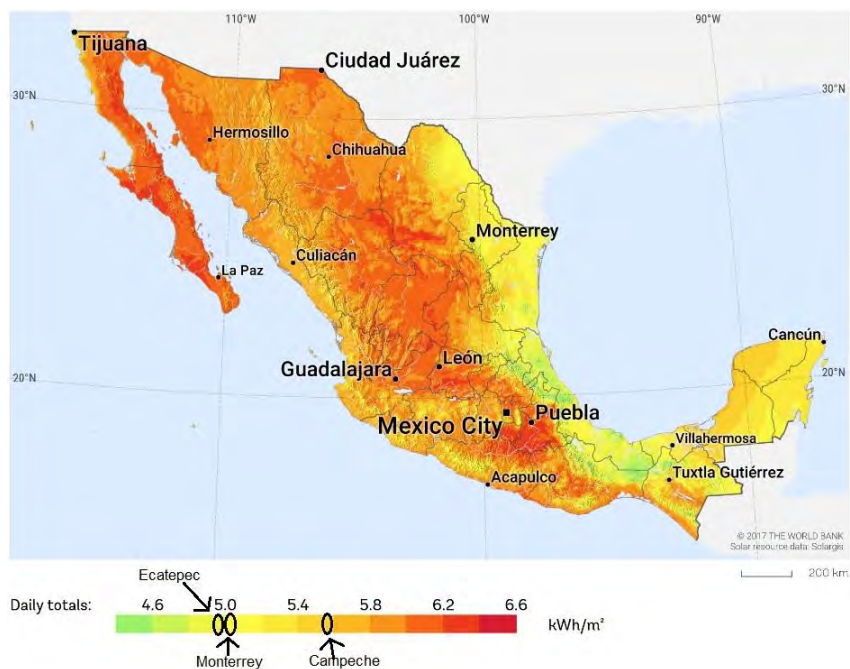


Figura A.1: *Recurso solar en México.*

La temperatura ambiente promedio anual es de  $16.4^{\circ}C$ ,  $22.5^{\circ}C$  y  $26.1^{\circ}C$  para Ecatepec, Monterrey y Campeche, respectivamente. El promedio mensual máximo y mínimo fue de  $19.2^{\circ}C$  y  $13.6^{\circ}C$ , para Ecatepec,  $28.7^{\circ}C$  y  $15.2^{\circ}C$ , para Monterrey y  $22.3^{\circ}C$  y  $29.0^{\circ}C$ , para Campeche. La diferencia entre la temperatura máxima y mínima para Ecatepec y Campeche datan de alrededor de  $6^{\circ}C$ , por lo que se puede decir que no tienen climas extremos a lo largo del año. Monterrey, por su parte, tiene temperaturas más extremas, con una diferencia entre su temperatura promedio máxima y mínima de  $13.5^{\circ}C$ .

La irradiación solar promedio diaria directa, difusa y global fue de  $2.79 \frac{kWh}{m^2}$ ,  $2.16 \frac{kWh}{m^2}$  y  $4.95 \frac{kWh}{m^2}$ , para Ecatepec,  $3.11 \frac{kWh}{m^2}$ ,  $2.03 \frac{kWh}{m^2}$  y  $5.14 \frac{kWh}{m^2}$ , para Monterrey y  $3.33 \frac{kWh}{m^2}$ ,  $2.22 \frac{kWh}{m^2}$  y  $5.54 \frac{kWh}{m^2}$ , para Campeche, respectivamente. De acuerdo al espectro de irradiación de la Figura A.1, Ecatepec y Monterrey se encuentran por debajo de la media en irradiación nacional, mientras que Campeche se encuentra por arriba de la media. La cantidad de radiación difusa representa aproximadamente el 44%, para Ecatepec, 40%, para Monterrey y Campeche. Lo anterior nos indica que los captadores solares planos son la mejor selección para estas ciudades, debido a su capacidad de colección de radiación directa y difusa.




Figura A.2: Recurso solar en Ecatepec.




Figura A.3: Recurso solar en Monterrey.

En las Figuras A.2, A.3 y A.4 se presenta el recurso solar para Ecatepec, Monterrey y Campeche respectivamente. La irradiación diaria promedio mensual máxima y mínima de Ecatepec es de  $5.95 \frac{kWh}{m^2-día}$  y  $3.96 \frac{kWh}{m^2-día}$ , respectivamente, mientras que la irradiación en Monterrey fluctúa entre  $2.95 \frac{kWh}{m^2-día}$  y  $6.89 \frac{kWh}{m^2-día}$  y el rango de Campeche va de 3.93 a  $6.63 \frac{kWh}{m^2-día}$ . En Ecatepec, debido a que la irradiación es relativamente constante a lo largo del año, el desempeño del sistema de calentamiento solar tampoco debe fluctuar en gran medida. En Campeche la irradiación tampoco fluctúa tanto, sin mencionar que en los meses de abril a agosto, la irradiación promedio se encuentra por arriba de los  $6 \frac{kWh}{m^2-día}$ . Por su parte, Monterrey tiene una irradiación promedio de  $6.36-6.89 \frac{kWh}{m^2-día}$  de mayo a agosto, lo cual se encuentra en el extremo máximo del espectro nacional. Por lo que se puede decir que Ecatepec, Monterrey y Campeche son buenas opciones de lugar para la instalación de una planta solar.




Figura A.4: Recurso solar en Campeche.