



ESCUELA POLITÉCNICA NACIONAL

FACULTAD DE INGENIERÍA MECÁNICA

DESARROLLO DE UN MODELO CON TÉCNICAS DE INTELIGENCIA ARTIFICIAL PARA EL ANÁLISIS Y OPTIMIZACIÓN DE LA EFICIENCIA DE COLECTORES SOLARES CON TUBOS DE VACÍO, DE USO DOMÉSTICO PARA LA CIUDAD DE RIOBAMBA

TRABAJO DE TITULACIÓN PREVIO A LA OBTENCIÓN DEL TÍTULO DE MAGÍSTER EN MECATRÓNICA Y ROBÓTICA

ING. JORDY ALEXANDER HERNÁNDEZ VIVANCO, Mtr

jordy.hernandez@epn.edu.ec

DIRECTOR: ING. ÁLVARO XAVIER AGUINAGA BARRAGÁN, Ph.D.

alvaro.aguinaga@epn.edu.ec

CODIRECTOR: ING. WASHINGTON SALVATORE REINA GUZMÁN, Ph.D.

salvatore.reina@epn.edu.ec

Quito, junio 2022

DECLARACIÓN

Yo, Jordy Alexander Hernández Vivanco, declaro que el trabajo aquí descrito es de mi autoría; que no ha sido previamente presentado para ningún grado o calificación profesional; y, que hemos consultado las referencias bibliográficas que se incluyen en este documento.

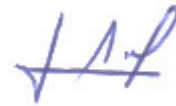
La Escuela Politécnica Nacional, puede hacer uso de los derechos correspondientes a este trabajo, según lo establecido por la Ley de Propiedad Intelectual, por su Reglamento y por la normatividad institucional vigente.



**Ing. Jordy Alexander
Hernández Vivanco, Mtr.**

CERTIFICACIÓN

Certificamos que el presente trabajo fue desarrollado por el señor JORDY ALEXANDER HERNÁNDEZ VIVANCO bajo nuestra supervisión.



Ing. Álvaro Aguinaga, Ph.D.
DIRECTOR DE PROYECTO



Ing. Salvatore Reina, Ph.D.
CO-DIRECTOR DE PROYECTO

DEDICATORIA

El presente trabajo le dedico principalmente a mis padres, por ser ejemplo y darme fuerza para continuar en este proceso de obtener uno de los anhelos más deseados. El amor de mis padres, trabajo y sacrificio en todos estos años, gracias a ustedes he logrado llegar hasta aquí. A mi hermana y a mi sobrino Joseph por estar siempre presentes, acompañándome y por el apoyo moral, que me brindaron a lo largo de esta etapa. Finalmente, al grupo de amigos por sus incontables horas de apoyo incondicional.

Ing. Jordy Alexander Hernández Vivanco, Mtr.

AGRADECIMIENTO

Principalmente, doy gracias a todos los docentes que forman parte del programa de maestría de mecatrónica y robótica, por permitirme adquirir una gran gama de conocimientos, al Ing. Álvaro Xavier Aguinaga Barragán, PhD. por la acertada guía en la presente tesis de grado. Adicionalmente, quiero agradecer a la empresa de investigación INNOVARING S. A. S cuyo presidente es Ing. Jorge Nejer, Mtr. por su apoyo inmensurable en incontables momentos.

Ing. Jordy Alexander Hernández Vivanco, Mtr.

CONTENIDO

RESUMEN	x
Abstract	xi
CAPÍTULO I	1
1. INTRODUCCIÓN	1
1.1. PLANTEAMIENTO DEL PROBLEMA	1
1.2. JUSTIFICACIÓN DE LA INVESTIGACIÓN	2
1.2.1. Justificación Teórica	2
1.2.2. Justificación Metodológica	3
1.2.3. Justificación Práctica	4
1.3. OBJETIVOS DE LA INVESTIGACIÓN	5
1.3.1. Objetivo General	5
1.3.2. Objetivos Específicos	5
1.4. ALCANCE	6
CAPÍTULO II	7
2. MARCO TEÓRICO	7
2.1. ANTECEDENTES DEL PROBLEMA	7
2.2. BASES TEÓRICAS	8
2.2.1. Visión global de la generación de energías renovables en el Ecuador	8
2.3. CONCEPTO DE MODELACIÓN	9
2.3.1. Modelos de inteligencia artificial aplicados a colectores solares	10
2.3.2. Modelo Multicapa Neural Network (NNML) entrenamiento supervisado	12
2.3.2.1. Aprendizaje y entrenamiento de la red neuronal Multicapa (ML)	14
2.3.2.2. Algoritmo Backpropagation	15
2.3.2.3. Algoritmo Descenso de Gradiente	15
2.3.2.4. Función de activación	15
2.3.3. Modelo Radial Basis Excat Fit (NNRB), entrenamiento híbrido	16

2.3.4.	Modelo de inferencia adaptativo neuro-difuso (ANFIS)	17
2.3.4.1.	Aprendizaje y entrenamiento ANFIS.....	19
2.3.4.2.	Métodos para el análisis de rendimiento de los modelos NNML y ANFIS.....	20
2.4.1.	Modelo matemático de la dinámica de los colectores solares de tubos al vacío	21
2.4.2.	Irradiancia.	22
2.4.3.	<i>Ecuación del rendimiento.</i>	26
2.4.4.	Valores termodinámicos de modelación del colector solar con tubos de vacío	27
CAPÍTULO III		28
3.	DISEÑO DE LA INVESTIGACIÓN	28
3.1.	DESARROLLO DE LA METODOLOGÍA DE INVESTIGACIÓN	28
3.1.1.	Métodos de investigación.....	29
3.1.2.	Enfoque de la investigación	29
3.1.3.	Alcance de la investigación.....	29
3.2.	SISTEMA DE INFERENCIA ADAPTATIVO NEURO-DIFUSO (ANFIS)	30
3.2.1.	Adquisición de conocimiento del experto.....	31
3.2.2.	Determinación y fuzificación de entradas	32
3.2.3.	Generación de las reglas de inferencia difusa	34
3.2.4.	Entrenamiento ANFIS.....	38
3.2.5.	Conclusiones ANFIS	39
3.3.	ANÁLISIS DE DATOS PARA ENTRENAMIENTO DE LAS REDES NEURONALES 40	
3.3.1.	Bifurcación de datos	40
3.3.2.	Desarrollo del modelo Redes Neuronales Multicapa (NNML), entrenamiento supervisado	41
3.3.3.	Elección del grupo de técnicas de entrenamiento.....	43
3.3.4.	Conclusiones NNML.....	45

3.3.5.	Desarrollo del modelo Radial Basis Exact Fit (NNRB), entrenamiento hibrido	46
3.4.	SIMULACIÓN DEL MODELO CON INTELIGENCIA ARTIFICIAL	47
3.4.1.	Métodos estadísticos para la valoración del desempeño de los modelos NNML	47
3.4.2.	Desarrollo de la programación de los modelos con técnicas de inteligencia artificial	48
3.4.3.	Ingreso de datos de entrenamiento	49
3.4.4.	Introducción a Matlab para crear redes neuronales	49
3.4.5.	Generación de la red	50
3.4.6.	Entrenamiento de los modelos	51
3.4.7.	Realizar la simulación	52
3.5.	OPTIMIZACIÓN DE LA EFICIENCIA DE LOS COLECTORES SOLARES CON TUBOS DE VACÍO DE USO DOMÉSTICO	54
3.5.1.	Determinación de los parámetros óptimos del sistema	54
CAPÍTULO IV		60
4.	RESULTADOS Y DISCUSIÓN	60
4.1.	PRUEBAS DE FUNCIONAMIENTO DE LOS MODELOS NNML Y ANFIS	60
4.2.	RESULTANTES DE LAS CONFIGURACIONES DE LOS MODELOS ANFIS, NNML Y NNRB	61
4.2.1.	Relación de los algoritmos de entrenamiento TRAINGDM y TRAINGDY en la red neuronal Feed-forward Backpropagation	61
4.2.2.	Comparación de rendimiento de los diferentes modelos de redes neuronales multicapa	62
4.2.3.	Pronóstico de la eficiencia con diferentes conjuntos de datos	64
4.2.4.	Valoración de desempeño de los modelos NNML	65
4.3.	CÁLCULO DE LA EFICIENCIA ÓPTIMA PARA EL SISTEMA	66
CAPÍTULO V		69
5.	CONCLUSIONES Y TRABAJOS FUTUROS	69

5.1 CONCLUSIONES	69
5.2 RECOMENDACIONES	70
5.3. PLANTEAMIENTO DE TRABAJOS FUTUROS	71
BIBLIOGRAFÍA.....	73
ANEXOS.....	76

ÍNDICE DE TABLAS

Tabla 1-2: Algoritmos de entrenamiento.....	14
Tabla 2-2: Características climáticas medias de Riobamba.....	24
Tabla 3-2: Valores de Irradiancia en la Sultana de los Andes año 2021.....	25
Tabla 4-2: Criterios del Sistema.....	26
Tabla 5-2: Valores de Irradiancia.....	27
Tabla 6-2: Datos de presión atmosférica en la ciudad de Riobamba	27
Tabla 7-3: Cantidades mínimas y máximas de las variables del sistema	32
Tabla 8-3: Reglas de inferencia difusa.....	35
Tabla 9-3: Partición de la base de datos.	40
Tabla 10-3: Parámetros de las redes neuronales multicapa	45
Tabla 11-4: Parámetros de los modelos ANFIS, NNML y NNRB	60
Tabla 12-4: Comparación de rendimiento de las diferentes arquitecturas NNBP.....	62
Tabla 13-4: Comparación de rendimiento de los algoritmos NNML.....	63
Tabla 14-4: Comparación de rendimiento NNRB según su constante de propagación.	63
Tabla 15-4: Análisis de rendimiento de las mejores características de las redes NNML.....	64
Tabla 16-4: Valoración de los parámetros de rendimiento del colector solar NNML.....	65

ÍNDICE DE FIGURAS

Figura 1-1: Funcionamiento de un colector con tubos de vacío.....	3
Figura 2-2: Generación de energía a partir de fuentes renovables en Ecuador.....	9
Figura 3-2: Modelo dinámico de una planta	9
Figura 4-2: Clasificación de las redes neuronales artificiales	11
Figura 5-2: Configuración de la red multicapa feed-forward.....	13
Figura 6-2: Radial Base fase de entrenamiento hibrido	17
Figura 7-2: Estructura general ANFIS	18
Figura 8-2: Sistema de inferencia adaptativo neuro-difuso.....	19
Figura 9-2: Metodo para el analisis de rendimiento.	21
Figura 10-3: Pasos operativos de la red neuronal artificial	28
Figura 11-3: Arquitectura ANFIS modelo Mandani	30
Figura 12-3: Función de pertenencia Gaussiana.....	31
Figura 13-3: Implementación de los valores lingüísticos a las funciones de membresía.....	34
Figura 14-3: Introducción de reglas al sistema de inferencia difusa.....	36
Figura 15-3: Tendencia deseada de las variables de entrada respecto a la salida	37
Figura 16-3: Grafico 3D del comportamiento del modelo ANFIS.....	38
Figura 17-3: Variable de salida de la metodología Takani-Sujeno	39
Figura 18-3: Pasos operativos de las redes neuronales artificiales.....	41
Figura 19-3: Configuración de ANN para el sistema	42
Figura 20-3: Determinación de entradas y salidas de ANN.....	43
Figura 21-3: Entrenamiento de redes neuronales artificiales.....	44
Figura 22-3: Radial Basis entrenamiento hibrido.....	47
Figura 23-3: Introducción de valores estandarizados para entrenamiento y prueba.....	49
Figura 24-3: Configuración de la arquitectura de la red neuronal.....	50
Figura 25-3: Características de NNML	51
Figura 26-3: Entrenamiento ANN	52
Figura 27-3: Obtención de datos del entrenamiento.....	53
Figura 28-3: Ficha técnica colectores solares marca SOL-5820SS	55
Figura 29-3: Colector solar marca AMAWTEC.....	56
Figura 30-4: Comparación de resultados con los métodos desarrollados.....	61
Figura 31-4: Análisis de rendimientos de los modelos desarrollados	66

Figura 32-4: Resultados de eficiencia del Colector Solar marca SOL-5820SS	67
Figura 33-4: Resultados de eficiencia del Colector Solar marca SOL-5820SS.....	68

LISTA DE ANEXOS

- ANEXO A:** Datos para entrenar los modelos con redes neruonales
- ANEXO B:** Registro de simulaciones realizadas
- ANEXO C:** Resultados de los modelos NNMML
- ANEXO D:** Conjuntos de datos para validación
- ANEXO E:** Calculo de error de los modelos NNLR y NNFB

RESUMEN

En esta tesis de grado ANFIS y NNML, son empleados para analizar y optimizar la eficiencia de colectores solares con tubos de vacío, de uso doméstico para la ciudad de Riobamba. Con el propósito de diseñar y manufacturar colectores solares térmicos, la eficiencia es un parámetro fundamental y las variables de entrada que difieren en su rendimiento son el área del colector, la irradiación solar y el porcentaje de vacío. Los datos generados mediante ANFIS simulando el comportamiento de los diferentes parámetros que inciden en la eficiencia del colector solar, fueron normalizados y clasificados con el fin de entrenar y validar los modelos NNML. Las salidas NNFB, NNLR y NNRB fueron comparados entre ellos mediante las funciones RMSE, MAPE, R^2 y MSE. Diferentes características de las redes neuronales, como la cantidad de capas ocultas, cantidad de neuronas en dicha capa, los algoritmos de entrenamiento y función de activación fueron modificados para obtener la mejor arquitectura de las redes neuronales. NNRB con la función de entrenamiento GDX, obtuvo mejor rendimiento, con un R^2 de 0,99999; obteniendo como resultado que los modelos con técnicas de inteligencia artificial tienen un desempeño muy elevado para analizar y optimizar la eficiencia de los colectores solares.

PALABRAS CLAVES: <INTELIGENCIA ARTIFICIAL>, <REDES NEURONALES ARTIFICIALES>, <SISTEMA DE INFERENCIA ADAPTATIVO NEURO-DIFUSO>, <REDES NEURONALES ARTIFICIALES MULTICAPA>, <COEFICIENTE DE CORRELACIÓN>.

ABSTRACT

In this thesis ANFIS and NNML are used to analyze and optimize the efficiency of solar collectors with vacuum tubes for domestic use in the city of Riobamba. For the purpose of designing and manufacturing solar thermal collectors, efficiency is a fundamental parameter and the input variables that differ in their performance are collector area, solar irradiation and vacuum percentage. The data generated by ANFIS simulating the behavior of the different parameters that affect the efficiency of the solar collector were normalized and classified in order to train and validate the NNML models. The NNFB, NNLR and NNRB outputs were compared with each other using RMSE, MAPE, R^2 and MSE functions. Different characteristics of the neural networks, such as number of hidden layers, number of neurons in that layer, training algorithms and activation function were modified to obtain the best architecture of the neural networks. NNRB with GDX training function, obtained better performance, with an R^2 of 0.99999; obtaining as a result that the models with artificial intelligence techniques have a very high performance to analyze and optimize the efficiency of solar collectors

KEY WORDS: <ARTIFICIAL INTELLIGENCE>, <ARTIFICIAL NEURAL NETWORKS>, <ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM>, <MULTI-LAYER ARTIFICIAL NEURAL NETWORKS>, <CORRELATION COEFFICIENT>.

CAPÍTULO I

1. INTRODUCCIÓN

1.1. PLANTEAMIENTO DEL PROBLEMA

Actualmente gran parte de los colectores solares con tubos de vacío que son utilizados para elevar la temperatura del agua que se utiliza en los domicilios de los ecuatorianos, son importados de países que no consideran al momento de diseñar los factores ambientales de los países donde se van a comercializar. Lo mencionado anteriormente, genera un inconveniente al momento de ser seleccionados en nuestro país debido a que la ergonomía ambiental interviene en el desempeño del sistema.

Existen diversas variables que se estiman para obtener el desempeño de un colector solar con tubos de vacío, los cuales se mencionan a continuación; flujo másico de agua, área del colector, la irradiancia en el plano del colector, porcentaje de vacío de los tubos.

Estudios realizados en la ciudad de Riobamba, el 46% de la población no tiene noción sobre los colectores solares. Cabe mencionar que también analizaron que el 74% de la población estaría dispuesta a realizar la instalación de un colector solar con tubos de vacío. (Jiménez & Portalanza, 2009)

Sin embargo, se siguen instalando calentadores eléctricos o calefones de agua debido a que, las personas no tienen conocimiento sobre las ventajas que ofrecen los colectores solares para elevar la temperatura del agua en sus domicilios.

A escala internacional, el consumo energético en hogares y edificaciones han producido una huella en el cambio climático, las edificaciones utilizan el 40% de la energía a nivel internacional y generan el 21% de gases de efecto invernadero (Lecuona Neumann et al., 2013). Al cambiar la matriz energética del Ecuador, se determinó que el 50 % de la población se verá beneficiada, por tal razón este cambio es imperativo para obtener un desarrollo más sustentable. (Iglesias et al., 2017)

Tomando como referencia el estudio de (CAJO & TACO, 2017) indica que para elevar la temperatura del agua de uso residencial a nivel nacional, se emplean prioritariamente sistemas eléctricos en un 33%, gas licuado de petróleo (GLP) 53%, leña 14% y kerosene un 0.002%, los cuales emanan gases de efecto invernadero (GEI) en su producción y uso, provocando contaminación ambiental, gasto económico a nivel general.

Por tal motivo, es ineludible realizar un estudio de estos sistemas, con el fin de desarrollar un método para medir y aumentar la eficiencia del equipo instalado en la Sultana de los Andes empleando técnicas de inteligencia artificial.

1.2. JUSTIFICACIÓN DE LA INVESTIGACIÓN

1.2.1. Justificación Teórica.

Anteriormente, se explica los problemas que se generan en los colectores solares con tubos de vacío, para uso doméstico y el bajo conocimiento de las primacías que otorgan el uso de energías renovables, se propone obtener un método para medir y aumentar el desempeño del sistema empleando métodos de inteligencia artificial en el actual tesis de grado.

Las ondas electromagnéticas emitidas por el sol, son recibidas por el colector y transferidas mediante conducción térmica al agua, los captadores solares tienen la principal función de captar la radiación generada por el sol, impidiendo que se refleje al exterior del sistema. Por tal motivo, la composición interna de los tubos consiste en una cámara de vacío que admite solo la radiación, evitando la convección térmica fuera del sistema. Por leyes termodinámicas el agua al aumentar la temperatura su densidad disminuye y por el principio de termosifón, esta se almacena en la parte superior del tanque mientras que el agua fría permanece en el fondo debido a su mayor densidad, luego esta agua fría absorbe el calor del captador y el ciclo se repite como se indica en la figura 1-1.




Figura 1-1: Funcionamiento de un colector con tubos de vacío.

Fuente: (Pineda Medina, 1989)

1.2.2. Justificación Metodológica.

Antes de proceder al montaje del sistema en análisis, es imprescindible realizar un modelo que emplee los principales datos de la ergonomía ambiental para percibir la eficiencia que tendrán en la ciudad de Riobamba. Para el análisis y optimización, se empleará un sistema con la cabida de 450 L ideal, para un grupo 13 personas aproximadamente con la ergonomía ambiental de la Sultana de los Andes.

El sistema se planteará como una planta a ser controlada, teniendo como entradas sobre las que actuará el control, entre otras: irradiancia solar, porcentaje de vacío de los tubos, área del colector del colector y como salida la eficiencia. Con este planteamiento se utilizará la lógica difusa para determinar las funciones de

membresía para cada una de las entradas y salida, así como las inferencias entre estos parámetros operativos. Con este sistema de inferencia difusa, para cada vector de entradas, se obtendrá la respectiva salida nítida, conformando de esta manera un conjunto de aprendizaje. Se estructurará una red neuronal artificial, la misma que será entrenada con el conjunto de aprendizaje. Con la red ya entrenada se interpolarán y/o extrapolarán valores de variación de temperatura del agua, para diferentes valores de las entradas del modelo inteligente hasta determinar los valores óptimos, que corresponderán a la mejor eficiencia térmica del colector.

La validación del modelo con técnicas de inteligencia artificial se desarrollará comparando los datos de salida de las redes neuronales, con los datos analíticos de las ecuaciones que describen matemáticamente estos sistemas de colectores solares con tubos de vacío, utilizando métodos estadísticos para determinar el error entre los valores comparados.

1.2.3. Justificación Práctica

La energía tiene un papel fundamental para desarrollar la vida de miles de millones de personas acorde a los estándares de calidad alcanzados por la humanidad. Actualmente, la situación a nivel internacional sobre la demanda energética es complicada, generando grandes dificultades medioambientales, guerras internacionales, debido a la falta de recursos y el decrecimiento de los combustibles fósiles; en este sentido, en el Departamento de Ingeniería Mecánica se están realizando investigaciones y difundiendo los resultados que permitan utilizar eficientemente la energía solar como recurso sostenible en nuestro país. (Aguinaga et al., 2020)

El sector residencial tiene la necesidad de utilizar energía renovable, ya sea con colectores solares para elevar la temperatura del agua especialmente en las ciudades ubicadas en la región Andina donde las temperaturas son bajas. Por tal motivo, el Ministerio de Electricidad y Energía Renovable mediante la Agenda Nacional de Energía 2016-2040 indica, que dará como prioridad a la energía

renovable progresivamente hasta llegar a un nivel óptimo de las fuentes de fuentes de energía renovables como fotovoltaico, eólica, biogás. (Ministerio Coordinador de Sectores Estratégicos, 2016)

El presente estudio, tiene implicaciones en la creación y empleo de conocimientos para dar solución a los problemas, identificados como relevantes en el país, en el tema de sistemas de conversión energéticos y mejores prácticas de análisis y síntesis de equipos térmicos y termodinámicos, así como, dan cabida a la generación proyectos de innovación, a nivel interno e internacional.

1.3. OBJETIVOS DE LA INVESTIGACIÓN

1.3.1. Objetivo General

Desarrollar un modelo con técnicas de inteligencia artificial para el análisis y optimización de la eficiencia de colectores solares con tubo de vacío, de uso doméstico para el caso de la ciudad de Riobamba.

1.3.2. Objetivos Específicos

- Desarrollar una metodología para el uso de la inteligencia artificial en la optimización de un colector solar con tubos de vacío de uso doméstico.
- Describir y analizar el funcionamiento de los colectores solares con tubo de vacío de uso doméstico.
- Desarrollar el modelo con inteligencia artificial utilizando un software para el análisis y optimización del colector solar.
- Simular el modelo con inteligencia artificial.
- Analizar la sensibilidad paramétrica del modelo.
- Optimizar la eficiencia de los colectores solares con tubos de vacío de uso doméstico.

1.4. ALCANCE

Crear un modelo con técnicas de inteligencia artificial que permita analizar y optimizar la eficiencia de un colector solar con tubos de vacío para la Sultana de los Andes.

CAPÍTULO II

2. MARCO TEÓRICO

2.1. ANTECEDENTES DEL PROBLEMA

Globalmente la producción de energía de fuentes no renovables alcanza niveles muy elevados, especialmente en Ecuador donde el valor es del 98%, por tal motivo, optimizar el consumo de energía en edificaciones y viviendas implementando colectores solares con tubos de vacío. Investigaciones realizadas, las cuales se detallarán a continuación, se explica el diseño, construcción y el empleo de métodos de inteligencia artificial a estos sistemas cuya función es generar agua caliente. (Vivienda et al., 2018)

En la ciudad de Mashhad, Irán la técnica de red neural artificial perceptrón multicapa (MLP-ANN), función de base radial (RBF-ANN), Elman Back Propagation (Elamn BP-ANN), fueron utilizadas para desarrollar un método que permita pronosticar el rendimiento térmico de un colector solar, en el trabajo de Sadeghzadeh y Chen denominado "Modelado inteligente mediante el uso de técnicas de inteligencia artificial sobre el rendimiento térmico del colector solar plano utilizando nanofluidos". (Sadeghzadeh & Chen, 2019)

En Canadá, el autor Yaïci en su trabajo "Sistema de Inferencia Neuro-Fuzzy adaptativo para la predicción del rendimiento del sistema de energía solar térmica" estudio a detalle que tan aplicable puede llegar a ser ANFIS para pronosticar el desempeño de un sistema de energía solar térmica. Los datos para entrenar el modelo con redes neuronales fueron simulados en diferentes estaciones y condiciones climáticas, para posteriormente optimizar el modelo y predecir varias características que influyen en el desempeño del sistema. (Yaïci & Entchev, 2016)

En la actual tesis de grado, se busca desarrollar un modelo con métodos de inteligencia artificial para analizar y optimizar la eficiencia de colectores solares con tubos de vacío, de uso doméstico para la ciudad de Riobamba.

2.2. BASES TEÓRICAS

El cambio climático abarca un problema a nivel mundial, que exige acciones coordinadas en todas las direcciones y niveles para concientizar a todos los países a desarrollar la generación de energía con pequeñas generaciones de carbono. Se insta a limitar el acrecentamiento de la temperatura media global a niveles inferiores a 2 °C, restringiendo el aumento de temperaturas a 1.5 °C. (*Acuerdo de París Naciones Unidas 2015*, 2015) Para poder lograr este objetivo las naciones desarrolladas, estrechan lazos de cooperación para implementar sistemas capaces de generar energía a partir de fuentes renovables, a países en desarrollo.

2.2.1. Visión global de la generación de energías renovables en el Ecuador

La producción de energía eléctrica mediante recursos renovables a nivel nacional en el año 2019, alcanzó un 97.7% mediante fuentes hidráulicas, 1.80% mediante Bioenergía, 0.34% mediante sistemas impulsados por el viento, y 0.15% mediante energía solar, detallados por IRENA (Agencia Internacional de Energías Renovables) en la figura 2-2. Esto último explica, que la energía que proporciona el sol es la menos aprovechada para generar electricidad a partir de fuentes renovables en el País. Esto marca un hito para empezar este proyecto.




Figura 2-2: Generación de energía a partir de fuentes renovables en Ecuador
 Fuente: (Electricity Generation Trends, n.d.)

2.3. CONCEPTO DE MODELACIÓN

A un modelo dinámico se lo entiende a modo que la manipulación de variables de entrada obtiene señales de salida o un valor que se requiere del sistema; sin embargo, estos sistemas están expuestos a variables externas que afectan a su valor de salida, conocidas como perturbaciones, explicado en la imagen 3-2.

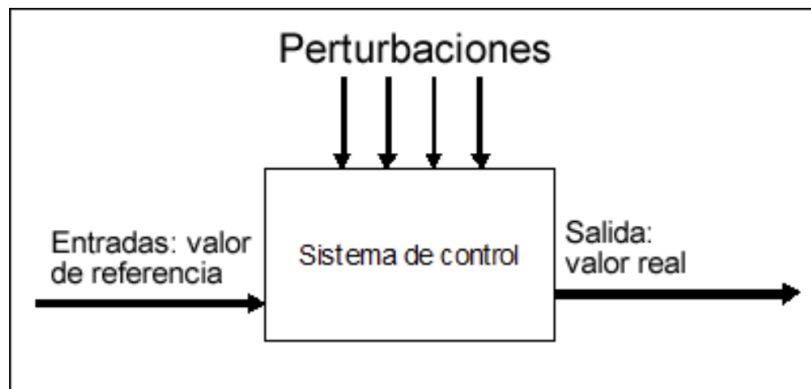


Figura 3-2: Modelo dinámico de una planta
 Fuente: (Empr, n.d.)

Al momento de querer modelar matemáticamente con técnicas paramétricas y no paramétricas una planta multivariable, con el cual represente la dinámica del sistema se torna implícitamente complejo; sin ninguna duda, se torna más engorroso cuando son sistemas no-lineales; por tal razón, años de investigación lograron encontrar que estos sistemas sean representados por medio de una técnica sustentada en redes neuronales artificiales.

Un modelo desarrollado con inteligencia artificial no proporcionara una fórmula matemática explícita; más bien; entregara una caja negra de predicción donde entradas y salidas se encuentran relacionadas. (Obregón et al., 2017)

Las redes neuro-difusas incorporan características de las redes neuronales, como el aprendizaje y generalización, mientras que la lógica difusa trabajar con razonamientos lógicos basados en reglas de inferencia, adicionalmente, varían el tratamiento binario del sistema generado por las redes neuronales artificiales por un tratamiento difuso. (Velásquez et al., 2004)

2.3.1. Modelos de inteligencia artificial aplicados a colectores solares

La estructura de una red neuronal artificial se divide generalmente: Feedforward, recurrente e híbrida. Una explicación más específica se indica en el siguiente gráfico, siendo multicapa Feed-Forward Backpropation (FBNN) las más utilizada.




Figura 4-2: Clasificación de las redes neuronales artificiales
 Fuente: (Trujillano Cabello et al., 2005)

Los modelos que más son usados en el ámbito de la energía solar térmica: (Khademi et al., 2013)

- Multicapa Neural Network (NNML), entrenamiento supervisado.
- Radial Basis excat fit (NNRB), entrenamiento híbrido.
- Artificial Neuro-Fuzzy Inference System (ANFIS).

El objetivo de esta tesis de maestría es emplear modelos fundamentados en inteligencia artificial (NNML y ANFIS) para analizar la eficiencia de un colector solar con tubos de vacío, manejando la lógica difusa para determinar las funciones de membresía para cada una de las entradas y salida, así como las inferencias entre estos parámetros operativos. Con este sistema de inferencia difusa, para cada vector de entradas, se obtendrá la respectiva salida nítida, conformando de esta manera un conjunto de aprendizaje. Se estructurará una red neuronal artificial la misma que será entrenada con el conjunto de aprendizaje. Con la red ya entrenada se interpolarán y/o extrapolarán valores de variación de temperatura del agua, para diferentes valores de las entradas del modelo

inteligente hasta determinar los valores óptimos, que corresponderán a la mejor eficiencia térmica del colector.

A continuación, se presenta detalladamente, los modelos de redes neuronales multicapa (NNML) y (ANFIS).

2.3.2. Modelo Multicapa Neural Network (NNML) entrenamiento supervisado

La clasificación de las redes neuronales está descrita por comportamientos dinámicos por ejemplo la red neuronal (Elman) y estáticos como las redes neuronales multicapa recurrente (NNR) o feed-forward backpropagation (NNFB), siendo este ultima modelo el más aplicado. El funcionamiento de las redes multicapa consiste que cada neurona obtiene datos de otra neurona siendo este el proceso de entrada, para después transmitirlos a la capa oculta y últimamente a la capa de salida. Las primordiales funciones del modelo Multicapa están expresadas a continuación: preparación por retro propagación del error, enlaces únicamente con la capa contigua, no existe conexiones entre los nodos de capas idénticas, redes neuronales hacia adelante.

El resultado de cada una de las neuronas es el resultado de una combinación de pesos y la entrada. La sumatoria de las entradas está expresada por la siguiente formula.

$$X = \sum_{i=1}^n (w_{ij} a_i + b_j) \quad [1]$$

Dónde:

- n = cantidad de datos de ingreso (1=0,1,2,3, 4... n).
- $w_{ij} = a_i$ es la conexión interna de pesos sinápticos de las premisas y b_j es el bias de la neurona.

La información es guardada en un grupo por medio de pesos sinápticos y bias. Una función de transferencia F mediante la adición de los pesos de entrada, junto las bias es analizada, la salida esta expresada a continuación:

$$Y = F(X) = F\left|\sum_{i=1}^n (w_{ij} a_i + b_j)\right| \quad [2]$$

Totalmente las capas de salida y ocultas disponen de una función de activación, estas pueden ser lineal o no lineal. Para lo cual varios métodos sirven para conseguir la relación entre las entradas y las salidas. Feedforward Backpropagation es el algoritmo más empleado. La función sigmoide es la muy empleada en la activación de una función no lineal, donde las salidas se encuentran entre 0 y 1, la siguiente formula expresa dicha función.

$$F(X) = \frac{1}{1+e^{-x}} \quad [3]$$

Al existir valores negativos entre las capas de entrada y salida, Tansig al ser una función de transferencia es empleada y descrita a continuación:

$$F(x) = \frac{1-e^{-2X}}{1+e^{-2X}} \quad [4]$$

Las señales de ingreso son multiplicadas por los pesos sinápticos los cuales si toman un valor mayor a cero realizarán una señal excitadora, al tomar un valor menor a cero producirán una señal inhibitora, mientras al obtener un valor neutro o cero la conexión entre las neuronas no existe.




Figura 5-2: Configuración de la red multicapa feed-forward
Fuente: (Llano et al., 2007)

2.3.2.1. Aprendizaje y entrenamiento de la red neuronal Multicapa (ML)

El entrenamiento de la red neuronal es uno de los procesos más fundamentales, para obtener la salida deseada. La finalidad de este proceso es variar los pesos de las conexiones de una forma regulada según la entrada que se tenga, de tal manera que estos pesos tendrán un valor o información útil al finalizar este proceso; sin embargo, antes de este proceso no posaran ningún valor. El entrenamiento de una red neuronal tiene tres tipos: Híbrido, Supervisado y no supervisado.

En el presente trabajo de tesis de maestría, se plantea utilizar un entrenamiento supervisado con los algoritmos descenso de gradiente con impulso (GDM) y retropropagación de tasa de aprendizaje adaptable (GDX). El fin de utilizar estos algoritmos es menguar el coeficiente de determinación y el error global.

Factores al tomar en cuenta para obtener la salida deseada es incrementar la cantidad de capas ocultas, con el objetivo de aumentar los índices de libertad y lograr solucionar problemas más complejos. Adicionalmente, la retro propagación emplea el descenso de gradiente para reducir el error de la red al restablecer los pesos sinápticos de la red neuronal.

Tabla 1-2: Algoritmos de entrenamiento

Algoritmo	Acrónimo	Descripción
TRAINLM	LM	Levenberg-Marquardt
TRAINGD	GD	Batch gradient descent
TRAINGDM	GDM	Batch gradient descent with momentum
TRAINCGP	CGP	Polak-Ribiere conjugate gradient
TRAINBP	BP	Back Propagation
TRAINGDX	GDX	Gradient descent with momentum and adaptive learning rate Backpropagation

Fuente: Matlab Toolbox
Realizado por : Autor

2.3.2.2. Algoritmo Backpropagation

Este algoritmo de aprendizaje es uno de los más icónicos para ANN, cuya función es mejorar el rendimiento minimizando el error general al variar los pesos generados en su gradiente.

2.3.2.3. Algoritmo Descenso de Gradiente

El algoritmo Gradiente Descendiente con impulso y retropropagación de tasa de aprendizaje adaptable (TRAINGDX), es utilizado por Matlab para la resolución de problemas no lineales debido a que reduce el tiempo de cálculos. Es un eje de aprendizaje adaptable necesita cambios en el proceso de entrenamiento requerido por TRAINGDM. Inicialmente, se calcula la salida y el error iniciales de la red. En cada época o iteración se analizan nuevos pesos y sesgos empleando la pauta de aprendizaje actual. Consecuentemente, se analizan nuevos resultados y errores.

2.3.2.4. Función de activación

La salida requiere la devolución de un valor al ser generado por la entrada, para que esto sea posible la función de activación es responsable de este trabajo. El algoritmo perceptrón multicapa principalmente emplea una función sigmoideal no lineal. Una característica de esta función es generar la media aritmética mesurada de los productos entre las entradas y los pesos sinápticos que intervienen en el enlace de la neurona. Existen 3 tipos de funciones de activación:

$$\text{Lineal: } f(x) = x \quad [5]$$

$$\text{Sigmoideal: } f = \frac{1}{1 + \exp^{-\sum \text{entradas} * \text{pesos}}} \quad [6]$$

$$\text{Hiperbólica tangencial: } f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad [7]$$

Emplear las funciones de activación más simples para reducir el gasto computacional es una consigna de este trabajo.

2.3.3. Modelo Radial Basis Excat Fit (NRRB), entrenamiento híbrido

A ANN de base radial se basa en el cálculo de la distancia euclidiana dado un vector de entrada x , respecto a una referencia o centro c_i , (Spooner & Passino, 1999) definido de la siguiente manera:

$$f(x) = (\|x - c_i\|) \quad [8]$$

Una función de base radial $\theta(x)$ le corresponde a cada neurona en la capa de entrada y un peso sináptico de salida ω_i . El peso sináptico alimenta a una neurona de salida, la cual adiciona a las entradas y se obtiene como salida una respuesta, expresada en la siguiente función:

$$F(x) = \sum_{i=1}^N \omega_i \theta(\|x - c_i\|) \quad [9]$$

Las redes RBNN, poseen una estructura estricta de 3 capas: entrada, oculta y salida, lo cual difiere de otra red por ejemplo la Backpropagation.

El aprendizaje es una parte fundamental de una ANN y para este tipo de red no es la excepción, este proceso se basa en determinar centros, desviaciones y pesos sinápticos de la capa oculta hacia la capa de salida. Debido a que la capa de entrada efectúa diversas tareas, se optimiza el proceso separando las cuantificaciones de la capa oculta y la de salida.

El método de entrenamiento que se utilizará en este trabajo para este tipo de ANN será el híbrido, en el cual el cantidad de neuronas y pesos en la capa oculta y los umbrales de la capa de salida son calculados automáticamente por el software. Como se puede observar en 6-2.

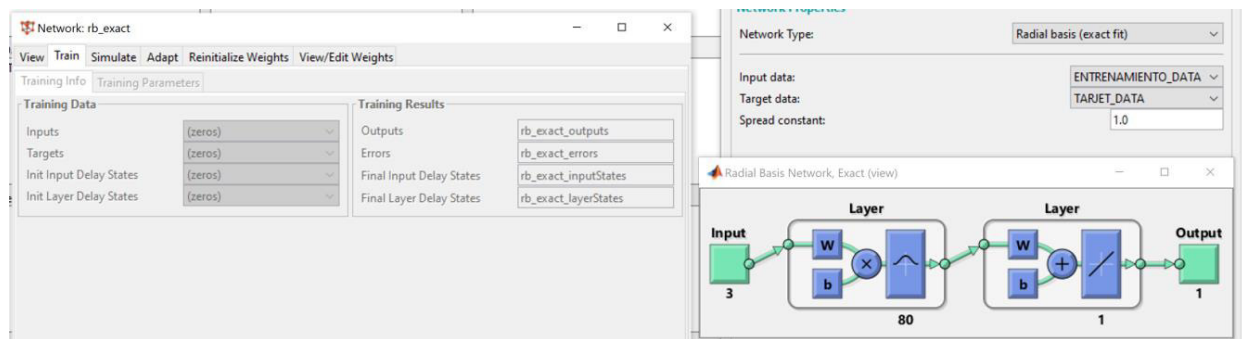


Figura 6-2: Radial Base fase de entrenamiento híbrido

Fuente: Autor

El único valor que se modifica es la constante de propagación, la cual determina la activación dentro del cluster de datos. Si el valor de la propagación es alto los puntos de datos se dispersarán lejos del centro, lo que conlleva a una eficiencia baja. Por lo tanto, de diversos trabajos (Martin & Choi, 2016), (K.S. Kasiviswanathan, 2012) se concluye que le mejor valor para entrenar la red es 1.

2.3.4. Modelo de inferencia adaptativo neuro-difuso (ANFIS)

ANFIS es la anexión del sistema FIS de redes adaptativas, que crean reglas difusas, tomando como referencia las funciones de membresía. FIS está formado por 3 elementos: la elección de reglas difusas; un conjunto de datos para establecer las funciones de membresía empleadas en la fuzificación de reglas y un módulo lógico. Sin duda, ANFIS es la conglomeración de varias capas empleando redes neuronales, razonamiento difuso y algoritmos para definir entradas a la salida.

ANFIS es empleado en diferentes frentes como: procesamiento, clasificación y control adaptativo. Las reglas difusas se plantean utilizando el método de Takani-Sugeno o Mandani, siendo este último utilizado para poder desarrollar el modelo debido a su salida que permite valores continuos.

Para una mejor comprensión se indica en la figura 7-2 una red general adaptativa neuro-difusa. Se realiza una planta a ser controlada, con las siguientes entradas: irradiancia solar, porcentaje de vacío en los tubos, área del colector y como salida la eficiencia.

Colectivamente la arquitectura ANFIS tipo Mandani de primer orden está formada por 5 capas:

- Capa uno: capa fuzzy de entrada, formada por nodos que se adaptan, cada una de sus entradas con sus respectivas funciones de membresía y diferentes grados especialmente Campana o Gaussian.
- Capa dos: capa producto, son nodos consolidados, la salida es la multiplicación del total de las entradas tomando en cuenta MF y la jerarquía de cada regla, etiquetado como Π .
- Capa tres: normalización de los niveles de activación, los nodos son fijos (N).
- Capa cuatro: defuzificación, mediante nodos adaptativos, basados en las medidas lógicas determinados por un término lingüístico, determinan las salidas de las reglas.
- Capa cinco: un nodo simple singular, que determina la salida holística del modelo ANFIS, se etiqueta Σ .

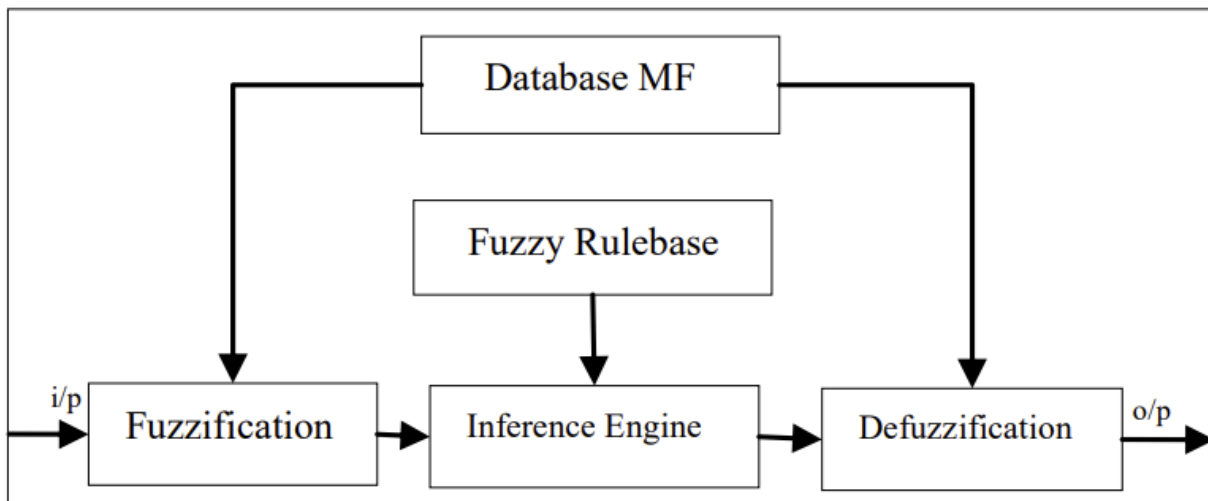


Figura 7-2: Estructura general ANFIS

Fuente: (Bravo & García, 2002)

2.3.4.1. Aprendizaje y entrenamiento ANFIS

La enseñanza ANFIS es una mezcla de los diferentes métodos: algoritmo de mínimo cuadrado, híbrido, Backpropagation que optimizan y determinan los factores del sistema de inferencia Mandani. Los modelos ANFIS requieren que los pasos que se indican en la figura (7-2) sean realizados en orden para poder ser utilizados.

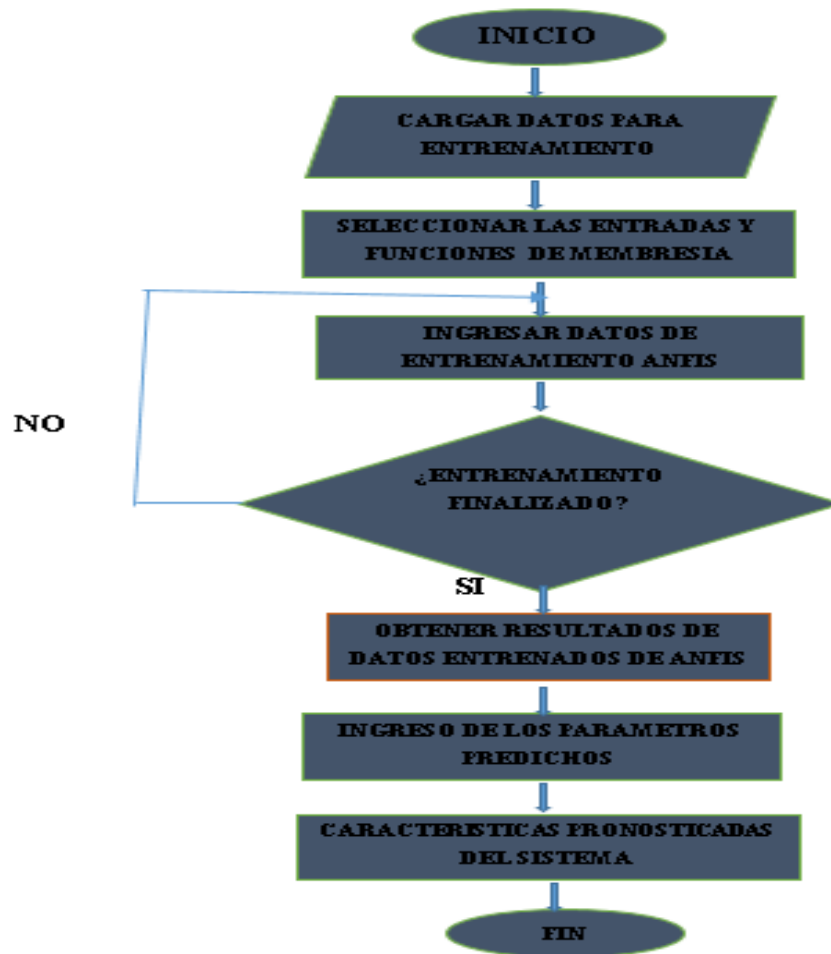


Figura 8-2: Sistema de inferencia adaptativo neuro-difuso

Fuente: (Walia et al., 2015)

Como se puede apreciar en la figura 7-2, un flujograma indica como formar un modelo ANFIS, las premisas generadas por literatura que serán ingresados de las variables analizadas que intervienen en el desempeño del colector solar.

- Se empieza cargando los datos desde una hoja electrónica, estableciendo vectores de datos anteriormente catalogados y establecidos en antecedentes de entrenamiento y prueba.
- Posteriormente, creamos FIS, empleando el método de inferencia difuso Mandani, en este punto se determina la cantidad de MF en la entrada, el tipo y las reglas de la ejecución del método planteado.
- Después, al entrenar con el método de Backpropagation o el método híbrido se procede a seleccionar el porcentaje de error tolerado para el proyecto y la cantidad de épocas.
- Por último, se ejecutan las ensayos y comprobación del entrenamiento del modelo con el fin de demostrar su desempeño.

ANFIS, es un método que optimiza los cimientos de las funciones de membresía, las cuales se obtienen de una base de datos que describen el funcionamiento del sistema, con un algoritmo de aprendizaje establecido en una base de antecedentes de entrenamiento. Lo mencionado logra que las reglas sean adaptativas.

2.3.4.2. Métodos para el análisis de rendimiento de los modelos NNML y ANFIS

De tal manera que los modelos entrenados NNML y ANFIS requieren ser validados mediante métodos estadísticos: el error cuadrático medio (RMSE), error porcentual absoluto (MAPE), el coeficiente de correlación (R2) y el error cuadrático medio (MSE). Representado en la figura 9-2.

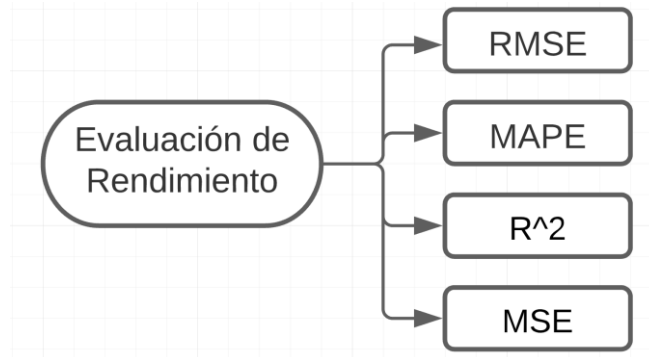


Figura 9-2: Metodo para el analisis de rendimiento.

Fuente: (Núñez et al., 2011)

2.4.1. Modelo matemático de la dinámica de los colectores solares de tubos al vacío.

Analizando cuantificaciones físicas, térmicas, hidráulicas, mecánicas mediante un proceso de cálculos obtendremos el modelo matemático que admite determinar el desempeño térmico del sistema.

A partir de las siguiente formula se calcula, la ganancia útil de la energía térmica del sistema:

$$ET = \dot{m} C \Delta T \quad [10]$$

Donde:

- \dot{m} = flujo masico acumulado en el colector.
- C = Energia necesaria del agua.
- ΔT = variación de la temperatura del fluido.

La siguiente formula permite encontrar, la energia solar captada por cantidad de superficie:

$$ET_{A=} = G * A \quad [11]$$

- G = Energía captada por la radiación.
- A = Superficie de impregnación.

La división de la radiación ocurrente en el área del colector solar y la energía térmica utilizable determina la eficiencia global del sistema.

$$\eta = \frac{\dot{m} C \Delta T}{G * A} \quad [12]$$

- η = Eficiencia del colector solar (%).

La norma NEC-11 capítulo 14 de construcción ecuatoriana, determina que la eficiencia del colector solar constituye la razón entre la potencia útil trasladada al flujo del sistema, por cantidad de área del captador y la irradiancia.

2.4.2. Irradiancia.

Se debe tener claro que la potencia recibida por cantidad de superficie es Irradiancia (I) (W/m^2), por otro lado, la irradiación (H) es la cantidad de energía captada por unidad de área mediante un tiempo establecido ($Wh/m^2 * día$).

La expresión radiación es empleada generalmente en sentido genérico. También es importante establecer las siguientes equivalencias, la irradiación normal directa o constante solar, con un valor de $1345 W/m^2$. Acotando que en una hora de luz solar se obtiene una potencia de $1000 W/m^2$; implica que una hora de Irradiación equivale a $1 kW-h/m^2$ de energía solar. (Jeklin, 2016)

Irradiación solar en Riobamba.

El porcentaje de radiación solar incidente que a cualquier lugar de la superficie terrestre establece por distintas operaciones analíticas (Jiménez & Portalanza, 2009), en función de la latitud geográfica y las horas de sol brillante (heliofanía), teniendo como a las más relevantes Glover y Mc Culloch, Liu –Jordan, descritas a continuación.

$$I = G_o [0.29 * \cos \phi + 0.52 * (\frac{n}{N})] \quad [13]$$

Donde :

- I= Radiación solar en el área (W/m^2).
- G_o = Factor solar. ($1353 -1367W/m^2$).
- $\cos \phi$ = ángulo de latitud geográfica para la Sultana de los Andes $1^\circ 38$ min= 1.633° . Latitud sur.
- 0.29 y 0.52= Factores de corrección para la dispersion de la radiación.
- n= Promedio de heliofanía en la Sultana de los Andes. 5,3 h.
- N= límite de horas de sol al dia en un lugar (10.6 h) (Instituto Nacional de Meteorología e Hidrología (INAMHI), 2021)

Utilizando el procedimiento de Glover y Mc Culloch, y conforme los resultados se analiza la ecuación:

$$I = G_o [0.29 * \cos \phi + 0.52 * (\frac{n}{N})] \quad [12]$$

$$I = 1360W/m^2 [0.29 * \cos(1.633) + 0.52 * (\frac{5.3}{10.6})]$$

$$I=747,84W/m^2$$

El método Page permite ratificar el valor de la radiación solar incidente de la siguiente manera:

$$G = G_o (a + \frac{Bn}{N}) \quad [13]$$

Descrito:

- G = Radiación incidente en la superficie.
- G_o =Factor solar.
- n = Media de heliofanía.
- N= límite de horas de sol al dia en un lugar (10.6 h) (Instituto Nacional de Meteorología e Hidrología (INAMHI), 2021)
- a, B = Factores correctivos de la radiación a nivel nacional: a = 0.25, B = 0.45.

Posteriormente, empleando los datos para la Sultana de los Andes, obtenemos:

$$G = 1360 \text{ W/m}^2 \left(0.25 + \frac{0.45 \cdot 5.3}{10.6} \right)$$

$$G = 646 \text{ W/m}^2$$

En la tabla 2-2, se representa valores de temperatura exterior a diferentes horarios del mes de diciembre, una heliófila diaria de 5,3 horas media para la Sultana de los Andes, aplicando la ecuación la radiación es 646 W/m^2 .

Tabla 2-2: Características climáticas medias de Riobamba

Tiempo (h)	Irradiancia (W/m^2)	Temperatura ($^{\circ}\text{C}$)
0 a 7	0	9
7 a 8	95	10
8 a 9	271	12
9 a 10	462	14
10 a 11	702	16
11 a 12	736	18
12 a 13	608	19
13 a 14	531	20
14 a 15	576	20
15 a 16	195	19
16 a 17	165	17
17 a 24	92	17
18 a 19	35	16
19 a 24	0	15

Fuente: (Instituto Nacional de Meteorología e Hidrología (INAMHI), 2021) & (utiempo Network, 2022)
Realizado por: Autor

Tabla 3-2: Valores de Irradiancia en la Sultana de los Andes año 2021

MES	Helofilia (h)	Horas de sol (h)	Irradiancia metodo Glover y Mc Culloch (W/m ²)	Irradiancia metodoPage (W/m ²)	Irradiancia Media (W/m ²)
Enero	4.8	9.5	751.56	649.22	700.39
Febrero	3.8	8.3	718.02	620.19	669.11
Marzo	3	8.4	646.81	558.57	602.69
Abril	4.3	8.8	739.80	639.05	689.42
Mayo	3.9	10.1	667.32	576.32	621.82
Junio	4.9	10.3	730.68	631.15	680.91
Julio	4.7	11.1	693.69	599.14	646.41
Agosto	4.3	9.6	711.01	614.13	662.57
Septiembre	4.7	9.4	747.84	646.00	696.92
Octubre	4.9	8.4	806.77	697.00	751.89
Noviembre	5.3	10.3	758.14	654.91	706.53
Diciembre	5.3	10.6	747.84	646.00	696.92
Media	4.49	9.57	726.62	627.64	677.13

Fuente: (Instituto Nacional de Meteorología e Hidrología (INAMHI), 2021) & (utiempo Network, 2022)

Realizado por: Autor

La eficiencia termina de los colectores solares para calentar agua se describe a continuación:

$$\eta = \frac{\dot{m}C_p(T_{out}-T_{in})}{GA_{ext}} \quad [14]$$

Descripción:

- η = eficiencia térmica
- \dot{m} = caudal.
- C_p = capacidad calorífica del fluido
- T_{out} = Temperatura del fluido a utilizar

- T_{in} = Temperatura de ingreso del fluido
- G = Irradiancia solar
- A_{ext} = Superficie del panel
- C_p = calor característico del fluido. 4,180J/kg °C

2.4.3. Ecuación del rendimiento.

Es imperativo tener como referencia las variables de funcionamiento que nos provee el fabricante, para determinar el desempeño del sistema. La siguiente ecuación sirven para el cálculo del rendimiento instantáneo, las variables que describen al sistema térmico se obtienen desde el gráfico de eficiencia referenciando a la norma UNE-EN 12975:

$$\eta = \eta_o - a_1 \left(\frac{tm - ta}{I} \right) - a_2 \left(\frac{tm - ta}{I} \right)^2 \quad [15]$$

Donde:

- η_o = Rendimiento óptico. Valor entregado por el fabricante.
- a_1 = Factores de decrementos lineal.
- a_2 = Factores de decrementos cuadrático.
- T_m = Temperatura promedio del líquido en el acumulador, $tm = \left(\frac{te + ts}{2} \right)$
- T_e = Temperatura de ingreso del líquido.
- T_a = Temperatura exterior.

Tabla 4-2: Criterios del Sistema.

Desempeño óptico	η_o	0,7865
Coeficiente de pérdidas lineal	a_1	1.2-4 (3.5)
Coeficiente de pérdidas cuadrático	a_2	0.015
Coeficiente general de pérdidas del	$F_R U_L [W/m^2 \cdot ^\circ C]$	2
Eficiencia óptica del sistema	$F_R (\tau \cdot \alpha)_n$	0.7

Fuente: (Ríos Encalada, 2021)
Realizado por: Autor

2.4.4. Valores termodinámicos de modelación del colector solar con tubos de vacío.

Para este trabajo de maestría se emplearán valores difusos bajos, medios bajos, medios, medios altos, altos de irradiancia, incluyendo datos de porcentaje de vacío de los tubos y área del colector.

Tabla 5-2: Valores de Irradiancia

BAJA IRRADIANCIA	MEDIA BAJA IRRADIANCIA	MEDIA IRRADIANCIA	MEDIA ALTA IRRADIANCIA	ALTA IRRADIANCIA
0 W/m ²	250 W/m ²	500 W/m ²	750 W/m ²	1000 W/m ²

Fuente: (Mecánica et al., 2015)

Realizado por: Autor

La presión atmosférica se torna una variable a tomar en cuenta para poder dimensionar el porcentaje de vacío que pueden adquirir estos tubos que son implementados en los colectores solares. Posteriormente, en la tabla 6-3 se indican los valores de la presión atmosférica anual en la ciudad de Riobamba, obtenida mediante la Estación Agrometeorológica ESPOCH.

Tabla 6-2: Datos de presión atmosférica en la ciudad de Riobamba

Meses	MEDIA en mm hg	MEDIA en Bar
ENERO	543.5	0.7244855
FEBRERO	543.5	0.7244855
MARZO	543.9	0.7250187
ABRIL	544.1	0.7252853
MAYO	544.8	0.7262184
JUNIO	545	0.726485
JULIO	545.1	0.7266183
AGOSTO	545.1	0.7266183
SEPTIEMBRE	545.1	0.7266183
OCTUBRE	544.4	0.7256852
NOVIEMBRE	543.5	0.7244855
DICIEMBRE	543.4	0.7243522
MEDIA	544.3	0.7255519

Fuente: (Mecánica et al., 2015)

Realizado por: Autor

CAPÍTULO III

3. DISEÑO DE LA INVESTIGACIÓN

Este capítulo tiene como fin describir los pasos para desarrollar los modelos de redes neuronales artificiales multicapa (ML) y el sistema (ANFIS), dichos modelos van a anunciar la eficiencia del sistema, analizando principalmente los criterios como la Irradiancia solar, área del colector y porcentaje de vacío en los tubos, estos modelos poseen la primacía de emplear criterios de expertos, la capacidad de “razonamiento” en ANFIS conjuntamente con la enseñanza y adaptación de las ANN.

3.1. DESARROLLO DE LA METODOLOGÍA DE INVESTIGACIÓN

- Recolección de datos: normalización, configuración de datos, selección de la cantidad de información para instrucción y análisis.
- Selección de la constitución ANN: tipo de ANN, variables de entrada y salida, cantidad de capas ocultas, cantidad de neuronas en las capas ocultas, determinar la interconectividad en las neuronas, función de activación de la ANN.
- Preparación ANN: selección del algoritmo.
- Validación y prueba.
- Ejecución.



Figura 10-3: Pasos operativos de la red neuronal artificial

Fuente: (Matich Damián, 2001)

3.1.1. Métodos de investigación

El proyecto empleará los métodos deductivo e inductivo para examinar la operatividad general del sistema y la aplicación de los distintos modelos de IA. A continuación, se empleará el método analítico contrastando la cuantía de las variables de entrada (área del colector, irradiancia y porcentaje de vacío en los tubos) que afectan el desempeño del sistema con los factores ambientales en la Sultana de los Andes.

3.1.2. Enfoque de la investigación

Un enfoque cuantitativo se empleará en la siguiente tesis de grado, debido a que se busca obtener la eficiencia del sistema, analizar el estado del arte. Se concierne los datos generados, normalizados, clasificados, entrenados y como punto terminal se estudian los datos de salida de los modelos NNML y ANFIS.

3.1.3. Alcance de la investigación

La tesis de grado va a tener una importancia exploratoria, se ahonda en el entendimiento del desempeño del sistema empleando técnicas de IA, investigando proyectos enfocados con la temática. Después, se obtiene una transcendencia correlacional debido a que la meta es obtener valores de desempeño del sistema a partir de la Irradiancia, área del colector y porcentaje de vacío en los tubos empleando los modelos NNML y ANFIS. Para el desarrollo del mismo, se emplearán los siguientes pasos:

- Modelado y selección de la estructura ANFIS
- Generación y normativización de premisas mediante ANFIS.
- Elección de la arquitectura en NNML.
- Clasificación de datos de entrenamiento de las ANN.
- Procesamiento de datos de autenticación de las ANN.
- Simulación

- Determinación de parámetros a optimizar del sistema.

3.2. SISTEMA DE INFERENCIA ADAPTATIVO NEURO-DIFUSO (ANFIS)

Al implementar una NNFB utilizando algoritmos de enseñanza de ANN conjuntamente con normas de aprendizaje difuso se obtiene el modelo ANFIS. Posteriormente, en la figura 11-3 se indica la arquitectura de primer orden ANFIS fuzzy Mandani.

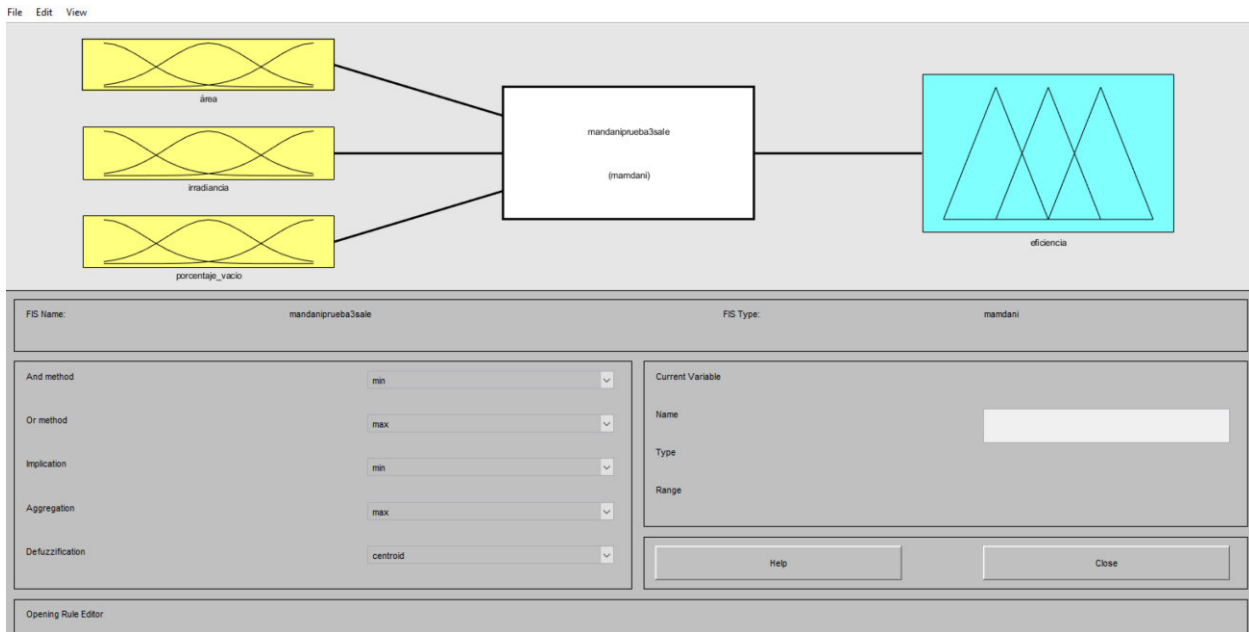


Figura 11-3: Arquitectura ANFIS modelo Mandani

Fuente: Autor

El funcionamiento básico ANFIS, tiene el siguiente arreglo de 5 capas:

- **Capa uno:** Son nodos adaptativos en la fuzificación de las características de ingreso. En este punto, se determina el tipo de MF para cada entrada, en el presente proyecto usamos, gaussmf. Representada en la siguiente ecuación.

$$\mu(x) = e^{-k(x-m)^2} \quad [16]$$

Donde:

$x =$ es la entrada al nodo i

$m =$ valor medio

$k =$ cuanto mayor el k , más estrecha es la campana




Figura 12-3: Función de pertenencia Gaussiana

Fuente: (Andrade Revelo, 2006)

- **Capa dos:** Según las reglas planteadas obtiene a la salida el resultado, según la evaluación de los ingresos en términos de las MF. Es etiquetada como Π .
- **Capa tres:** Esta capa tiene nodos consolidados que se constituyen mediante N que significa los niveles de activación al final.
- **Capa cuatro:** Un nodo adaptativo representa a cada nodo de esta capa.

$$\omega_i Z_i = \omega_i (p_i x + q_i x + r_i) \quad [17]$$

Dónde: p_i , q_i y r_i son las cuantificaciones sistemáticas.

- **Capa cinco:** Existe una salida que representa el dato estimado para el modelo.

3.2.1. Adquisición de conocimiento del experto

Un recurso fundamental para obtener información para nuestra tesis de grado es el dominio y destreza de personas que se especializan en la distribución e implementación de dichos sistemas. Con la ayuda de los valores derivados de proyectos desarrollados a nivel nacional, conjuntamente con el criterio técnico de personal especializado en la temática adquirimos asesoría relevante y premisas que garantizan modelos con un alto rendimiento.

Adicionalmente información relevante para este estudio fue proporcionada por personal de la empresa ECUASUN, localizada en la Sultana de los Andes. Brindando información sobre caracteres fundamentales, dificultades y primacías de manejo. Esta información fue verificada en los estudios, (Morales et al., 2016) y (CECU, n.d.); donde afirman que el área del colector solar y el porcentaje de vacío del tubo tienen una relación directamente proporcional a la eficiencia del sistema.

3.2.2. Determinación y fuzificación de entradas

En el transcurso del análisis de los factores centrales que repercuten en el desempeño del sistema, se obtuvo las siguientes variables como: Área del colector solar, Irradiancia, Porcentaje de vacío en el tubo.

Implementando el toolbox <<fuzzy>> del software Matlab, se desarrolló FIS, indicando las normas, las clases de MF, obtuvimos los distintos datos que se generan en los diferentes parámetros de funcionamiento y configuración del colector solar con tubos de vacío.

Tabla 7-3: Cantidades mínimas y máximas de las variables del sistema

COLECTOR CON TUBOS DE VACÍO

VARIABLES	BAJO	MEDIO BAJO	MEDIO	MEDIO ALTO	ALTO	UNIDADES
Área del colector	2	4	6	8	10	m^2
Irradiancia	0	250	500	750	1000	W/m^2
Porcentaje de vacío	0	25	50	75	100	%

Fuente: ECUASUN, (Instituto Nacional de Meteorología e Hidrología (INAMHI), 2021) & (utiempo Network, 2022)
Realizado por: Autor

Los valores lingüísticos difusos: bajo, medio bajo, medio, medio alto, alto. Son representados por cada intervalo de la función de membresía (MF). Es necesario fuzificar las entradas entre 0 y 1 de la siguiente manera para poder representar los parámetros establecidos en la tabla 7-3:

$U_{\text{Área}} = [0.2-0.4-0.6-0.8-1]$ es particionado en 5 partes iguales (bajo, medio bajo, medio, medio alto, alto).

$U_{\text{Irrad}} = [0-0.25-0.5-0.75-1]$ es particionado en 5 partes iguales (bajo, medio bajo, medio, medio alto, alto).

$U_{\%vacío} = [0-0.25-0.5-0.75-1]$ es particionado en 5 partes iguales (bajo, medio bajo, medio, medio alto, alto). gaussmf

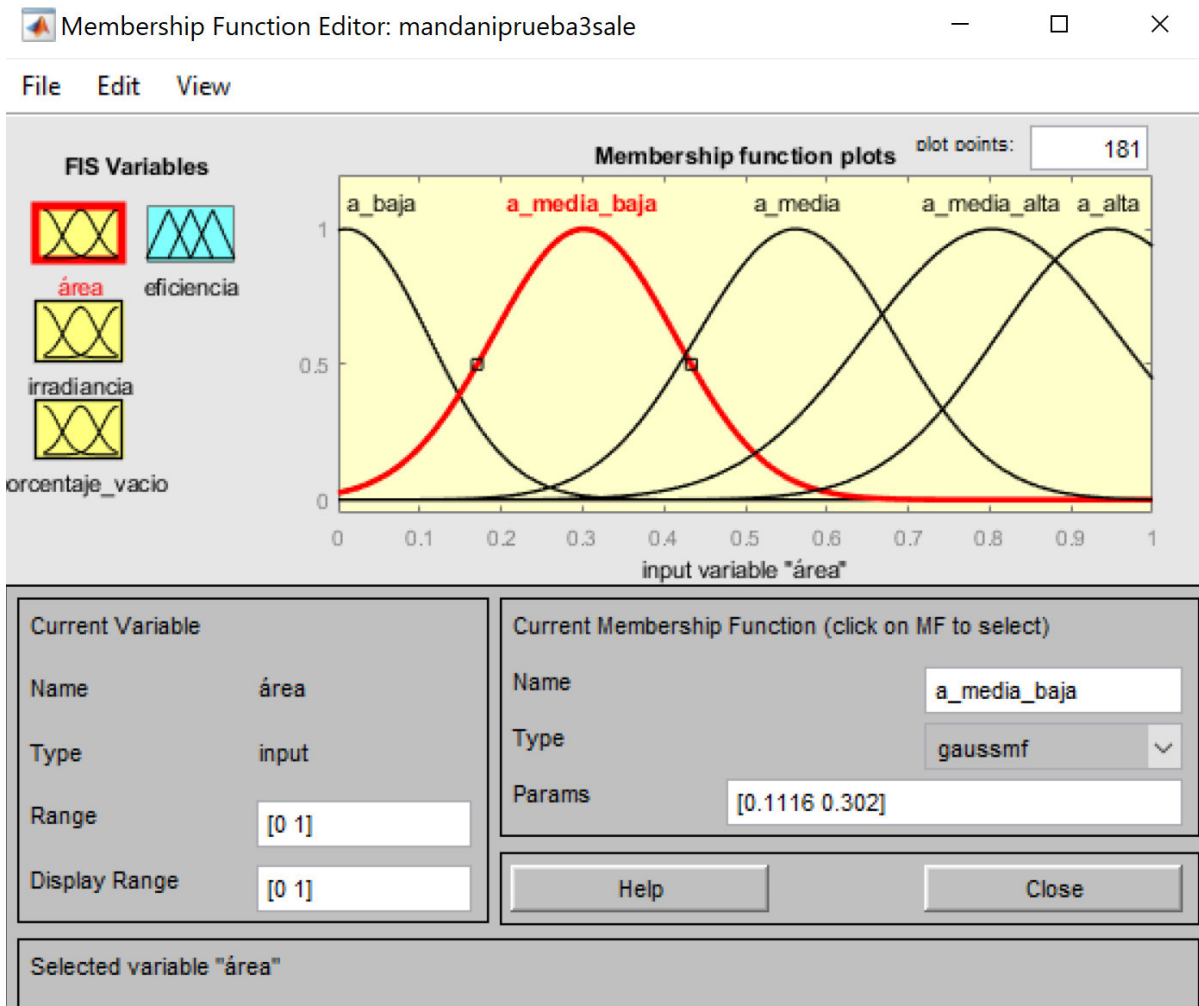


Figura 13-3: Implementación de los valores lingüísticos a las funciones de membresía
Fuente: Autor

3.2.3. Generación de las reglas de inferencia difusa

Las reglas de inferencia difusa se generan mediante el conocimiento del experto y la relación que existe de las diferentes variables que infieren en la eficiencia del sistema. Generamos un total de 48 reglas de inferencia difusa para poder obtener el modelo ANFIS que describa el sistema deseado, y de esa manera obtener la eficiencia del sistema al modificar los diferentes parámetros que inciden en él.

Tabla 8-3: Reglas de inferencia difusa

Reglas	Área	Irradiancia	% vacío	Eficiencia
R1	Baja	Bajo	Bajo	Baja
R2	Media baja	Bajo	Medio bajo	Bajo
R3	Media baja	Medio bajo	Medio bajo	Media baja
R4	Media	Bajo	Medio	Media baja
R5	Media	Medio bajo	Medio	Media baja
R6	Media	Medio	Medio	Media
R7	Media alta	Medio bajo	Medio alto	Media
R8	Media alta	Medio	Medio alto	Media alta
R9	Media alta	Medio alto	Medio alto	Media alta
R10	Alta	Alto	Alto	Alta
R11	Baja	Bajo	Medio bajo	Baja
R12	Baja	Medio bajo	Medio bajo	Media baja
R13	Baja	Medio	Medio bajo	Media baja
R14	Baja	Medio alto	Medio bajo	Media baja
R15	Media baja	Bajo	Medio	Media baja
R16	Media baja	Medio bajo	Medio	Media baja
R17	Media baja	Medio	Medio	Media
R18	Media	Bajo	Medio alto	Media baja
R19	Media	Medio bajo	Medio alto	Media
R20	Media	Medio	Medio alto	Media alta
R21	Media	Medio alto	Medio alto	Media alta
R22	Media alta	Medio	Alto	Media alta
R23	Media alta	Medio alto	Alto	Alta
R24	Media alta	Alto	Alto	Alta
R25	Alta	Medio alto	Bajo	Media
R26	Alta	Alto	Bajo	Media
R27	Baja	Bajo	Medio	Baja
R28	Media baja	Bajo	Medio alto	Medio
R29	Media baja	Medio bajo	Medio alto	Medio
R30	Media	Medio bajo	Alto	Media
R31	Media	Medio	Alto	Media alta
R32	Media alta	Medio	bajo	Media
R33	Media alta	Medio alto	bajo	Media
R34	Alta	Alto	Medio bajo	Media alta
R35	Baja	Bajo	Medio alto	Baja
R36	Media baja	Bajo	Alto	Media baja
R37	Media baja	Medio bajo	Alto	Media
R38	Media	Medio	Bajo	Media baja
R39	Media alta	Medio	Medio bajo	Media
R40	Alta	Alto	Medio	Media alta
R41	Baja	Bajo	Alto	Media baja
R42	Media baja	Bajo	Bajo	Baja
R43	Media baja	Medio bajo	Bajo	Media baja
R44	Media	Medio	Medio bajo	Media baja
R45	Media alta	Medio	Medio	Media alta
R46	Media alta	Medio alto	Medio	Media alta
R47	Alta	Alto	Medio alto	Alta
R48	Media alta	Medio alto	Medio bajo	Media alta

Fuente: Autor

Realizado por: Autor

Analizamos diferentes criterios para la formación de las reglas de inferencia difusa. Planteando que cuando se dispone de un área alta, la irradiancia también va ser alta pero no puede ser baja, media baja ni media. También, que el porcentaje de vacío de los tubos no depende del área del colector ni la irradiancia, pero el porcentaje de vacío si influye directamente en la eficiencia del colector solar. Adicionalmente al generar un numero de excesivo de reglas de inferencia difusa, es decir fomentando un criterio de posibilidades se genera un modelo cuyas variables de entrada no aportan valor a la salida. En la figura 14-3, se indica el modo de como incorporar las reglas de inferencia difusa para el entrenamiento del modelo ANFIS.

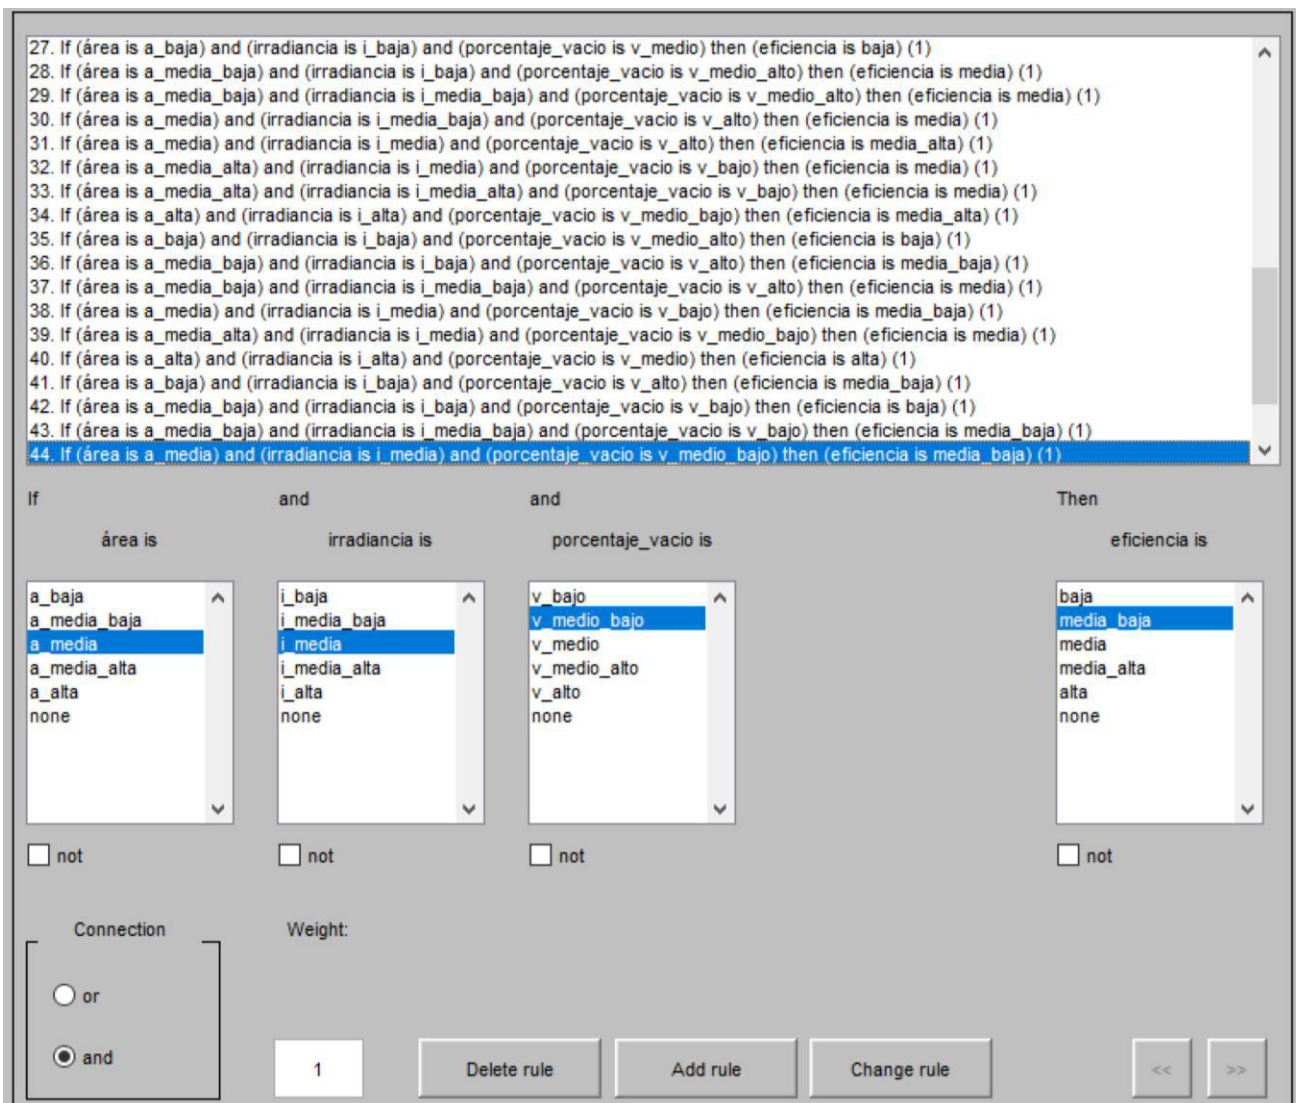




Figura 14-3: Introducción de reglas al sistema de inferencia difusa

Fuente: Autor


A continuación, se presenta la tendencia grafica que se requiere obtener de las diferentes entradas con respecto a la salida.



a) Variación de la eficiencia según el area



b) Variación de la eficiencia según la irradiancia



c) Variación de la eficiencia según el porcentaje de vacío.

Figura 15-3: Tendencia deseada de las variables de entrada respecto a la salida
fuente: Autor

Acotando, en la figura 16-3 se puede analizar el comportamiento de la variable de salida segunda la variación de las entradas, de esta manera existe una mayor facilidad para el entendimiento de cómo se comporta el modelo.

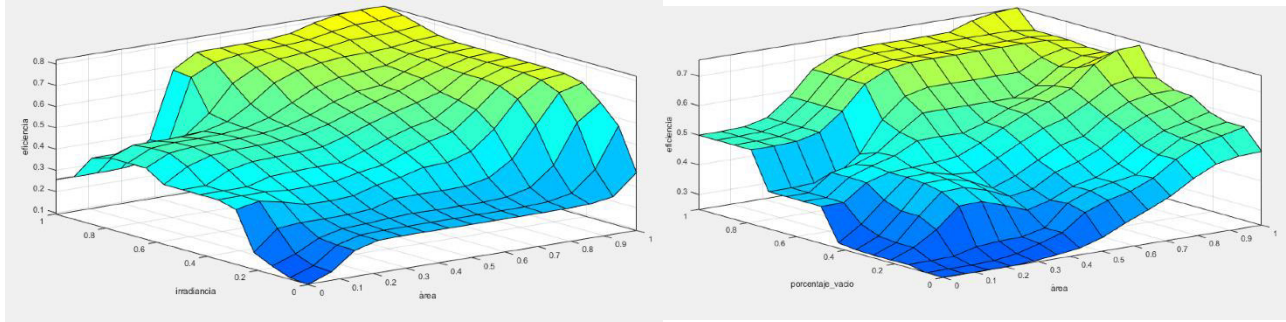


Figura 16-3: Grafico 3D del comportamiento del modelo ANFIS

fuelle: Autor

3.2.4. Entrenamiento ANFIS

Parámetros que acceden al sistema neuro difuso deben representar la problemática que se espera solucionar. Para este modelo ANFIS existes dos factores que necesitan ser capacitados:

- **Parámetros de los antecedentes:** son los coeficientes que determinan las funciones de activación de los arreglos difusos. Para este modelo ANFIS se emplearon, funciones de membresía tipo gaussmf para las variables de entrada excepto para el porcentaje de vacío de los tubos la cual se implementó de tipo trimf. Adicionalmente, para la variable de salida se utilizó de tipo trimf.
- **Parámetros del consecuente:** la salida del modelo de inferencia está regido por parámetros lineales. Emplea un aprendizaje hibrido el cual consiste en aplicar algoritmos de mínimos cuadrados para obtener parámetros cuadrados y de gradiente descendiente para optimizar estos parámetros. Este tipo de aprendizaje genera una doble ventaja al implementar la lógica, concatenado mediante la red adaptativa, tiene como fin perfeccionar las reglas difusas.

3.2.5. Conclusiones ANFIS

Matlab es una herramienta enfocada para modelar y representar el modelo ANFIS.

Al utilizar esta toolbox que posee matlab para desarrollar un modelo que simule el comportamiento de un sistema deseado, empleando mecanismos con distintas clases y cifras de MF al ingreso para luego obtener valores que sirven para entrenar una red neuronal artificial. Adicionalmente, se determino que mientras mas MF por entrada, Las salidas tienden a ser mejores.

Al tratar de implementar la metodologia Takani-Sugeno al entrenamiento ANFIS se determino que la variable de salida estaba atada a un analisis muy concreto, siendo este un tipo de funcion lineal o constante. Indicado en la figura 17-3.

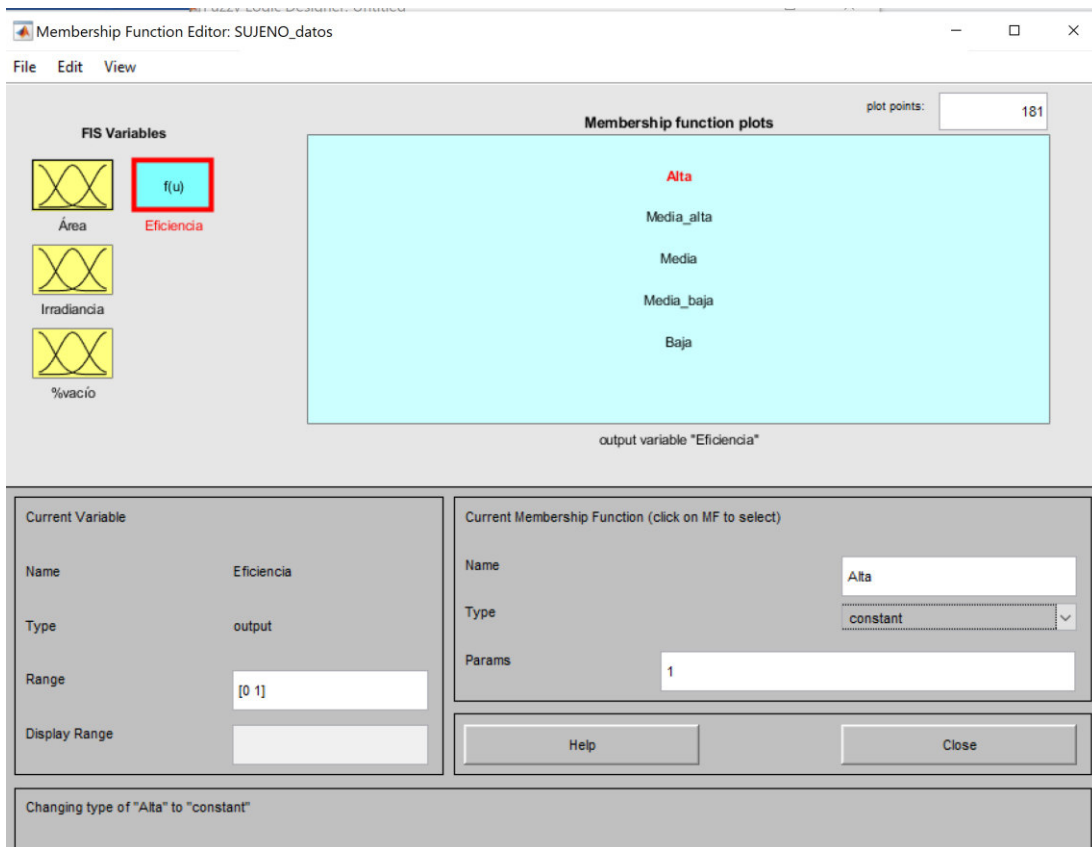


Figura 17-3: Variable de salida de la metodología Takani-Sujeno

Fuente: Autor

3.3. ANÁLISIS DE DATOS PARA ENTRENAMIENTO DE LAS REDES NEURONALES

Generalmente, la parte con mayor dificultad para conseguir una ANN entrenada se sustenta en la recopilación y preparación de los datos de entrada. En este paso de procesamiento se busca analizar y normalizar los datos, de forma que la entrada y salida se encuentren entre 0 a 1.

3.3.1. Bifurcación de datos

Al modelar una red neuronal artificial, normalmente se generan 3 conjunto de elementos: prueba, validación y entrenamiento. Una vez generados mediante la interacción de posibilidades de las diferentes reglas difusas y normalizar los conjuntos de valores, se realiza la división de valores de forma aleatoria, como si indica en la tabla 9-3. Adicionalmente, aquellos valores se representan en el ANEXO A.

Tabla 9-3: Partición de la base de datos.

División de los datos	Porcentajes
Entrenamiento	70 %
Validación	30 %

Fuente: Autor

Realizado por: Autor

Al ser los tipos de redes neuronales clasificadas según su método de entrenamiento, en el grupo de aprendizaje por corrección de error. Es necesario, desarrollar un método con un tipo de red neuronal artificial con entrenamiento híbrido, Radial Basis Exact Fit se ajusta a este requerimiento. Al mismo tiempo, la función de activación, aprendizaje y validación en las ANN se analizarán en este trabajo.

3.3.2. Desarrollo del modelo Redes Neuronales Multicapa (NNML), entrenamiento supervisado

Se obtiene la información que interviene en el desempeño del sistema y se tiene conocimiento sobre las definiciones de ANN, proseguimos con el presente proyecto.

- Escogemos tres neuronas en la capa de ingreso (Área del colector, Irradiancia, porcentaje de vacío de los tubos), la capa oculta 7 neuronas (valor subjetivo determinado por la fórmula 18) y una neurona en la capa de salida (eficiencia).
- Seleccionamos los pesos sinápticos de entrada para las conexiones (aleatoria).
- Elección del algoritmo de entrenamiento (GDM y GDY).
- Selección de la función de activación.
- Validación y pruebas.



Figura 18-3: Pasos operativos de las redes neuronales artificiales

Fuente: (Matich Damián, 2001)

Cantidad de Capas

Por temas de ahorro en recursos computacionales y debido a que el sistema no represente una complejidad elevada se decide crear un modelo con una sola capa oculta.

El sistema representado con tres neuronas en la entrada, siete neuronas ocultas y una neurona a la salida:




Figura 19-3: Configuración de ANN para el sistema
Fuente: Autor

Cantidad de neuronas

En la capa de ingreso no se emplean funciones de activación, ni se modifican pesos sinápticos por lo cual, tenemos 3 neuronas representando las variables de entrada: área del colector, irradiancia, porcentaje de vacío. Mientras, que la cantidad de neuronas en la capa oculta se obtiene de manera subjetiva, inicialmente con la fórmula 18, donde n es la cantidad de entradas de la red (3 para este sistema), dando como resultado 7 neuronas, pero este valor se modificara a 20 y 50 neuronas para verificar resultados.

$$\#neuronas = 2 * n + 1 \quad [18]$$

En la capa de salida, se representa con una neurona indicando la eficiencia del sistema.

$$f(\text{Area}, G, \%vacío) \rightarrow \text{eficiencia} \quad [19]$$

- **Área del colector (A):** Es la superficie del colector solar. [m^2]
- **Irradiación (G):** cantidad de energía que admite una superficie, en un intervalo de tiempo. [MJ/m^2] ó [kWh/m^2]
- **Porcentaje de vacío (%vacío):** porcentaje para disminuir las pérdidas de calor hacia el ambiente.
- **Eficiencia (n):** Es la razón entre la energía admitida por el fluido acarreador del calor y la energía incidente sobre su superficie.




Figura 20-3: Determinación de entradas y salidas de ANN
Fuente: Autor

La red neuronal artificial es representada de forma estructural en la figura 20-3, indicando las variables utilizadas en esta tesis de grado.

Selección de la estructura de ANN

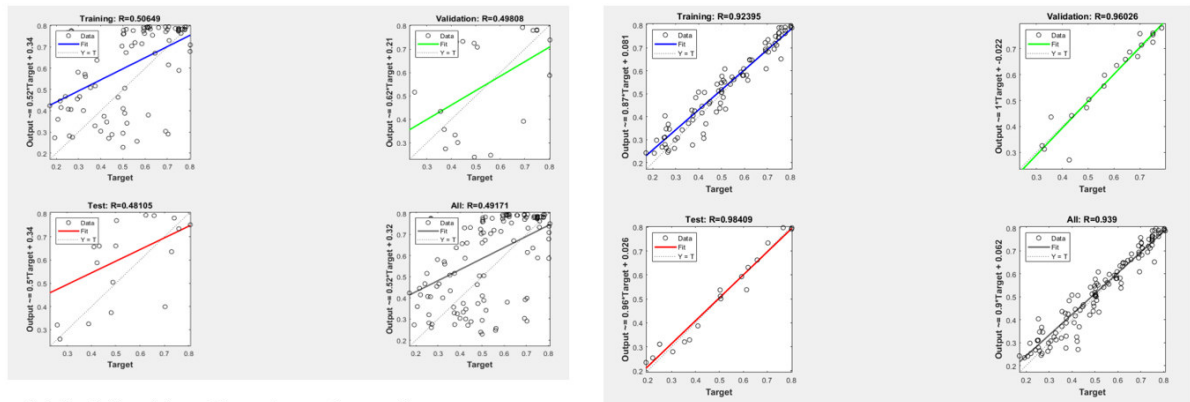
En el software Matlab se inserta los valores de ingreso de cada variable respectivamente (3), valores de salida (1), se selecciona la cantidad de neuronas en la capa oculta (7), la función de transferencia (TANSIG), la función de entrenamiento (TRAINGD), función adaptativa de aprendizaje (LEARNGDM), rendimiento (MSE) y obteniendo la estructura de la red neuronal.

3.3.3. Elección del grupo de técnicas de entrenamiento

Un periodo trascendental para una ANN es el proceso de entrenamiento, el cual consiste en variar los pesos sinápticos de las bias de conexión de una forma sistemática manejando una técnica aprendizaje que mejor se ajuste al sistema que se intenta modelar. La entrada es presentada conjuntamente con la salida deseada, de tal manera que los pesos sinápticos son ajustados de cada neurona para obtener la salida deseada.


Al existir distintas técnicas de entrenamiento: Backpropagation (BP), Levenberg-Marquardt (LM), híbrido, etc. La red neuronal multicapa se basan en las redes

Feedforward Backpropagation y Layer Recurrent, el algoritmo de entrenamiento de tipo Backpropagation es el método más usado, mientras que el algoritmo de Levenberg-Marquardt es el más veloz, Matlab tiene mecanismos como los algoritmos Levenberg-Marquardt (LM), descenso de gradiente con momento (GDM), Retropropagación de tasa de aprendizaje variable (GDX) que sirven para el entrenamiento.




a) Validación-Prueba sin entrenar

b) Validación-Prueba con entrenamiento



c) Validación-Gradiente sin entrenamiento



d) Validación-Gradiente con entrenamiento

Figura 21-3 Entrenamiento de redes neuronales artificiales

Fuente: Autor

En la figura 21-3 se indica los valores en la ANN sin entrenamiento alguno y luego los datos en la red neuronal con entrenamiento, adicionalmente las gráficas de entrenamiento del dato del gradiente. Se analizan los valores que constituyen el área del colector, irradiancia y porcentaje del calentador solar con tubos de vacío.

Función de activación

Las funciones de activación más utilizadas en este tipo de redes neuronales son la función Tangente Hiperbólica (TANSIG, Ec. 20) se emplea donde existen variaciones suaves de valores y la función lineal (Pureline, Ec. 21) para la capa oculta y la de salida correspondientemente: (Llano et al., 2007)

$$\text{TANSIG}(M) = \frac{e^M - e^{-M}}{e^M + e^{-M}} \quad [20]$$

$$\text{Lineal: } f(M) = M \quad [21]$$

Se escoge la función de activación apropiada y encontrar el más óptimo desempeño del modelo. Por tal motivo incluimos en un breve análisis a la función de activación sigmoidea logarítmica:

$$\text{Logsig}(n) = \frac{1}{1 + \exp^{-n}} \quad [22]$$

3.3.4. Conclusiones NNML

Los parámetros seleccionados para implementar en las redes neuronales multicapa con entrenamiento supervisado, se indican en la tabla 10-3.

Tabla 10-3: Parámetros de las redes neuronales multicapa

TIPO DE RED	Feedforward/Layer Recurrent
FUNCIÓN DE ENTRENAMIENTO	Train GDM/GDX
FUNCIÓN DE APRENDIZAJE	LEARN GDM
FUNCIÓN DE TRANSFERENCIA CAPA OCULTA	TANSIG/LOGSIG
FUNCIÓN DE TRANSFERENCIA DE LA CAPA DE SALIDA	Pureline
NÚMERO DE NEURONAS EN LA CAPA OCULTA	7/20/50
NÚMERO DE ÉPOCAS	5000
NÚMERO DE CAPAS OCULTAS	2/3
NÚMERO DE VALIDACIÓN MÁXIMO DEL ERROR	500
DATOS PARA ENTRENAMIENTO	500

Realizado por: Autor

- En la etapa de entrenamiento se ingresan variables de entrada y salida que interactúan hasta que se obtiene un resultado deseado.
- La configuración más óptima de las redes neuronales NNML fue obtenida mediante la selección de parámetros tales como: cantidad de capas ocultas, cantidad de neuronas en la capa oculta, tipo de función de activación, función de entrenamiento, tipo de ANN. Al obtener el valor más cercano a 1 del coeficiente de determinación, se sabrá de la configuración de la red más óptima y los pesos sinápticos son los utilizados para tomar decisiones.
- Mediante criterios estadísticos como: el error cuadrático medio (RMSE), error porcentual absoluto (MAPE), error cuadrático medio (MSE) y el coeficiente de correlación (R2); se evalúa el rendimiento de la red general con los datos generados de entrada y salida mediante el método ANFIS.

3.3.5. Desarrollo del modelo Radial Basis Exact Fit (NRRB), entrenamiento híbrido

El método de entrenamiento que se utilizará en este trabajo para esta clase de ANN será híbrido, en el cual la cantidad de neuronas y pesos en la capa oculta y los umbrales de la capa de salida son calculados automáticamente por el software. Como se puede observar en la figura 22-3.

El único valor que se modifica es la constante de propagación, la cual determina la activación dentro del cluster de datos. Si el valor de la propagación es alto los puntos de datos se dispersarán lejos del centro, lo que conlleva a una eficiencia baja. Por lo tanto, de diversos trabajos (Martin & Choi, 2016),(K.S. Kasiviswanathan, 2012) se concluye que le mejor valor para entrenar la red es 1.

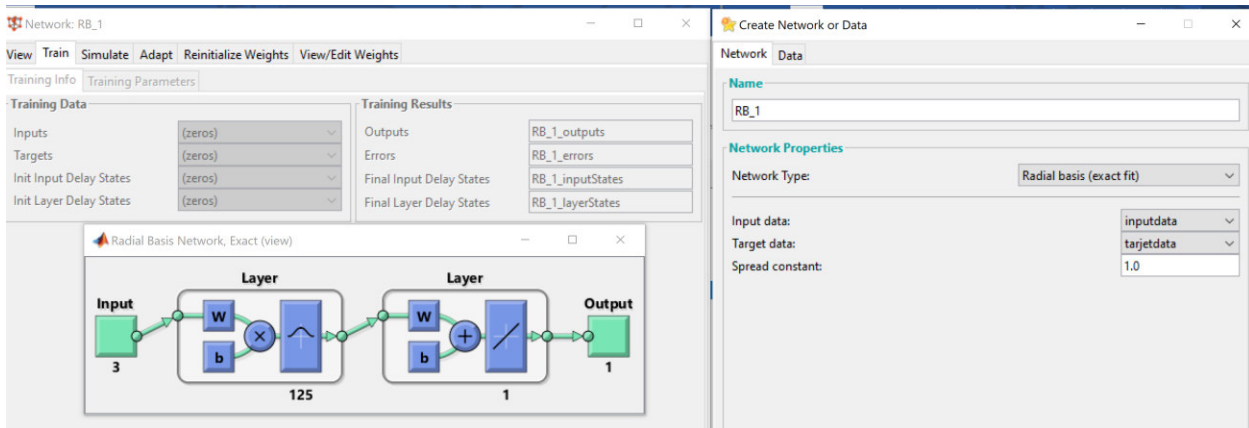


Figura 22-3: Radial Basis entrenamiento híbrido
Fuente: Autor

3.4. SIMULACIÓN DEL MODELO CON INTELIGENCIA ARTIFICIAL

3.4.1. Métodos estadísticos para la valoración del desempeño de los modelos NNML

La validación de los modelos Multicapa Feed-Forward Backpropagation, Layer Recurrent y Radial Basis Exact Fit se realizan fundamentalmente con R^2 , MSE, RMSE, MAPE; pero este análisis se debe realizar con el conjunto de datos de validación que son diferentes al conjunto de datos empleados para el entrenamiento. Es relevante indicar que el grupo de datos de validación, tiene gran vinculación con el problema que se intenta solucionar.

Se realiza el entrenamiento y pruebas de diversas tipologías variando la cantidad de iteraciones, cantidad de épocas, cantidad de neuronas en la capa oculta y función de entrenamiento para alcanzar la arquitectura optima del modelo. Al final se produce un escrito con la valoración del desempeño de la red. Las ecuaciones de las diferentes técnicas estadísticas empleados son:

El error en el proceso de entrenamiento se denomina error cuadrático medio (MSE):

$$MSE = \frac{1}{n} \sum_{i=1}^n (\bar{Y}_i - Y_i)^2 \quad [23]$$

RMSE indica la cantidad de error que existe entre 2 conjuntos de datos:

$$RMSE = \sqrt{\frac{\sum_1^n (Y_{pre,m} - t_{mea,m})^2}{n}} \quad [24]$$

Dónde:

- $t_{mea,m}$ = Valor medido
- $Y_{pre,m}$ = Salida predicha
- n = Cantidad de valores empleados en entrenamiento y validación

Además, R^2 , es el indicador que nos permite conocer que tan bien se van a predecir esos resultados:

$$R^2 = 1 - \left(\frac{\sum_j (t_j - o_j)^2}{\sum_j (o_j)^2} \right) \quad [25]$$

Finalmente, MAPE, indica la desviación en términos porcentuales.

$$MAPE = \frac{o-t}{o} * 100 \quad [26]$$

Dónde:

- t = Valor objetivo
- o = Valor de salida

3.4.2. Desarrollo de la programación de los modelos con técnicas de inteligencia artificial

Actualmente, se encuentran diversas softwares para desarrollar modelos con tecnicas de inteligencia artificial pero las mas importantes son Matlab y Python. La principal característica positiva de Python es su licencia libre pero no tiene la herramienta para trabajar con logica difusa, lo que implico que no se pudo utilizar en el transcurso de la

investigación. Por otro lado, el software Matlab R2020b es utilizado debido a que tiene diferentes funciones como: fuzzy que nos posibilita crear datos mediante un sistema de inferencia difuso, procesamiento, estandarizacion de valores para entrenar y validar una ANN utilizando la funcion nntool. En los siguientes puntos se detallaran los pasos para generar modelos de IA obteniendo la eficiencia del sistema.

3.4.3. Ingreso de datos de entrenamiento

Con la finalidad de entrenar los modelos de IA multicapa, se ingresan los datos clasificados y normalizados desde una hoja electrónica, donde el 70% son para entrenamiento de la red y 30% para la validación (ANEXO C).

	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	0.0689	0.0689	0.0689	0.0689	0.0689	0.2510	0.2510	0.2510	0.2510	0.2510	0.5000	0.5000	0.5000	0.5000
2	0.0689	0.2470	0.5000	0.7760	0.9360	0.0910	0.2510	0.4960	0.7670	0.9360	0.1040	0.2820	0.4910	0.7760
3	0.0686	0.0686	0.0686	0.0686	0.0686	0.2540	0.2540	0.2540	0.2540	0.2540	0.4980	0.4980	0.4980	0.4980
4														

Figura 23-3: Introducción de valores estandarizados para entrenamiento y prueba
Fuente: Autor

3.4.4. Introducción a Matlab para crear redes neuronales

Una vez obtenido el conjunto de datos, vamos a dividirlos aleatoriamente en dos partes, el 70% se ejecutará para el entrenamiento de ANN en el módulo Neural Networks Toolbox del software matemático MATLAB, el código <<nntool>> se escribe en la ventana de comando del software para ingresar al toolbox; el 30% se ejecutará para las fases de validación y evaluación, todo esto con la finalidad de obtener un subconjunto representativo de la distribución de datos. Dicho toolbox incorpora técnicas de aprendizaje seleccionables en esta tesis de grado se utilizará TRAINGDM y TRAINGDX.

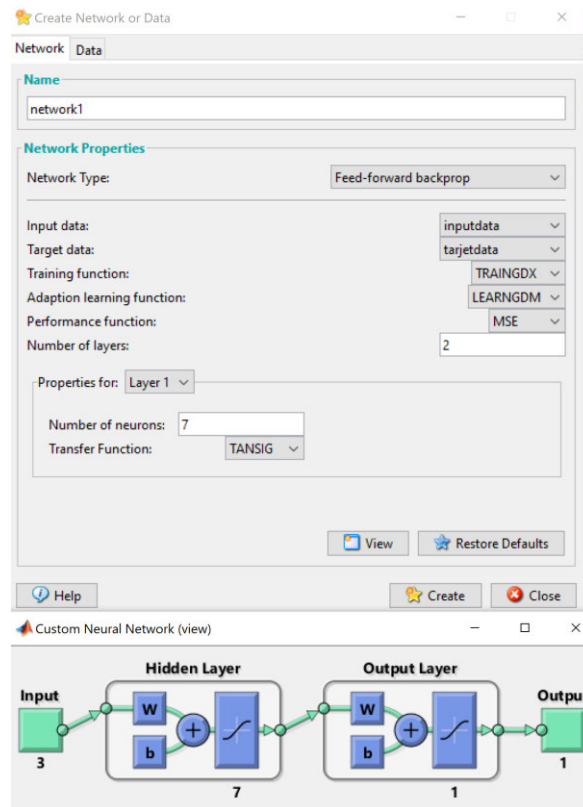


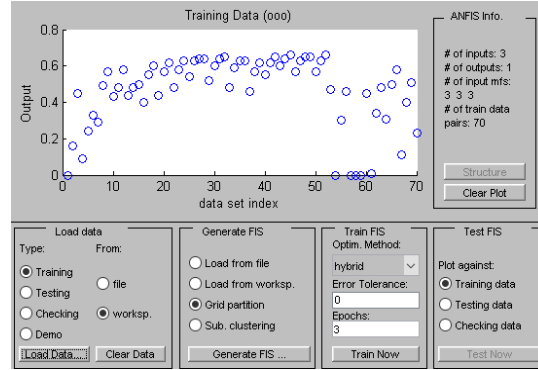
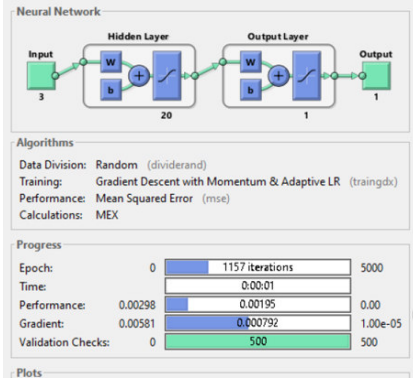
Figura 24-3: Configuración de la arquitectura de la red neuronal

Fuente: Autor

3.4.5. Generación de la red

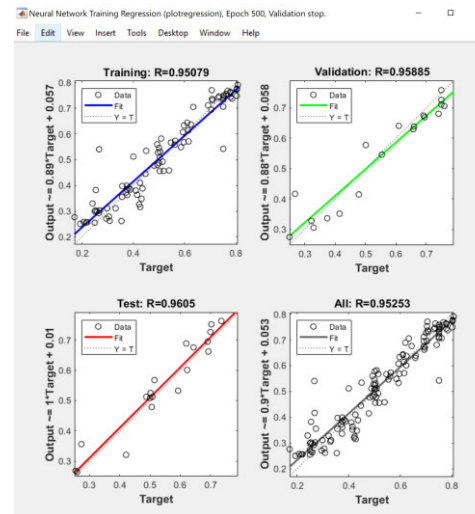
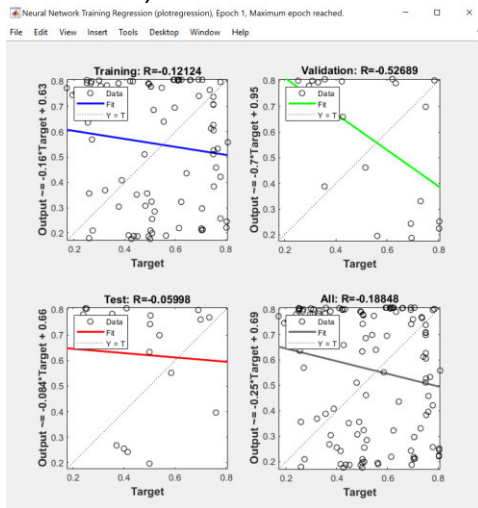
La red neuronal multicapa se configurar con las siguientes características: Feed-forward Backpropagation es el tipo de red, TRAINGDX es el algoritmo de entrenamiento tasa de aprendizaje variable. La función de aprendizaje adaptable LEARNNGDM, que significa gradiente descendiente.

La función de activación elegida es la TIPO TANSIG. La función de rendimiento es la MSE que indica el error cuadrático medio entra la salida de la red obtenido y la salida deseada. Cantidad de capas ocultas (2), la cantidad de neuronas en la capa oculta (20); representado en la figura 25-3.



a) ANN 500 valores

b) Valores de entrenamiento



c) Entrenamiento erroneo.

d) Entrenamiento correcto

Figura 25-3: Características de NNML

Fuente: Autor

3.4.6. Entrenamiento de los modelos

Cuando las ANN con entrenamiento supervisado se encuentran diseñadas, se prosigue a su entrenamiento. Por concretar este paso, se tendrá que corroborar los datos de entrada y salida de la red. A continuación, se detallan las características de entrenamiento.

- El gradiente mínimo (min_grad), equivale el número mínimo que alcanzará el gradiente para poder cesar la etapa de entrenamiento.
- El valor máximo de épocas (epochs), se ingresará 5000, por defecto son 100.
- El tiempo que tomara la simulación, es infinito por defecto.

- El máximo número de iteraciones 500 (max_fail). Si se alcanzara este valor significará que la ANN está disipando su facultad de difusión y se finalizara el entrenamiento, por defecto son 6.
- El máximo error permitido, que es el propósito para detener el entrenamiento, por definición viene indicado en 0 pero es complejo obtener ese dato por lo que se ingresa un valor de 0,001.

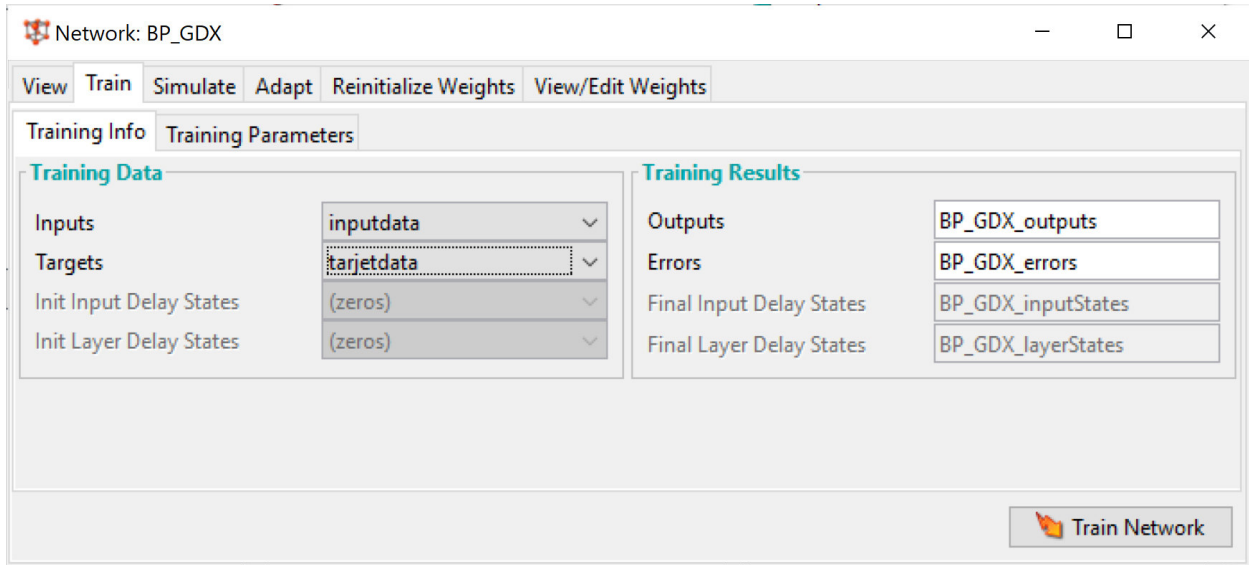
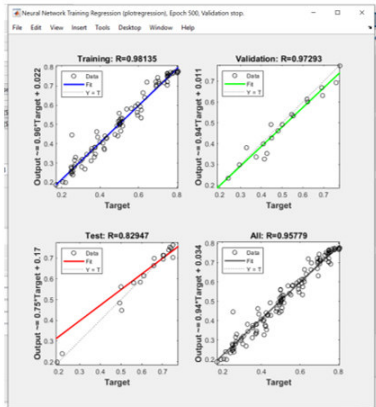


Figura 26-3: Entrenamiento ANN


Fuente: Autor

3.4.7. Realizar la simulación

En este punto verificamos que el entrenamiento de la ANN ha sido correcto ingresando el conjunto de datos (testdata) que vienen a ser 36 datos (30% del total de datos generados). Este conjunto de datos es procesado y se puede verificar mediante técnicas estadísticas que los resultados son idénticos a los generados, en otras palabras, la predicción de resultados es muy buena. En la figura 27-3 se comprueba el buen rendimiento de la ANN. Por tal razón, Matlab nos entrega información que a posterior nos dará información necesaria para analizar el sistema analizado.



a) Entrenamiento de la red



b) Datos de entrenamiento y prueba

Figura 27-3: Obtención de datos del entrenamiento

Fuente: Autor

Los datos obtenidos de los NNML tanto con entrenamiento supervisado e híbrido son expedidos al workshop de Matlab para luego ser analizados en tablas de Excel mediante una serie de criterios estadísticos que fueron mencionados anteriormente.

Por otra parte, puede existir el caso en el que se sobreentrena la red neuronal con el objetivo de obtener un error mínimo absoluto. Adicionalmente, se tiene el perjuicio de que no hay como sistematizar de forma idónea la ANN con otros valores ya que solo se acerca a los valores de entrada y salida, por esta razón, no se aconseja sobreentrenar la red neuronal y de esa manera se pueda generalizar los resultados de manera idónea. En fin, Matlab tiene a su disposición una serie de funciones que permiten entrenar, validar y se demuestra que son de gran utilidad para desarrollar otros proyectos de investigación en diversos campos para después aplicarlos tanto en predicción, optimización y control.

En el anexo B, se puede apreciar diversas arquitecturas empleadas para el entrenamiento de la ANN, hasta obtener una red con el mayor rendimiento posible.

3.5. OPTIMIZACIÓN DE LA EFICIENCIA DE LOS COLECTORES SOLARES CON TUBOS DE VACÍO DE USO DOMÉSTICO

3.5.1. Determinación de los parámetros óptimos del sistema

Se analizan hasta qué punto los parámetros que se utilizaron para realizar el modelo ANFIS pueden ser optimizados y de esa manera obtener la mejor eficiencia posible de colectores solares con tubos de vacío de uso doméstico para la ciudad de Riobamba. Sin embargo, los parámetros de construcción que se optó para modelar el sistema se encuentran limitados por factores de espacio, parámetros del fabricante y fenómenos físicos. Adicionalmente, el área del colector solar como el porcentaje de vacío son características que pueden ser susceptibles a cambios para ajustarse a diseños o condiciones climatológicas requeridas.

Por tal razón, fue imperativo analizar estas variables para crear funciones de membresía y reglas de dispersión difusa, con el fin de crear un modelo con técnicas de inteligencia artificial que nos permita obtener valores de eficiencia del colector según cuanto varíe cada variable.

Sobre ideas expuestas, se plantea poner como referencia el siguiente colector solar con tubos de vacío marca SOLARIS, el cual viene a ser uno de los colectores con el área más grande que se comercializa en Latinoamérica. De esta manera, se buscará obtener la eficiencia de uno de los colectores con el área más grande y poder generar una discusión con el fin de analizar hasta qué punto se puede optimizar el área del colector solar. Adicionalmente, el porcentaje de vacío en los tubos es una variable que el fabricante establece según los materiales que se hayan utilizado para su manufactura y la presión atmosférica donde va a ser instalado, el análisis de este parámetro a optimizar tiene la misma metodología que se utiliza en el área del colector. Las características del colector solar vienen mostradas en la imagen 28-3.

Ficha Técnica

Calentador Solar



Generalidades

Tipo	Gravedad
Presión máxima de operación kg/cm ²	0.4 kg/cm ²
Pendiente	23°

Termotanque

Material interior del termotanque	Acero inoxidable Calidad Alimenticia SUS304-B
Espesor del interior de lámina de acero	0.51
Material exterior del termotanque	Acero inoxidable 304-BA
Espesor del exterior de lámina de acero	0.41
Material aislante	Poliuretano
Espesor del material aislante	50 mm.
Sello del tanque para entrada de tubos	Silicón



Estructura

Material de estructura	Acero inoxidable 202
Espesor del interior de lámina de acero	1.2 mm



Tubo al vacío

Material	Borosilicato
Medidas	1,800 mm x 58 mm
Espesor	1.8 mm
Recubrimientos	Barium, nitrato de aluminio y cobre



Otros

Anodo de sacrificio	Barra de magnesio
Vida útil	25 años
Garantía del tanque	5 años

Capacidades		Medidas	Largo	Alto	Ancho
8 tubos	84 lts		195 cm	110 cm	85 cm
10 tubos	130 lts		195 cm	110 cm	100 cm
12 tubos	150 lts		195 cm	110 cm	120 cm
15 tubos	173 lts		195 cm	110 cm	145 cm
18 tubos	206 lts		195 cm	110 cm	160 cm
20 tubos	228 lts		195 cm	110 cm	185 cm
24 tubos	273 lts		195 cm	110 cm	210 cm
30 tubos	340 lts		195 cm	110 cm	340 cm
40 tubos	450 lts		195 cm	110 cm	365 cm

Figura 28-3: Ficha técnica colectores solares marca SOL-5820SS

Fuente:(SOLARIS, 2022)

Se torna necesario, analizar un segundo colector solo de la marca Amawtec que se comercializa en Ecuador cuyas características vienen a ser las más altas en el mercado, en la figura 29-3 se indican las características de este colector.

Datos técnicos

Colector solar tubos de vacío alemán

Cantidad de tubos	30 tubos de vacío heat pipe Ø24x90mm	Capacidad de calentamiento	Δ10 °C (4-6m ³)
Presión max	0,48Bar	Área de apertura	2,6m ²
Dimensiones	2,6 x 2,2 x 0,15m	Peso	75kg
Material de colector	Acero inoxidable 316	flujo	4,8 L/min
Temperatura de estancamiento	200°C	Producción de energía	5,4kW

0967012008

www.amawtec.com

Figura 29-3: Colector solar marca AMAWTEC

Fuente: (AMAWTEC, 2022)

Por otra parte, el parámetro de irradiancia al ser un fenómeno climatológico y que varía según la longitud y latitud donde este instalado el colector solar con tubos de vacío, necesita ser analizado para entender cómo afecta este parámetro a la eficiencia del colector solar y mucho más importante hasta qué punto máximo llegara este parámetro. Por tal efecto, los datos que se encuentra en la tabla 3-2, nos proporcionara la información necesaria para entender hasta qué punto el parámetro de irradiación puede ser optimizado.

CAPÍTULO IV

4. RESULTADOS Y DISCUSIÓN

4.1. PRUEBAS DE FUNCIONAMIENTO DE LOS MODELOS NNML Y ANFIS

A continuación, se indican los logros obtenidos por los modelos ANFIS y NNML, en optimizar y pronosticar la eficiencia del sistema implementado. Estudiando los logros, los modelos detallados consiguieron excelentes pronósticos (Anexo C), los datos de salida representan el buen rendimiento de los modelos. Las primordiales particularidades de los modelos realizados en el presente proyecto se indican en la tabla 11-4.

Tabla 11-4: Parámetros de los modelos ANFIS, NNML y NNRB

ANFIS	VALOR	NNML	VALOR
FUNCIÓN MEMBRESÍA IN	gaussmf	TIPO DE RED	FB/LR
FUNCIÓN MEMBRESÍA OUT	trimf	NUM CAPAS OCULTAS	2/3
REGLAS DIFUSAS	48	NEURONAS CAPA OCULTA	7/20/50
RANGE	[0-1]	FUNCIÓN TRANSFERENCIA	TANSIG/ LOGSIG
TIPO	mandani	FUNCIÓN APRENDIZAJE	LearnGDM
NÚMERO DE ENTRADAS	3	DATOS DE ENTRENAMIENTO	500
NÚMERO DE SALIDAS	1	DATOS DE PRUEBA	108
NÚMERO DE MF IN	5-5-5	MAX ITERACIONES	500
NÚMERO DE MF OUT	5	ALGORITMO ENTRENAMIENTO	GDM/GDX
NNRB		NUMERO DE EPOCAS	5000
CONSTANTE DE PROPAGACIÓN	1/2	FUNCIÓN DE RENDIMIENTO	MSE

Realizado por: Autor

4.2. RESULTANTES DE LAS CONFIGURACIONES DE LOS MODELOS ANFIS, NNML Y NNRB

Previa a la importación de los resultados predichos por los modelos desarrollados en Matlab. Los tres métodos desarrollados con redes neuronales son capaces de predecir la eficiencia del colector solar, pero se realiza un análisis comparativo para obtener el método con la mejor configuración, que entregue los resultados óptimos.




Figura 30-4: Comparación de resultados con los métodos desarrollados
Realizado por: Autor

4.2.1. Relación de los algoritmos de entrenamiento TRAINGDM y TRAINGDX en la red neuronal Feed-forward Backpropagation

Los resultados de las diferentes arquitecturas para obtener la mejor configuración de esta clase de ANN se indica en la tabla 12-4. Para lo cual se analizó RMSE, MAPE, R2 y MSE; entre los datos simulados por ANFIS y las diversas arquitecturas de esta red neuronal. Para realizar este análisis se modifica la cantidad de capas ocultas, neuronas en la capa oculta y los dos tipos de algoritmos de entrenamiento GDM (Backpropagation

con Momento) y GDx (algoritmo Gradiente Descendiente con impulso y Backpropagation de tasa de aprendizaje adaptable).

Tabla 12-4: Comparación de rendimiento de las diferentes arquitecturas NNBP

ALGORITMO GDM/GDX	ARQUITECTURA	RMSE	MAPE	R^2	MSE
2 capas ocultas					
GDM	3-7-1	0.08139	4.6255	0.8008	0.0066
GDM	3-20-1	0.080	4.087	0.8084	0.00641
GDM	3-50-1	0.07485	2.1163	0.8395	0.00560
GDX	3-7-1	0.0629	1.3168	0.8816	0.0040
GDX	3-20-1	0.04346	0.42549	0.9434	0.00188
GDX	3-50-1	0.05157	1.1330	0.9198	0.00286
3 capas ocultas					
GDM	3-7-1	0.0780	1.9769	0.8200	0.0061
GDM	3-20-1	0.0821	3.5153	0.7973	0.0067
GDM	3-50-1	0.0723	4.1230	0.8462	0.0052
GDX	3-7-1	0.065	2.8423	0.8703	0.00429
GDX	3-20-1	0.0547	2.10004	0.9096	0.00299
GDX	3-50-1	0.0532	1.2804	0.9147	0.0028

Realizado por: Autor

4.2.2. Comparación de rendimiento de los diferentes modelos de redes neuronales multicapa

Una vez obtenida la arquitectura de la red neuronal Feed-forward Backpropagation con mayor rendimiento, se procede a analizar que función de activación genera un mayor rendimiento. Adicionalmente, se analiza la red neuronal Layer Recurrent con la arquitectura que mayor eficiencia (2 capas ocultas, algoritmo de entrenamiento TRAINGDx, 20 neuronas en la capa oculta) que se generó en la red neuronal Feed-forward Backpropagation, en la tabla 13-4 se analizan los resultados.

Tabla 13-4: Comparación de rendimiento de los algoritmos NNML

Tipo de red neuronal	Función de activación	RMSE	MAPE	R^2	MSE
NNFB	TANSIG	0.04346	0.42549	0.9434	0.00188
NNFB	LOGSIG	0.0575	1.9144	0.9014	0.0033
NNLR	TANSIG	0.0613	2.4060	0.8865	0.0038
NNLR	LOGSIG	0.0659	3.3312	0.8692	0.0043

Realizado por: Autor

La red neuronal Feed-forward Backpropagation con la función de entrenamiento TANSIG es la que tiene un rendimiento más alto frente a la red neuronal Layer Recurrent. Adicionalmente la función de entrenamiento TANSIG genera resultados convenientes en ambas redes neuronales.

Finalmente, entra en análisis la red neuronal Radial Basis Exact Fit con la diferencia de que el tipo de entrenamiento de esta red neuronal es híbrido por tal razón, Matlab nos permite únicamente modificar el parámetro de constantes de propagación. En la tabla

Tabla 14-4: Comparación de rendimiento NNRB según su constante de propagación.

Tipo de red neuronal	Constante de propagación	RMSE	MAPE	R^2	MSE
NNRB	1	0.000014	0.001138	0.9999	0.0000
NNRB	2	0.03586	0.70935	0.9611	0.001286

Realizado por: Autor

4.2.3. Pronóstico de la eficiencia con diferentes conjuntos de datos

Se obtuvo que las cantidades pronosticadas mediante los modelos con redes neuronales artificiales están muy cercanos a los valores simulados mediante el modelo ANFIS. En el anexo D, se indican a los conjuntos "A" y "B" con 108 datos cada uno, que se emplearán para poder realizar el análisis paramétrico de los modelos, debido a que, al ingresar un conjunto de datos diferente al que se utilizó en las diferentes simulaciones (datos ANEXO A) para obtener los diversos valores de rendimiento de los modelos en los puntos anteriores. Cabe mencionar, que se escogerán las arquitecturas y características de las redes neuronales que mayor rendimiento tuvieron en el apartado 4.2.2, en la tabla 15-4 se presentan los resultados alcanzados.

Tabla 15-4: Análisis de rendimiento de las mejores características de las redes NNML

Tipo de red neuronal	RMSE	MAPE	R^2	MSE
CONJUNTO "A"				
NNFB	0.0310	1.4048	0.9664	0.0010
NNLR	0.05121	1.63948	0.91127	0.00262
NNRB	0.00001258	0.00071741	0.9999	0
CONJUNTO "B"				
NNFB	0.0302	1.7316	0.9725	0.0009
NNLR	0.0709	3.5287	0.8493	0.0050
NNRB	0.000014	0.00090	0.9999	0

Realizado por: Autor

Al realizar las simulaciones con diferentes conjuntos de 108 y 375 datos, se puede observar en las tablas 15-4 y 16-4 que los rendimientos varían notoriamente en las redes neuronales Feed-Forward Backpropagation y Layer Recurrent pero en la red neuronal Radial Basis Exact Fit se mantiene fijo el rendimiento de esta red al fijarnos al parámetros

del coeficiente de correlación, que nos permite conocer que tan bien se pueden predecir esos resultados.

4.2.4. Valoración de desempeño de los modelos con redes neuronales

La comparación final de este trabajo es tomar la mejor arquitectura y configuración de los diferentes parámetros de las redes neuronales, cuya validación se realizará mediante la función RMSE, MAPE, R^2 y MSE substituyendo en las funciones y análisis de cada parámetro estadístico. (Anexo F)

Tabla 16-4: Valoración de los parámetros de rendimiento del colector solar NNML

MÉTODO	EVALUACIÓN DE LOS CRITERIOS DE RENDIMIENTO TÉRMICO			
	RMSE	MAPE	R^2	MSE
NNBP	0.04346	0.42549	0.9434	0.00188
NNLR	0.0613	2.4060	0.8865	0.0038
NNRB	0.000014	0.001138	0.9999	0.0000

Realizado por: Autor

En la figura 31-4, se expone R^2 de los diferentes modelos desarrollados con técnicas de inteligencia artificial. El valor de R^2 determina el rendimiento que tiene el modelo desarrollado, se entiende que entre más cercano es el valor a 1 mejor es el rendimiento.

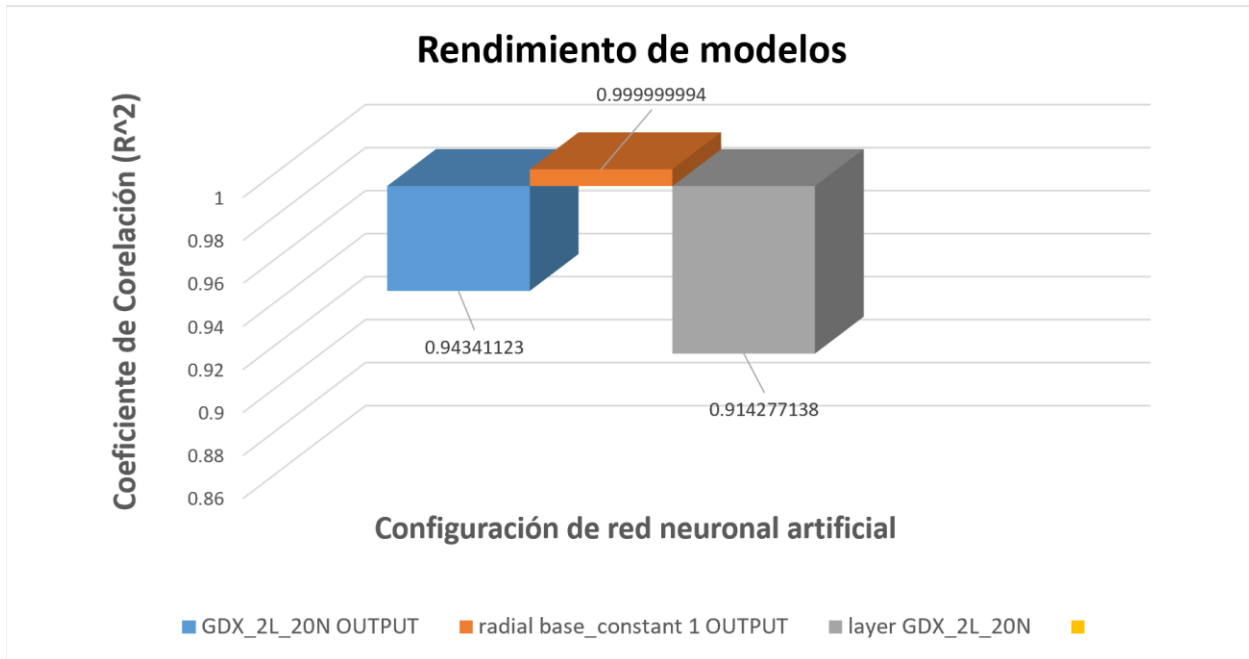


Figura 31-4: Análisis de rendimientos de los modelos desarrollados

Fuente: Autor

4.3. CÁLCULO DE LA EFICIENCIA ÓPTIMA PARA EL SISTEMA.

Para calcular la eficiencia óptima de este sistema es necesaria la utilización del método ANFIS creado en Matlab, pero es necesario realizar este análisis conjuntamente con modelo de colectores solares ya fabricados que se distribuyen en el mercado latinoamericano y ecuatoriano respectivamente. El primer colector solar analizado fue el SOL-5820SS con un área de 7.10 m^2 y una presión máxima de operación de $0.4 \frac{\text{kg}}{\text{cm}^2} = 0.392 \text{ Bar}$. Cabe recalcar, que el área de este colector es la máxima que se fabrica en este modelo, debido a condiciones de peso y uso del espacio en los techos de las viviendas este factor es limitado. También el precio influye en este parámetro dado que este modelo oscila el precio de 580 dólares americanos.

Para obtener el porcentaje máximo de vacío que soportan los tubos de vacío heat pipe, se toma en cuenta la presión atmosférica donde estará instalado el colector solar, para la ciudad de Riobamba 0,7255 Bar es la presión atmosférica media del año 2021, este dato se obtuvo de la Estación Meteorológica ESPOCH. Con este dato se puede descifrar mediante una regla de tres que el porcentaje de vacío que soporta es 54%. La ventaja

que se genera debido a que el colector solar este ubicado en la ciudad de Riobamba es que el porcentaje de vacío de los rubos puede aumentar dado a que la manufactura de estos tubos de vacío es generalmente al nivel del mar y esta condición limita dicho porcentaje. Cabe mencionar que este porcentaje de vacío está limitado por la resistencia a la implosión que tienen este tipo de tubos según los materiales empleados para su manufactura.

Adicionalmente, el factor climatológico que este caso viene a ser la Irradiancia en la ciudad de Riobamba, viene a ser un parámetro a tomar en cuenta al momento de optimizar dichos sistemas ya que depende netamente del lugar donde serán colocados. Para este caso el valor de Irradiancia media del año 2021 obtenido de la Estación Meteorológica ESPOCH es $677.13 \frac{W}{m^2}$.

Finalmente, el cálculo de la eficiencia optima del colector solar marca SOL-5820SS se aplica con las premisas mencionadas anteriormente, aunque previamente se deben fuzificar el valor de las entradas para obtener la eficiencia de 0.657, desfuzificando este valor se obtiene un 65.7% de eficiencia; los resultados de la simulación se indican en la figura 32-4.




Figura 32-4: Resultados de eficiencia del Colector Solar marca SOL-5820SS
Fuente: Autor

En este segundo análisis se optó por tomar como referencia el modelo AMAWTEC de 5.72 m^2 de área, cuyas características de fabricación se encuentran en la figura 29-3. Este colector solar fue seleccionado para su análisis debido a que se distribuye en Ecuador y la presión máxima de los tubos de vacío es 0,48Bar, siendo superior al del colector solar marca SOL-5820SS. Esta variante implica que el porcentaje de vacío de estos tubos aumenta a 66.16%. El resultado de la eficiencia máxima de este colector solar es 0.649. Desfuzificando este valor entrega una eficiencia de 64.9%.




Figura 33-4: Resultados de eficiencia del Colector Solar marca SOL-5820SS

Fuente: Autor

CAPÍTULO V

5. CONCLUSIONES Y TRABAJOS FUTUROS

5.1 CONCLUSIONES

- Se desarrollaron cuatro modelos con técnicas de inteligencia artificial, el sistema de inferencia adaptativo neuro-difuso (ANFIS), fue utilizado para optimizar el rendimiento del sistema, de uso doméstico para la Sultana de los Andes. Adicionalmente, los valores simulados mediante ANFIS de los parámetros de área del colector, Irradiancia y porcentaje de vacío, sirvieron para desarrollar redes neuronales artificiales tales como: Feed-forward Backpropagation, Layer Recurrent, Radial Basis Exact Fit, las cuales fueron utilizadas para analizar el rendimiento del sistema.
- Los tres modelos creados con redes neuronales artificiales, resultaron obtener desempeños muy satisfactorios, los modelos NNFB y NNLR, utilizaron entrenamiento supervisado, con la función de entrenamiento TRAINGDX, con 2 capas ocultas y 20 neuronas en la primera capa oculta, una función de activación TANSIG. Mientras que el modelo NNRB que fue entrenado con el método híbrido, la constante de propagación tiene un valor de 1 y 125 neuronas en su capa oculta. Por último, el modelo ANFIS, utilizó 5 MF tipo gaussiana en la entrada y triangular a la salida, adicionalmente 48 reglas para el sistema de inferencia difuso.
- Los datos para analizar la eficiencia del sistema generado mediante ANFIS, son muy parecidos a los valores obtenidos mediante Redes neuronales (anexo C). Los resultantes indican que el modelo Radial Basis tiene mayor precisión (ver figura

31-4), frente a los modelos NNFB y NNLR. En el capítulo de resultados en esta tesis de grado, se evidenció que estos modelos son un instrumento eficaz para el análisis de sistemas de energía solar térmica y nos proporcionan de manera óptima el desempeño del sistema.

- La sensibilidad paramétrica de los modelos neuronales multicapa Feed-forward Backpropagation y Layer Recurrente al utilizar el conjunto de datos de validación diferentes se ve afectada notoriamente, pero en el caso de la red neuronal Radial Basis Exact Fit, el coeficiente de correlación (ver tabla 15-6) que se usa para obtener el rendimiento de las ANN, no se ve afectado. Por tal razón, la red neuronal Radial Basis, es la óptima para analizar el desempeño del sistema analizado.
- La optimización de las variables de entrada que incurren directamente en el desempeño del sistema, están regidas por una relación directamente proporcional, pero a su vez están limitadas por parámetros de manufactura y fenómenos físicos como la presión atmosférica y la irradiación.

5.2 RECOMENDACIONES

- Modelar de forma correcta el funcionamiento de la planta para obtener todas las variables de entrada que mejor se adapten a la salida deseada.
- Implementar un número de reglas difusas no muy extenso, debido a que la creación de una cantidad excesiva de reglas, concluirá en un modelo de inferencia difuso mal entrenada que no otorgará utilidad alguna.

- Profundizar el estudio de la inteligencia artificial debido al aporte que entrega para la optimización y el análisis en el área de eficiencia energética con paneles solares y sistemas domóticos.

5.3. PLANTEAMIENTO DE TRABAJOS FUTUROS

En base a la presente investigación, los datos obtenidos verifican que los modelos con inteligencia artificial son aptos para optimizar y analizar la eficiencia de los colectores solares con tubos de vacío, de uso doméstico en la ciudad de Riobamba, para lo cual se plantea realizar el análisis con un número más amplio de variables de entrada y la ubicación de estos sistemas en otra región del Ecuador.

BIBLIOGRAFÍA

- Acuerdo de París Naciones Unidas 2015*. (2015).
- Aguinaga, A., Orquera, E., Avila, C., & Hidalgo, V. (2020). Characterization of energy vectors, in solar water heaters with PCMs for social interest housing. *Proceedings of the World Congress on Mechanical, Chemical, and Material Engineering*, 1–8. <https://doi.org/10.11159/icmie20.101>
- AMAWTEC. (2022). *AMAWTEC green technology*. <https://www.amawtec.com/>
- Andrade Revelo, S. (2006). *Simulación de un Convertidor Multinivel Apilable controlado con Lógica Difusa*. 63–88. http://catarina.udlap.mx/u_dl_a/tales/documentos/meie/revelo_a_s/capitulo4.pdf
- Bravo, Y., & García, D. (2002). *Estudio Y Aplicación De Los Modelos Anfis De Matlab*. <http://bibdigital.epn.edu.ec/bitstream/15000/5463/1/T2082.pdf>
- CAJO, C., & TACO, J. (2017). Diseño Y Construcción De Un Sistema De Calentamiento De Agua Potable Con Una Capacidad De 60 L/Día, Mediante El Uso De Energía Solar Para Una Vivienda Unipersonal. *Tesis*, 1–100. <http://dspace.ups.edu.ec/bitstream/123456789/5081/1/UPS-CYT00109.pdf>
- CECU, E. C. D. (n.d.). *Energía Solar Térmica*. RES & RUE Dissemination. Retrieved March 22, 2022, from https://cecu.es/campanas/medio_ambiente/res&rue/htm/dossier/3_solar_termica.htm
- Electricity Genera on Trends*. (n.d.). 2019.
- Empr, I. (n.d.). *FUNDAMENTO S DE LOS SISTEMAS DE CONTROL DEL RIEGO*. Y. 1–8.
- Iglesias, L. R., Ruperti, J. S., Valencia, L. K., & Moreira, M. C. (2017). El cambio de la matriz energética en el Ecuador y su incidencia en el desarrollo social y económico de la población. *Mikarimin*, 3(2), 25–36. <http://186.46.158.26/ojs/index.php/mikarimin/article/view/695>
- Instituto Nacional de Meteorología e Hidrología (INAMHI). (2021). *ESCUELA SUPERIOR POLITÉCNICA DE CHIMBORAZO ESTACIÓN AGROMETEOROLÓGICA AÑO : 2018 DIAGRAMA N° 1 TEMPERATURA (grados celsius - O C) MES : FEBRERO*. 0–7.
- Jeklin, A. (2016). *済無No Title No Title No Title*. 7(July), 1–23.
- Jiménez, H., & Portalanza, N. (2009). *Estandarización De Sistemas De Calentamiento De Agua*

Con Energía Solar En La Ciudad De Riobamba. 1–13.

- K.S. Kasiviswanathan, A. A. (2012). Radial Basis Function Artificial Neural Network: Spread Selection. *International Journal of Advanced Computer Science*, 2(11), 394–398. <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.428.6010&rep=rep1&type=pdf>
- Khademi, M., Moadel, M., Jafarkazemi, F., & Razeghi, A. (2013). Performance prediction of flat-Plate solar collectors using MLP and ANFIS. *J. Basic. Appl. Sci. Res*, 3(2s), 196–200. www.textroad.com
- Lecuona Neumann, A., n, M., & guez Aumente, P. (2013). Investigación e impacto ambiental de los edificios. La energía. *Informes de La Construcción, Figura 1.*
- Llano, L., Hoyos, A., Arias Sánchez, F., & Velásquez, J. (2007). Comparación del desempeño de funciones de activación en redes feedforward para aproximar funciones de datos con y sin ruido. *Revista Avances En Sistemas e Informática*, 4(2), 79–87.
- Martin, S., & Choi, C. T. M. (2016). On the influence of spread constant in radial basis networks for electrical impedance tomography. *Physiological Measurement*, 37(6), 801–819. <https://doi.org/10.1088/0967-3334/37/6/801>
- Matich Damián. (2001). Redes Neuronales: Conceptos Básicos y Aplicaciones. *Historia*, 55. <ftp://decsai.ugr.es/pub/usuarios/castro/Material-Redes-Neuronales/Libros/matich-redesneuronales.pdf>
- Mecánica, F. DE, por, P., & Diego Cruz Freire Darwin Vinicio Chimbo Chimbo, J. (2015). *Escuela Superior Politécnica De Chimborazo.*
- Ministerio Coordinador de Sectores Estratégicos. (2016). *Balance Energético Nacional 2016 Ecuador* (p. 447). https://issuu.com/sectoresestrategicos/docs/balance_energetico_2016
- Morales, R., Kleiner, I., Mariños, R., Elizabeth, R., Franco, R., Javier, F., Nacional, U., Ingeniería, E. A. P. De, & De, E. (2016). *Baja Presión Y Alta Presión De Un Colector Solar.* 14–19.
- Núñez, E., Steyerberg, E. W., & Núñez, J. (2011). Estrategias para la elaboración de modelos estadísticos de regresión. *Revista Espanola de Cardiología*, 64(6), 501–507. <https://doi.org/10.1016/j.recesp.2011.01.019>
- Obregón, N., Prada, Y., & Fragala, F. (2017). Redes Neuronales Artificiales En Hidroinformática. *Seminario Internacional La Hidroinformática En La Gestión Integrada de Los Recursos Hídricos, November.*
- Pineda Medina, J. G. (1989). Modificación, evaluación y análisis de eficiencia de un colector solar

- plano comercial. *Journal of Chemical Information and Modeling*, 53, 160.
- Ríos Encalada, J. A. (2021). "Evaluación De La Eficiencia De Un Colector Solar Con Tubos Al Vacío Para El Pre calentamiento De Agua Para La Cocción De Alimentos."
- Sadeghzadeh, M., & Chen, L. (2019). *Smart modeling by using artificial intelligent techniques on thermal performance of flat - plate solar collector using nanofluid*. April, 1649–1658. <https://doi.org/10.1002/ese3.381>
- SOLARIS. (2022). *SOLARIS ECO-SYSTEMS*. <https://www.solariseco.com>
- Spooner, J. T., & Passino, K. M. (1999). Decentralized adaptive control of nonlinear systems using radial basis neural networks. *IEEE Transactions on Automatic Control*, 44(11), 2050–2057. <https://doi.org/10.1109/9.802914>
- Trujillano Cabello, J., Badía Castelló, M., March Llanes, J., Rodríguez Pozo, À., Serviá Goixart, L., & Sorribas Tello, A. (2005). Redes neuronales artificiales en medicina intensiva. Ejemplo de aplicación con las variables del MPM II. *Medicina Intensiva*, 29(1), 13–20. [https://doi.org/10.1016/S0210-5691\(05\)74198-X](https://doi.org/10.1016/S0210-5691(05)74198-X)
- ut tiempo Network, S. . (2022). *RadiacionSolar.es*. <https://www.radiacionsolar.es/riobamba.html>
- Velásquez, J. D., Dyner R., I., & Souza, R. U. (2004). Modelación de Series Temporales usando ANFIS. *Inteligencia Artificial*, 8(23). <https://doi.org/10.4114/ia.v8i23.791>
- Vivienda, D. E. U. N. A., Quito, E. N., En, S., & Barrio, E. L. (2018). *Escuela politécnica nacional*.
- Walia, N., Singh, H., & Sharma, A. (2015). ANFIS: Adaptive Neuro-Fuzzy Inference System- A Survey. *International Journal of Computer Applications*, 123(13), 32–38. <https://doi.org/10.5120/ijca2015905635>
- Yaïci, W., & Entchev, E. (2016). Adaptive Neuro-Fuzzy Inference System modelling for performance prediction of solar thermal energy system. *Renewable Energy*, 86, 302–315. <https://doi.org/10.1016/j.renene.2015.08.028>

ANEXOS

ANEXO A.

Tabla 1-A: Datos para entrenar los modelos con redes neuronales artificiales

Reglas	Área	Irradiancia	% vacío	Eficiencia
R1	0.0689	0.0689	0.0686	0.171
R2	0.0689	0.247	0.0686	0.241
R3	0.0689	0.5	0.0686	0.25
R4	0.0689	0.776	0.0686	0.25
R5	0.0689	0.936	0.0686	0.25
R6	0.251	0.091	0.254	0.207
R7	0.251	0.251	0.254	0.295
R8	0.251	0.496	0.254	0.423
R9	0.251	0.767	0.254	0.421
R10	0.251	0.936	0.254	0.268
R11	0.5	0.104	0.498	0.259
R12	0.5	0.282	0.498	0.375
R13	0.5	0.491	0.498	0.496
R14	0.5	0.776	0.498	0.633
R15	0.5	0.913	0.498	0.734
R16	0.75	0.118	0.75	0.415
R17	0.75	0.251	0.75	0.501
R18	0.75	0.5	0.75	0.705
R19	0.75	0.8	0.75	0.761
R20	0.75	0.927	0.75	0.767
R21	0.887	0.136	0.9	0.494
R22	0.887	0.256	0.9	0.561
R23	0.887	0.5	0.9	0.703
R24	0.887	0.776	0.9	0.802
R25	0.887	0.904	0.9	0.803
R26	0.127	0.104	0.219	0.221
R27	0.127	0.25	0.219	0.305
R28	0.127	0.5	0.219	0.331
R29	0.127	0.744	0.219	0.308
R30	0.127	0.9	0.219	0.253
R31	0.251	0.104	0.51	0.254
R32	0.251	0.3	0.51	0.329
R33	0.251	0.6	0.51	0.493
R34	0.251	0.78	0.51	0.504
R35	0.251	0.9	0.51	0.546
R36	0.571	0.104	0.76	0.371

R37	0.571	0.242	0.76	0.488
R38	0.571	0.5	0.76	0.76
R39	0.571	0.789	0.76	0.751
R40	0.571	0.918	0.76	0.751
R41	0.802	0.104	0.9	0.436
R42	0.802	0.247	0.9	0.5
R43	0.802	0.5	0.9	0.703
R44	0.802	0.776	0.9	0.802
R45	0.802	0.9	0.9	0.803
R46	0.9	0.149	0.135	0.4
R47	0.9	0.26	0.135	0.481
R48	0.9	0.51	0.135	0.554
R49	0.9	0.762	0.135	0.61
R50	0.9	0.931	0.135	0.62
R51	0.136	0.12	0.52	0.217
R52	0.1	0.256	0.485	0.354
R53	0.082	0.5	0.533	0.375
R54	0.113	0.789	0.54	0.503
R55	0.1	0.94	0.511	0.503
R56	0.278	0.118	0.75	0.478
R57	0.282	0.256	0.75	0.5
R58	0.3	0.5	0.75	0.597
R59	0.3	0.8	0.75	0.75
R60	0.3	0.936	0.75	0.75
R61	0.57	0.104	0.92	0.415
R62	0.57	0.256	0.92	0.508
R63	0.57	0.504	0.92	0.708
R64	0.57	0.767	0.92	0.778
R65	0.57	0.927	0.92	0.778
R66	0.798	0.12	0.11	0.376
R67	0.816	0.242	0.113	0.388
R68	0.842	0.473	0.122	0.514
R69	0.807	0.8	0.12	0.593
R70	0.8	0.913	0.12	0.61
R71	0.92	0.104	0.26	0.45
R72	0.92	0.264	0.26	0.614
R73	0.92	0.504	0.26	0.585
R74	0.92	0.771	0.26	0.691
R75	0.92	0.922	0.26	0.706
R76	0.1	0.956	0.75	0.267
R77	0.122	0.229	0.75	0.383
R78	0.1	0.54	0.75	0.502
R79	0.1	0.771	0.75	0.693

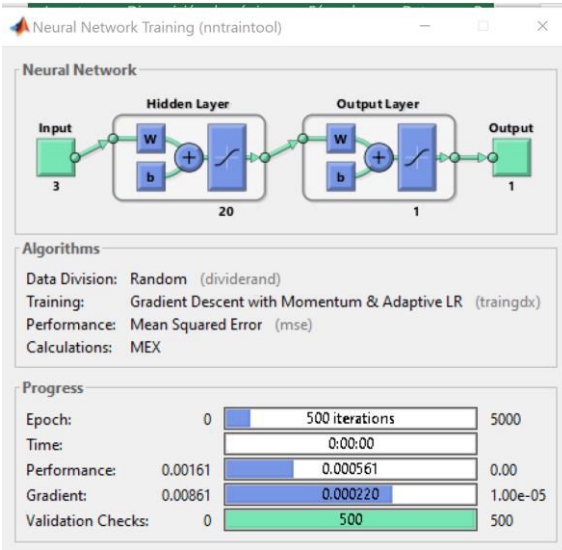
R80	0.1	0.953	0.75	0.75
R81	0.313	0.082	0.949	0.356
R82	0.313	0.264	0.949	0.506
R83	0.313	0.51	0.949	0.623
R84	0.313	0.774	0.949	0.75
R85	0.313	0.918	0.949	0.75
R86	0.571	0.104	0.113	0.27
R87	0.571	0.242	0.113	0.374
R88	0.571	0.513	0.113	0.41
R89	0.571	0.802	0.113	0.596
R90	0.571	0.94	0.113	0.624
R91	0.807	0.091	0.246	0.273
R92	0.807	0.256	0.246	0.518
R93	0.807	0.504	0.246	0.539
R94	0.807	0.78	0.246	0.658
R95	0.807	0.927	0.246	0.691
R96	0.9	0.118	0.5	0.426
R97	0.9	0.264	0.5	0.695
R98	0.9	0.5	0.5	0.73
R99	0.9	0.78	0.5	0.736
R100	0.9	0.9	0.5	0.778
R101	0.2	0.028	0.95	0.322
R102	0.2	0.25	0.95	0.447
R103	0.2	0.5	0.95	0.515
R104	0.2	0.744	0.95	0.741
R105	0.2	0.94	0.95	0.75
R106	0.4	0.055	0.055	0.193
R107	0.4	0.251	0.055	0.266
R108	0.4	0.5	0.055	0.298
R109	0.4	0.75	0.055	0.357
R110	0.4	0.94	0.055	0.615
R111	0.6	0.55	0.25	0.254
R112	0.6	0.25	0.25	0.427
R113	0.6	0.5	0.25	0.432
R114	0.6	0.75	0.25	0.593
R115	0.6	0.913	0.25	0.66
R116	0.8	0.05	0.5	0.259
R117	0.8	0.25	0.5	0.508
R118	0.8	0.5	0.5	0.644
R119	0.8	0.753	0.5	0.7
R120	0.8	0.94	0.5	0.784
R121	1	0.05	0.75	0.5
R122	1	0.25	0.75	0.563

R123	1	0.504	0.75	0.692
R124	1	0.75	0.75	0.752
R125	1	0.958	0.75	0.807

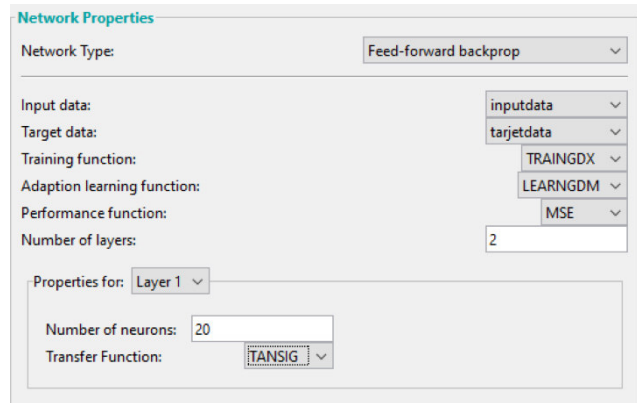
Realizado por: Autor

ANEXO B

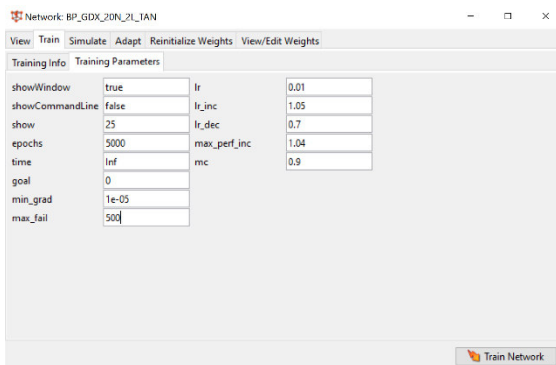
Registró de las simulaciones realizadas:



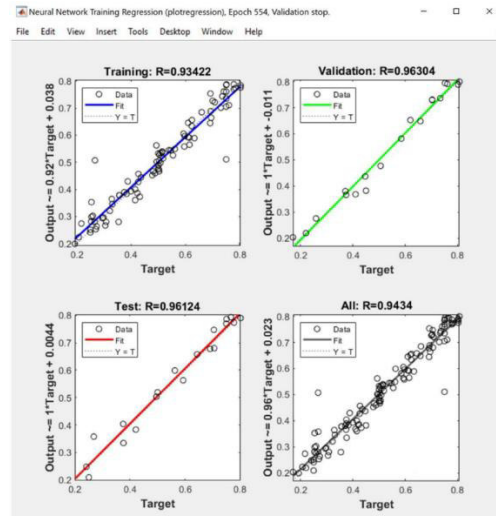
a) ANN Estructura de la red neuronal



b) Creación y función de transferencia TANSIG



c) Parámetros de entrenamiento de la red neuronal




d) Resultados entrenamiento y prueba NNBP

Figura 1-B: Características del modelo Feed-forward Backpropagation


Realizado por: Autor



a) Creación de la red neuronal



b) Estructura de la red neuronal artificial



c) Entrenamiento de la red neuronal artificial

Figura 2-B: Características del modelo Radial Basis (exact fit)

Realizado por: Autor

ANEXOS C

Tabla 1-C: Resultados de los modelos NNML

REFERENCIA ANFIS	NNBPGDX_2L_20N SALIDA	RADIAL BASIS_ SALIDA	LAYER RECURRENT SALIDA
0.268	0.35824	0.26801	0.38904
0.259	0.3026	0.25901	0.26715
0.375	0.40423	0.37499	0.36161
0.496	0.50365	0.49599	0.5153
0.633	0.58893	0.633	0.63497
0.734	0.73631	0.734	0.67741
0.415	0.36052	0.41499	0.41769
0.501	0.48887	0.50099	0.52307
0.705	0.74702	0.70499	0.70336
0.761	0.79126	0.76099	0.77557
0.767	0.79316	0.76699	0.78714
0.494	0.50184	0.494	0.48374
0.561	0.54913	0.56099	0.56671
0.703	0.73084	0.703	0.70924
0.802	0.79036	0.80199	0.77436
0.803	0.78362	0.80298	0.78718
0.221	0.21978	0.221	0.22649
0.305	0.26695	0.305	0.26891
0.331	0.34592	0.331	0.33297
0.308	0.28022	0.30796	0.32243
0.253	0.28123	0.253	0.30606
0.254	0.29884	0.254	0.27029
0.329	0.36451	0.32898	0.35432
0.493	0.56206	0.493	0.52452
0.504	0.52829	0.504	0.55202
0.546	0.54379	0.54601	0.53461
0.371	0.38035	0.37099	0.40271
0.488	0.45964	0.48799	0.4927
0.76	0.71039	0.76	0.68419
0.751	0.78648	0.75101	0.77304
0.751	0.78701	0.75098	0.78431
0.436	0.44426	0.43602	0.44319
0.5	0.53276	0.50001	0.54334
0.703	0.72939	0.70299	0.71063
0.802	0.78868	0.80202	0.78124
0.803	0.7756	0.80298	0.7918

Realizado por: Autor

ANEXO D

Tabla 1-D: CONJUNTO " A " PARA VALIDACIÓN

Área	Irradiancia	% vacío	Eficiencia
0.127	0.9	0.219	0.253
0.251	0.104	0.51	0.254
0.251	0.3	0.51	0.329
0.251	0.6	0.51	0.493
0.251	0.78	0.51	0.504
0.251	0.9	0.51	0.546
0.571	0.104	0.76	0.371
0.571	0.242	0.76	0.488
0.571	0.5	0.76	0.76
0.571	0.789	0.76	0.751
0.571	0.918	0.76	0.751
0.802	0.104	0.9	0.436
0.802	0.247	0.9	0.5
0.802	0.5	0.9	0.703
0.802	0.776	0.9	0.802
0.802	0.9	0.9	0.803
0.9	0.149	0.135	0.4
0.9	0.26	0.135	0.481
0.9	0.51	0.135	0.554
0.9	0.762	0.135	0.61
0.9	0.931	0.135	0.62
0.136	0.12	0.52	0.217
0.1	0.256	0.485	0.354
0.082	0.5	0.533	0.375
0.113	0.789	0.54	0.503
0.1	0.94	0.511	0.503
0.278	0.118	0.75	0.478
0.282	0.256	0.75	0.5
0.3	0.5	0.75	0.597
0.3	0.8	0.75	0.75
0.3	0.936	0.75	0.75
0.57	0.104	0.92	0.415
0.57	0.256	0.92	0.508
0.57	0.504	0.92	0.708
0.57	0.767	0.92	0.778
0.57	0.927	0.92	0.778

Realizado por: Autor

Tabla 2-D: CONJUNTO " B " PARA VALIDACIÓN

Área	Irradiancia	% vacío	Eficiencia
0.571	0.94	0.113	0.624
0.807	0.091	0.246	0.273
0.807	0.256	0.246	0.518
0.807	0.504	0.246	0.539
0.807	0.78	0.246	0.658
0.807	0.927	0.246	0.691
0.9	0.118	0.5	0.426
0.9	0.264	0.5	0.695
0.9	0.5	0.5	0.73
0.9	0.78	0.5	0.736
0.9	0.9	0.5	0.778
0.2	0.028	0.95	0.322
0.2	0.25	0.95	0.447
0.2	0.5	0.95	0.515
0.2	0.744	0.95	0.741
0.2	0.94	0.95	0.75
0.4	0.055	0.055	0.193
0.4	0.251	0.055	0.266
0.4	0.5	0.055	0.298
0.4	0.75	0.055	0.357
0.4	0.94	0.055	0.615
0.6	0.55	0.25	0.254
0.6	0.25	0.25	0.427
0.6	0.5	0.25	0.432
0.6	0.75	0.25	0.593
0.6	0.913	0.25	0.66
0.8	0.05	0.5	0.259
0.8	0.25	0.5	0.508
0.8	0.5	0.5	0.644
0.8	0.753	0.5	0.7
0.8	0.94	0.5	0.784
1	0.05	0.75	0.5
1	0.25	0.75	0.563
1	0.504	0.75	0.692
1	0.75	0.75	0.752
1	0.958	0.75	0.807

Realizado por: Autor

ANEXO E

Tabla 1-E: Cálculo del error de los modelos NNLR y NNFB

	A	B	C	D	E	F	G	H	I	J	K	L	M	N
	actual output data	LR/GDX/20N/2L/tan-A	FB/GDX/20N/2L/tan-A	FB error		error/actu		error/actu		error/actu				
				LR error	error	LR error	FB error	al LR	ual BP	ual LR	al FB			
3														
4	0.253	0.35153	0.28123	-0.09853	-0.02823	0.0097082	0.00079693	-0.3894466	-0.111581	0.3894466	0.11158103			
5	0.254	0.30187	0.29884	-0.04787	-0.04484	0.0022915	0.00201063	-0.1884646	-0.1765354	0.1884646	0.17653543		LR/GDX/20N/2L/tan-A	FB/GDX/20N/2L/tan-A
6	0.329	0.36044	0.36451	-0.03144	-0.03551	0.0009885	0.00126096	-0.0955623	-0.1079331	0.0955623	0.10793313	r2	0.91127	0.9664
7	0.493	0.46687	0.56206	0.02613	-0.06906	0.0006828	0.00476928	0.05300203	-0.1400811	0.053002	0.14008114	mse	0.00262	0.0010
8	0.504	0.53297	0.52829	-0.02897	-0.02429	0.0008393	0.00059	-0.0574802	-0.0481944	0.0574802	0.04819444	rmse	0.05121	0.0310
9	0.546	0.57423	0.54379	-0.02823	0.00221	0.0007969	4.8841E-06	-0.0517033	0.0040476	0.0517033	0.00404762	mape	1.63948	1.4048
10	0.371	0.3927	0.38035	-0.0217	-0.00935	0.0004709	8.7423E-05	-0.0584906	-0.0252022	0.0584906	0.02520216			
11	0.488	0.48551	0.45964	0.00249	0.02836	6.2E-06	0.00080429	0.00510246	0.0581148	0.0051025	0.05811475			
12	0.76	0.64256	0.71039	0.11744	0.04961	0.0137922	0.00246115	0.15452632	0.0652763	0.1545263	0.06527632			
13	0.751	0.73287	0.78648	0.01813	-0.03548	0.0003287	0.00125883	0.02414115	-0.0472437	0.0241411	0.04724368			
14	0.751	0.75158	0.78701	-0.00058	-0.03601	3.364E-07	0.00129672	-0.0007723	-0.0479494	0.0007723	0.0479494			
15	0.436	0.47322	0.44426	-0.03722	-0.00826	0.0013853	6.8228E-05	-0.085367	-0.018945	0.085367	0.01894495			
16	0.5	0.57271	0.53276	-0.07271	-0.03276	0.0052867	0.00107322	-0.14542	-0.06552	0.14542	0.06552			
17	0.703	0.70077	0.72939	0.00223	-0.02639	4.973E-06	0.00069643	0.00317212	-0.0375391	0.0031721	0.03753912			
18	0.802	0.76031	0.78868	0.04169	0.01332	0.0017381	0.00017742	0.05198254	0.0166085	0.0519825	0.01660848			
19	0.803	0.77212	0.7756	0.03088	0.0274	0.0009536	0.00075076	0.03845579	0.034122	0.0384558	0.03412204			
20	0.4	0.42858	0.39327	-0.02858	0.00673	0.0008168	4.5293E-05	-0.07145	0.016825	0.07145	0.016825			
21	0.481	0.47696	0.46625	0.00404	0.01475	1.632E-05	0.00021756	0.00839917	0.0306653	0.0083992	0.03066528			
22	0.554	0.58334	0.52555	-0.02934	0.02845	0.0008608	0.0008094	-0.0529603	0.0513538	0.0529603	0.05135379			
23	0.61	0.66432	0.59281	-0.05432	0.01719	0.0029507	0.0002955	-0.0890492	0.0281803	0.0890492	0.02818033			
24	0.62	0.6997	0.65262	-0.0797	-0.03262	0.0063521	0.00106406	-0.1285484	-0.0526129	0.1285484	0.0526129			
25	0.217	0.29533	0.27383	-0.07833	-0.05683	0.0061356	0.00322965	-0.3609677	-0.2618894	0.3609677	0.2618894			
26	0.354	0.31272	0.28003	0.04128	0.07397	0.001704	0.00547156	0.11661017	0.2089548	0.1166102	0.2089548			
27	0.375	0.37995	0.38948	-0.00495	-0.01448	2.45E-05	0.00020967	-0.0132	-0.0386133	0.0132	0.03861333			
28	0.503	0.47909	0.50572	0.02391	-0.00272	0.0005717	7.3984E-06	0.04753479	-0.0054076	0.0475348	0.00540755			

Realizado por: Autor

$$MSE = \frac{1}{n} \sum_{i=1}^n (\bar{Y}_i - Y_i)^2$$

$$R^2 = 1 - \left(\frac{\sum_j (t_j - o_j)^2}{\sum_j (o_j)^2} \right)$$

$$RMSE = \sqrt{\frac{\sum_1^n (Y_{pre,m} - t_{mea,m})^2}{n}}$$

$$MAPE = \frac{o-t}{o} * 100$$