



ESCUELA SUPERIOR POLITÉCNICA DE CHIMBORAZO
FACULTAD DE CIENCIAS
CARRERA INGENIERÍA QUÍMICA

**DISEÑO DE UNA RED NEURONAL ARTIFICIAL PARA LA
PREDICCIÓN DEL PODER CALORÍFICO SUPERIOR A
PARTIR DEL ANÁLISIS TERMOGRAVIMÉTRICO (TGA) DE
RESIDUOS DE NARANJA**

Trabajo de Integración Curricular

Tipo: Propuesta Tecnológica

Presentado para optar al grado académico de:

INGENIERA QUÍMICA

AUTORA: DENISSE LILIBETH MARTÍNEZ VALENCIA

DIRECTOR: Ing. MABEL MARIELA PARADA RIVERA

Riobamba – Ecuador

2022

© 2022, **Denisse Lilibeth Martínez Valencia.**

Se autoriza la reproducción total o parcial, con fines académicos, por cualquier medio o procedimiento, incluyendo cita bibliográfica del documento, siempre y cuando se reconozca el Derecho del Autor.

Yo, DENISSE LILIBETH MARTÍNEZ VALENCIA, declaro que el presente Trabajo de Titulación es de mi autoría y los resultados del mismo son auténticos. Los textos en el documento que provienen de otras fuentes están debidamente citados y referenciados.

Como autor asumo la responsabilidad legal y académica de los contenidos de este Trabajo de Titulación; el patrimonio intelectual pertenece a la Escuela Superior Politécnica de Chimborazo.

Riobamba, 11 de agosto de 2022

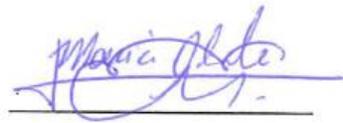
A handwritten signature in blue ink, appearing to read 'Denisse Lilibeth Martínez Valencia', written over a horizontal line.

Denisse Lilibeth Martínez Valencia

080241327-8

ESCUELA SUPERIOR POLITÉCNICA DE CHIMBORAZO
FACULTAD DE CIENCIAS
CARRERA INGENIERÍA QUÍMICA

El Tribunal del Trabajo de Integración Curricular certifica que: El Trabajo de Integración Curricular Tipo: Propuesta Tecnológica, **DISEÑO DE UNA RED NEURONAL ARTIFICIAL PARA LA PREDICCIÓN DEL PODER CALORÍFICO SUPERIOR A PARTIR DEL ANÁLISIS TERMOGRAVIMÉTRICO (TGA) DE RESIDUOS DE NARANJA**, realizado por la señorita: **DENISSE LILIBETH MARTÍNEZ VALENCIA**, ha sido minuciosamente revisado por los Miembros del Tribunal del Trabajo de Titulación, el mismo que cumple con los requisitos científicos, técnicos, legales, en tal virtud el Tribunal Autoriza su presentación.

	FIRMA	FECHA
Ing. Daniel Antonio Chuquin Vasco PRESIDENTE DEL TRIBUNAL		2022-08-11
Ing. Mabel Mariela Parada Rivera DIRECTORA DEL TRABAJO DE TITULACIÓN		2022-08-11
Ing. Mónica Lilian Andrade Avalos MIEMBRO DEL TRIBUNAL		2022-08-11

DEDICATORIA

Este proyecto de tesis se la dedico primero a Dios por protegerme y permitirme cumplir con una meta más en mi vida, a mis maravillosos padres los cuales sin su apoyo no hubiera conseguido ser una profesional, les estaré eternamente agradecida por estar siempre en los momentos de alegría y de tristezas. A mis hermanos y mis mejores amigas por estar ahí dándome voz de aliento para poder seguir adelante, a mi tía Magda por que siempre estuvo presente dándome su apoyo de todas las maneras a pesar de lo lejos que está. A mi esposo llegaste para alegrar mis días y ser mi compañero de vida, gracias inmensamente a todos.

Denisse

AGRADECIMIENTO

A mi honorable Escuela Superior Politécnica de Chimborazo por haberme permitido formar parte de ella dándome un espacio en sus aulas y aprender nuevos conocimientos. Mis más enormes agradecimientos a mi Tutora Ing. Mabel Parada y a mi miembro colaborador Ing. Mónica Andrade, quienes con su confianza, paciencia, tiempo, conocimientos y apoyo pudieron guiarme en mi proyecto de tesis. A cada uno de mis docentes que con sus sapiencias brindadas me permitieron aprender cada día un poco más, tanto en la parte teórica como la parte práctica, a todas mis amistades las cuales siempre con sus palabras de apoyo nunca me rendí para conseguir mis sueños. Esta hermosa etapa de ser una estudiante universitaria me enseñó a madurar y tener claros mis objetivos, a todos mil veces gracias siempre permanecerán en mis recuerdos que Dios y la Virgen de Guadalupe los cuide y proteja siempre, muchas gracias y bendiciones a todos.

Denisse

TABLA DE CONTENIDO

ÍNDICE DE TABLAS.....	xi
ÍNDICE DE FIGURAS.....	xii
ÍNDICE DE GRÁFICOS.....	xiii
ÍNDICE DE ANEXOS.....	xiv
RESUMEN.....	xv
SUMMARY.....	xvi

CAPÍTULO I

1.	INTRODUCCIÓN.....	1
1.1.	Antecedentes.....	1
1.2.	Planteamiento del problema.....	2
1.3.	Justificación del proyecto.....	2
1.4.	Objetivos.....	4
1.4.1.	<i>Objetivo General</i>	4
1.4.2.	<i>Objetivos Específicos</i>	4
1.5.	Alcance.....	4
1.6.	Marco legal.....	5
1.6.1.	<i>Licencia estudiantil de Matlab</i>	5
1.6.2.	<i>Duración de la licencia estudiantil</i>	6
1.6.3.	<i>Funcionalidad del software Matlab para estudiantes</i>	6

CAPÍTULO II

2.	MARCO TEÓRICO.....	7
2.1.	Estado del Arte.....	7
2.2.	Bases Teóricas.....	9
2.2.1.	<i>Biomasa</i>	9
2.2.2.	<i>Poder calorífico superior (PCS)</i>	10
2.2.3.	<i>Análisis termogravimétrico</i>	11
2.2.4.	<i>Análisis proximal</i>	12
2.2.5.	<i>Redes neuronales artificiales</i>	12
2.2.5.1.	<i>Arquitectura de una red neuronal</i>	13
2.2.5.2.	<i>Algoritmo de entrenamiento</i>	14

2.2.6.	<i>Redes neuronales en Matlab</i>	14
2.2.6.1.	<i>Flujo de trabajo típico para diseñar redes neuronales</i>	15
2.2.7.	<i>Ventajas de la inteligencia artificial en la predicción del PCS de biomasa</i>	15

CAPÍTULO III

3.	METODOLOGÍA	17
3.1.	Análisis del diseño de la metodología	17
3.2.	Localización del proyecto	20
3.3.	Determinación de las variables de estudio	20
3.4.	Análisis termogravimétrico (TGA)	21
3.5.	Establecimiento de la base de datos	22
3.6.	Diseño de la red neuronal artificial	24
3.6.1.	<i>Entradas y salidas de la red</i>	24
3.6.2.	<i>Normalización de datos</i>	24
3.6.3.	<i>Desarrollo de la red neuronal artificial</i>	24
3.6.4.	<i>Selección del número de neuronas en la capa oculta</i>	26
3.7.	Entrenamiento de la red neuronal artificial	27
3.7.1.	<i>Selección del algoritmo de entrenamiento</i>	27
3.8.	Validación de la red neuronal artificial	29
3.8.1.	<i>Análisis estadístico</i>	29
3.8.1.1.	<i>Análisis de varianza</i>	30
3.9.	Integración de la red neuronal artificial en una interfaz gráfica de usuario	30

CAPÍTULO IV

4.	GESTIÓN DEL PROYECTO	32
4.1.	Cronograma	32
4.2.	Presupuesto	33
4.3.	Recursos materiales	33
4.4.	Discusión y Análisis de Resultados	34
4.4.1.	<i>Análisis termogravimétrico</i>	34
4.4.2.	<i>Análisis proximal de la biomasa</i>	36
4.4.3.	<i>Poder calorífico superior de los residuos de cáscara de naranja</i>	38
4.4.4.	<i>Base de datos de la red neuronal artificial</i>	39
4.4.5.	<i>Desarrollo de la red neuronal artificial</i>	40
4.4.6.	<i>Validación de la red neuronal artificial</i>	41

4.4.6.1.	<i>Análisis de la varianza</i>	41
4.4.7.	<i>Desarrollo y validación de la interfaz gráfica de usuario</i>	42
CONCLUSIONES		45
RECOMENDACIONES		46
GLOSARIO		
BIBLIOGRAFÍA		
ANEXOS		

ÍNDICE DE TABLAS

Tabla 1-2:	Estado evolutivo de la investigación.....	8
Tabla 1-3:	Descripción de la metodología a desarrollar en la investigación	19
Tabla 2-3:	Localización del proyecto.....	20
Tabla 3-3:	VARIABLES de estudio.....	21
Tabla 4-3:	Especificaciones del análisis termogravimétrico.....	21
Tabla 3-3:	VARIABLES de entrada y salida de la red neuronal artificial.....	24
Tabla 4-3:	Tabla ANOVA para el análisis de la varianza	30
Tabla 1-4:	Cronograma del proyecto	32
Tabla 2-4:	Presupuesto del proyecto.....	33
Tabla 3-4:	Talento humano.....	33
Tabla 4-4:	Recursos materiales utilizados en el proyecto.....	33
Tabla 5-4:	Resultados del análisis termogravimétrico	34
Tabla 6-4:	Resultados del análisis proximal	37
Tabla 7-4:	Resultados del poder calorífico superior en función del análisis proximal	39
Tabla 8-4:	Análisis de la media en los datos reales y predichos	41
Tabla 9-4:	Análisis de la varianza en los datos reales y predichos.....	42
Tabla 10-4:	Predicción del poder calorífico superior en la cáscara de naranja.....	44

ÍNDICE DE FIGURAS

Figura 1-2:	Termobalanza (TGA).....	12
Figura 2-2:	Estructura básica de una neurona artificial.....	13
Figura 3-2:	Arquitectura de una Red Neuronal.....	14
Figura 1-3:	Etapas experimentales del proyecto, análisis TGA.....	17
Figura 2-3:	Etapas del diseño de la red neuronal artificial.....	18
Figura 2-3:	Ubicación geográfica del proyecto.....	20
Figura 4-3:	Asistente de diseño de la red neuronal en Matlab.....	25
Figura 5-3:	Asistente de selección de datos de entradas y salida normalizados.....	25
Figura 6-3:	Selección del porcentaje de datos para entrenamiento, validación y prueba....	26
Figura 7-3:	Selección del número de neuronas en la capa oculta.....	27
Figura 8-3:	Selección del algoritmo de entrenamiento.....	28
Figura 9-3:	Proceso de entrenamiento de la red neuronal artificial.....	29
Figura 10-3:	Ventana asistente de creación de la interfaz gráfica.....	31
Figura 11-3:	Ventana de diseño de la interfaz gráfica.....	31
Figura 1-4:	Interfaz gráfica de usuario para la red neuronal artificial.....	43
Figura 2-4:	Análisis próximo y PCS de la cascará de naranja.....	43
Figura 3-4:	Predicción de la red mediante la interfaz gráfica.....	44

ÍNDICE DE GRÁFICOS

Gráfico 1-4:	Correlación lineal en el entrenamiento de la red	40
Gráfico 2-4:	Error cuadrático medio en entrenamiento de la red	40
Gráfico 4-4:	Poder calorífico superior real y predicho por la red neuronal artificial	41
Gráfico 5-4:	Gráfico de medias para los datos reales y predichos	42

ÍNDICE DE ANEXOS

- ANEXO A:** ANÁLISIS TGA EN LABORATORIO DE INVESTIGACIÓN DE LA UCE
- ANEXO B:** RESULTADOS DEL PODER CALORÍFICO SUPERIOR
- ANEXO C:** BASE DE DATOS DE ENTRENAMIENTO DE LA RED NEURONAL ARTIFICIAL
- ANEXO D:** BASE DE DATOS PARA VALIDAR LA RED NEURONAL ARTIFICIAL
- ANEXO E:** NORMALIZACIÓN DE LOS DATOS DE ENTRENAMIENTO
- ANEXO F:** NORMALIZACIÓN DE LOS DATOS DE VALIDACIÓN
- ANEXO G:** DESARROLLO Y ENTRENAMIENTO DE LA RED NEURONAL ARTIFICIAL
- ANEXO H:** RESULTADOS PREDICHOS POR LA RED NEURONAL EN EL ENTRENAMIENTO
- ANEXO I:** VALIDACIÓN DE LA RED NEURONAL ARTIFICIAL
- ANEXO J:** RESULTADOS PREDICHOS POR LA RED NEURONAL EN LA VALIDACIÓN
- ANEXO K:** DESARROLLO DE LA INTERFAZ GRÁFICA DE USUARIO

RESUMEN

El objetivo de este trabajo fue desarrollar una red neuronal artificial para predecir el poder calorífico superior en los residuos de cáscara de naranja del cantón Caluma. Para establecer una base de 110 datos y desarrollar el modelo de predicción se utilizaron datos experimentales del análisis termogravimétrico y análisis proximales. El diseño de la red se llevó a cabo en el software Matlab y Simulink Student Suite con cuatro variables de entrada, 10 neuronas en la capa oculta, una variable de salida y el algoritmo de Levenberg Marquardt. Se seleccionaron 4 variables de entrada para el modelo de red neural que fueron las siguientes: porcentaje de humedad, carbono fijo, materia volátil y cenizas; siendo como variable de salida el poder calorífico superior. Una correlación lineal de 1 y un error cuadrático medio de $2,97 \times 10^{-10}$ evidencian el buen desempeño la red durante su entrenamiento con 10 neuronas en la capa oculta y el algoritmo de entrenamiento de Levenberg Marquardt. Un valor-P estadístico de 0,999 permite validar con un 95% de confianza el modelo de predicción, confirmando que no existe una diferencia significativa entre los valores reales del poder calorífico superior y los predichos por la red neuronal artificial. Los resultados indican que la red neuronal artificial demuestra ser eficiente al predecir el poder calorífico superior en los residuos de cáscara de naranja analizados por termogravimetría empleando una tasa de calentamiento de 15 °C/min en atmosfera inerte con inyección de Nitrógeno a 20 mL/min. Se recomienda utilizar la red neuronal en proyectos relacionados con la pirólisis o gasificación de biomasa que use los residuos de cáscara de naranja como fuente de bioenergía.

Palabras clave: <INGENIERÍA Y TECNOLOGÍA QUÍMICA>, <PODER CALORÍFICO SUPERIOR>, <CÁSCARA DE NARANJA>, <ANÁLISIS TERMOGRAVIMÉTRICO (TGA)>, <ANÁLISIS PROXIMAL>, <REDES NEURONALES ARTIFICIALES (RNA)>, <MATLAB (SOFTWARE)>

Firmado digitalmente por LUIS ALBERTO CAMINOS VARGAS
Nombre de reconocimiento
IDN: c=EC, o=RIOBAMBA,
serialNumber=602766974,
cn=LUIS ALBERTO CAMINOS VARGAS
Fecha: 2021.04.15 15:20:21 -05'00'

LUIS ALBERTO CAMINOS VARGAS



1014-DBRAI-UTP-2021

SUMMARY

The objective of this study was to develop an artificial neural network to predict the higher heating value in the orange peel residues in the Caluma canton, to create a database with 110 data. To develop the prediction model, experimental data from thermogravimetric analysis and proximal analyses were used. The network design was carried out in Matlab and Simulink Student Suite using four input variables, 10 neurons in the hidden layer, one output variable and the Levenberg Marquardt algorithm. Four input variables were selected for the neural network model, these are the percentage of humidity, fixed carbon, volatile matter, and ash, and as an output variable the higher calorific value. A statistical P-value of 0.999 allowed the prediction model to be validated with 95% confidence, confirming that there is no significant difference between the real values of the higher heating value and those predicted by the artificial neural network. The results indicate that the artificial neural network proves to be efficient in predicting the higher heating value in the orange peel residues analysed by thermogravimetry, using a heating rate of 15 ° C / min in an inert atmosphere with nitrogen injection at 20 mL / min. It is recommended to use the neural network in projects related to the pyrolysis or gasification of biomass that uses orange peel residues as a source of bioenergy.

Keywords: <CHEMICAL ENGINEERING AND TECHNOLOGY>, <HIGHER HEATING VALUE>, <ORANGE PEEL>, <THERMOGRAVIMETRIC ANALYSIS (TGA)>, <PROXIMAL ANALYSIS>, <ARTIFICIAL NEURONAL NETWORKS (ANN)>, <MATLAB (SOFTWARE)>.

ANA GABRIELA REINOSO ESPINOSA
Firmado digitalmente
por ANA GABRIELA
REINOSO ESPINOSA
Fecha: 2022.07.26
20:54:26 -05'00'

Ana Gabriela Reinoso Espinosa

CAPÍTULO I

1. INTRODUCCIÓN

1.1. Antecedentes

La energía renovable desempeña un papel importante en la estructura energética mundial con la creciente demanda de energía global, las reservas limitadas de combustibles fósiles y la demanda urgente de fuentes de energía respetuosas con el medio ambiente (Hosseinpour et al., 2017, p.3). La biomasa es la principal fuente de energía renovable (Toor, Rosendahl y Rudolf, 2015, p.2328).

La biomasa es un residuo que se genera permanentemente, y aprovecharla en procesos de conversión térmica, a la vez que se genera energía se resuelve el problema de la disposición del residuo. La variedad de residuos de biomasa agrícola es amplia, y para utilizar la biomasa como fuente de energía se requiere de un estudio exhaustivo de sus propiedades físicas, químicas y termodinámicas (Yu et al., 2015, p.1128).

El Poder calorífico superior es un parámetro importante para optimizar el proceso de conversión de biomasa en diferentes condiciones. Por ejemplo, Prins et al. (2015), recomienda la biomasa con diferentes valores de poder calorífico superior para obtener la mayor eficiencia de gasificación a diferentes temperaturas. Además, el modelado matemático, la simulación y la optimización son herramientas clave para analizar y desarrollar tecnologías complejas de conversión de biomasa, en las que el valor calorífico de la biomasa debe ser calculado para revelar la energía potencial de la biomasa (Wen et al., 2017, p.2).

Durante las últimas décadas, se han realizado muchos intentos previos para desarrollar modelos que permitan predecir el PCS de la biomasa a partir de correlaciones próximas con métodos no lineales (Nhuchhen et al., 2015, p.55) y lineales (Majumder et al., 2016, p.3077), un enfoque de sistema de inferencia neuro-difuso adaptativo (Akkaya, 2016, p.688), red neuronal iterativa - Mínimo cuadrados parciales adaptados (Hosseinpour et al., 2017, p.5) y redes neuronales artificiales (Estiati et al., 2016, p.378).

Yu et al. (2017) propuso dos correlaciones lineales a partir de los resultados del análisis elemental y próximo de biomasa agrícola. Nhuchhen y Abdul Salam (2015) correlaciones lineales y no lineales a partir del análisis próximo de biomasa. García et al. (2015) desarrollaron correlaciones lineales y no lineales con Matlab a partir del análisis elemental y próximo de biomasa.

Con el desarrollo de la inteligencia artificial, se han desarrollado y probado enfoques alternativos de aprendizaje automático, como la RNA. Estos enfoques se han aplicado con éxito a los combustibles sólidos, como el carbón y la biomasa (Xing et al., 2019, p.3), la desvolatilización, la

gasificación de la biomasa (Mutlu y Yucel, 2018, p.896), el control del sistema de pirólisis de la biomasa (Kasmuri et al., 2019, p.4) y las centrales combinadas de calor y energía (De et al., 2017, p.2100).

Recientemente, se han realizado varios intentos para estimar el PCS de la biomasa a partir de un análisis próximo utilizando algoritmos de RNA. Estiati et al. (2016) y Uzun et al. (2017) estimaron el PCS de la biomasa utilizando el enfoque de RNA, y los rendimientos del modelo fueron mejores en comparación con los de las correlaciones empíricas tradicionales.

1.2. Planteamiento del problema

El aumento de la necesidad de energía obliga a las sociedades a encontrar fuentes de energía alternativas que sean baratas, abundantes y de bajo impacto ambiental. Los combustibles fósiles están muy lejos de cumplir estos requisitos. Desde este punto de vista, la biomasa se considera una fuente de energía abundante, fácil de encontrar, renovable y sostenible. Sin embargo, la principal preocupación relevante para el uso de esta energía está relacionada principalmente con el bajo poder calorífico de la biomasa.

Por tanto, el poder calorífico es el parámetro clave para evaluar la calidad del combustible de un material de biomasa especial en aplicaciones energéticas. Existen correlaciones empíricas en la literatura para la determinación del poder calorífico superior (PCS) basadas tanto en datos de análisis elementales (más exigentes en términos de instrumentación) como en datos de análisis proximal (más simples y fáciles de lograr experimentalmente); pero estos métodos experimentales suelen conllevar mucho tiempo y son costosos, motivo por el cual resulta conveniente recopilar datos bibliográficos de análisis proximales basados en TGA realizados en los residuos de naranja para diseñar una red neuronal artificial que permita calcular y predecir el poder calorífico superior de la cáscara de naranja en el cantón Caluma, disminuyendo tiempos y recursos que conlleva la experimentación.

La cáscara de naranja (*citrus sinensis*) es una biomasa orgánica, que generalmente es desechada al extraer el jugo de la naranja, y compone entre un 40 - 45% del peso de una naranja (Cerón y Cardona, 2015, p.69); estos residuos representan un desperdicio constante y permanente en el cantón Caluma, ya que la naranja es el producto referente del cantón en la provincia de Bolívar, lugar donde se produce el 60% del cultivo nacional de la fruta con un promedio anual estimado de producción de 3000 toneladas (Montalvo, 2018, p.2).

1.3. Justificación del proyecto

La biomasa es una de las fuentes de energías renovables y sostenibles que no genera emisiones de gases de efecto invernadero. El uso eficiente de la energía de la biomasa ayudará a resolver los problemas derivados de los combustibles fósiles, puesto que, a diferencia de los combustibles fósiles, la biomasa está permitida como combustible neutro en CO₂ ya que no contribuye al aumento neto de las emisiones de CO₂ a la atmósfera. Es decir, la cantidad de CO₂ que se forma al quemar biomasa es casi equivalente al CO₂ capturado de la atmósfera durante la fotosíntesis de la biomasa verde (ÖzyüğÜran y Yaman, 2017, p.131).

Por estas razones, la biomasa es de gran interés en proyectos de energía renovable en todo el mundo para mitigar los gases de efecto invernadero y reducir la participación de los combustibles fósiles en el consumo de energía. Hay tres tipos principales de biomasa para obtener energía: lípidos, azúcares / almidones y celulosa / lignocelulosa.

Los residuos de la producción agrícola han ido tomando lugar en la constante búsqueda de fuentes de energía para satisfacer la necesidad mundial urgente por reemplazar a los combustibles fósiles. Debido a que los residuos de naranja representan un desperdicio permanente en el cantón Caluma se plantea el desarrollo de la siguiente propuesta tecnológica “DISEÑO DE UNA RED NEURONAL ARTIFICIAL PARA LA PREDICCIÓN DEL PODER CALORÍFICO SUPERIOR A PARTIR DEL ANÁLISIS TERMOGRAVIMÉTRICO (TGA) DE RESIDUOS DE NARANJA” cuyo enfoque principal es visibilizar los procedimientos tecnológicos que permiten la valoración energética de la biomasa como es el poder calorífico superior de los residuos de cáscara de naranja; disminuyendo tiempos y recursos que conlleva la experimentación junto con cálculos engorrosos, misma que se fundamenta en la utilización de redes neuronales artificiales como técnica computacional que asemeja el funcionamiento del cerebro humano y que ha ganado un importante reconocimiento en el análisis de datos y predicción de procesos.

Además, el desarrollo de esta propuesta tecnológica abre un amplio campo investigativo en la valorización energética mediante redes neuronales artificiales de otros residuos agrícolas que igualmente puedan ser usados como biomasa para obtener biocombustibles por diferentes procesos de tratamiento térmico, por ejemplo, la pirólisis. En este contexto, se desarrollará una red neuronal artificial capaz de estimar el poder calorífico superior de la biomasa, entrenada a partir de cuatro variables de entrada (independientes) que corresponden a los datos recopilados de bibliografía para el análisis proximal basados en TGA (humedad, materia volátil, carbono fijo y contenido de cenizas) de la biomasa conformada por residuos de naranja. Matlab facilita el desarrollo de RNA, ya que proporciona una programación sencilla y muchas funciones que se pueden utilizar directamente.

1.4. Objetivos

1.4.1. Objetivo General

Diseñar una red neuronal artificial para la predicción del poder calorífico superior a partir del análisis termogravimétrico (TGA) de los residuos de cáscara de naranja.

1.4.2. Objetivos Específicos

- Recopilar datos experimentales reportados en bibliografía de los análisis proximales basados en TGA que se han realizado en los residuos de cáscara de naranja para determinación del poder calorífico superior.
- Establecer las variables independientes y dependiente de la red neuronal artificial, así como la topología de red (cantidad de neuronas en la capa oculta) que permita la mejor exactitud del modelo de predicción.
- Evaluar la capacidad de predicción de la red neuronal artificial a partir de datos experimentales reportados en bibliografía para el poder calorífico superior de la cáscara de naranja.
- Desarrollar una interfaz gráfica de usuario que permita interactuar fácilmente con los resultados de la red neuronal artificial.

1.5. Alcance

En la revalorización de los residuos para biomasa es necesario analizar su composición para el diseño de procesos, sin embargo, no existe estudios de modelos termodinámicos para el cálculo de propiedades como el poder calorífico, Humedad, Carbono Fijo, Materia Volátil, cantidad de Cenizas y la composición elemental (C, H, O, N, S) de la biomasa; variables necesarias en procesos de transformación termoquímica y en el análisis de cinéticas de reacción para el diseño de reactores. Por ello, en lugar de determinar la composición como en cualquier proceso convencional, se calcula en función de análisis termogravimétricos y proximales que proporcionan el porcentaje de Carbono Fijo, Materia Volátil, Ceniza y Humedad (Ismail et al., 2017, p.2).

Con datos del análisis proximal y modelos apropiados es posible calcular propiedades como el poder calorífico superior (PCS). Generalmente los modelos de predicción para valorizar los residuos de biomasa no están incorporados a simuladores debido a su limitada capacidad de

predicción por la gran variedad de residuos no convencionales que existen en la actualidad. Sin embargo, se pueden incorporar a un simulador tanto componentes, como modelos de predicción. La presente investigación pretende correlacionar el poder calorífico superior con los análisis proximales realizados en los residuos de cáscaras de naranja, aplicando inteligencia artificial. El modelo de predicción permitirá valorar el potencial del residuo como fuente de energía en procesos de conversión térmica como la pirólisis o la gasificación; plasmando una posibilidad de incorporar el modelo predictivo en un simulador de procesos.

Este proyecto busca beneficiar directamente a los comerciantes de naranja en el Cantón Caluma, puesto que, la presente propuesta al implementar redes neuronales artificiales brinda las herramientas necesarias para predecir una correcta valoración de los residuos de cáscara de naranja y el aprovechamiento energético de los mismos como biomasa. Permitiendo disminuir la cantidad de desperdicios relacionados a la naranja; que representan el residuo orgánico de mayor cantidad en el Cantón.

Adicionalmente, el proyecto beneficiará a los agricultores y productores del cantón a través de sus desperdicios de cáscara de naranja. Además, la metodología de esta investigación podrá ser aplicada no solo en diferentes residuos agrícola, también con diferentes residuos orgánicos domésticos.

1.6. Marco legal

1.6.1. Licencia estudiantil de Matlab

Matlab es una plataforma de programación y computación numérica utilizada por estudiantes, ingenieros y científicos para analizar datos, desarrollar algoritmos y crear modelos. Matlab brinda la posibilidad de adquirir una licencia estudiantil que permite únicamente realizar investigación académica. No está disponible para uso gubernamental, comercial o de otra organización. No puede utilizar el software con fines de lucro o actividades generadoras de ingresos (Mathworks,2020). La licencia denominada “Matlab y Simulink Student Suite” Incluye Matlab, Simulink y 10 de los productos complementarios más utilizados, así como soporte integrado para prototipos, pruebas y ejecución de modelos en el hardware de destino:

- Control System Toolbox
- Curve Fitting Toolbox
- DSP System Toolbox
- Image Processing Toolbox
- Instrument Control Toolbox

- Optimization Toolbox
- Parallel Computing Toolbox
- Signal Processing Toolbox
- Statistics and Machine Learning Toolbox
- Symbolic Math Toolbox

1.6.2. Duración de la licencia estudiantil

Se puede utilizar el software para estudiantes de forma indefinida. Culminados los estudios, es necesario la compra de una licencia profesional (Mathworks,2020).

1.6.3. Funcionalidad del software Matlab para estudiantes

El software para estudiantes le proporciona la misma funcionalidad que la versión profesional de Matlab. Existen pequeñas diferencias entre la interfaz del software para estudiantes y la versión profesional, entre ellas, el banner de la ventana de comandos y la barra de título incluyen una nota sobre el uso de los estudiantes (Mathworks,2020).

CAPÍTULO II

2. MARCO TEÓRICO

2.1. Estado del Arte

El primer estudio que utilizó redes neuronales artificiales para la predicción del Poder Calorífico Superior (PCS) a partir de biomasa fue el de Patel et al. (2015). Emplearon una red neuronal artificial de perceptrón multicapa utilizando 79 datos de entrenamiento conformado por análisis proximales y elementales combinados. El perceptrón multicapa es un modelo de RNA de retroalimentación simple que tiene un mínimo de 3 capas: las capas de entrada, oculta y de salida (Heidari et al., 2016, p.3). El estudio de Patel et al. (2015) permitió establecer que los modelos basados en RNA eran mejores que los modelos lineales.

Huang et al. (2016) consideraron 222 pares de datos sobre el contenido de cenizas de la paja como base de su investigación para predecir el PCS de esta biomasa. El mejor resultado se logró utilizando dos capas ocultas con nueve neuronas para la primera capa y una sola neurona para la segunda capa. Se estableció que el modelo RNA era superior a la regresión lineal y las ecuaciones de ajuste no lineal. Esta fue una extensión de la premisa de Patel et al. (2015) que solo consideró la regresión lineal junto con la RNA. Sin embargo, el modelo de Huang et al. (2016) a lo largo de los años ha demostrado no ser un buen modelo de RNA, probablemente a que los autores emplearon un conjunto de datos que se basa únicamente en el contenido de cenizas.

La revisión cualitativa más reciente sobre la predicción de biomasa PCS fue realizada por Zhao et al. (2015). En la revisión solo se mencionó una red neuronal artificial (RNA), ya que para entonces solo se habían publicado dos artículos (Patel et al. 2015 y Huang et al. 2016; ya mencionados) sobre el tema. Aunque el primer artículo sobre redes neuronales artificiales para la predicción del PCS fue de Patel et al. (2015), no fue hasta los últimos 4 años que creció el interés por la investigación (Ighalo et al., 2020, p.2).

Keybondorian et al. (2017) utilizaron una red neuronal artificial de perceptrón multicapa, con 350 pares de datos de análisis proximales. En la investigación se destinaron 298 pares de datos para el entrenamiento y prueba de la red y 52 pares de datos para su validación. Aunque el resultado del estudio fue positivo, no fue necesariamente una mejora del status quo (en términos de precisión).

Suleymani y Bemani (2018) aplicaron el algoritmo ANFIS-PSO como método novedoso para la estimación del poder calorífico superior de la biomasa en términos de carbono fijo (FC), contenido

de cenizas (ASH) y materias volátiles (VM). Para el entrenamiento de la red se extrajo un total de 350 datos experimentales de la literatura. ANFIS-PSO es un algoritmo híbrido que incorpora el sistema de inferencia neuro-difuso adaptativo y la optimización por enjambre de partículas.

En una investigación elaborada, Hosseinpour et al. (2018) aclararon el uso de una variedad de modelos RNA para la predicción del PCS de biomasa. Consideraron mínimos cuadrados parciales, análisis de componentes principales con paradigma RNA, mínimos cuadrados parciales adaptados a redes neuronales y mínimos cuadrados parciales adaptados a redes neuronales iterativas. El estudio empleó 350 pares de datos de análisis proximales. El estudio, concluye que los mínimos cuadrados parciales adaptados a la red neuronal iterativa son más precisos en la predicción de PCS de biomasa. El estudio fue más allá, integrando la red neuronal en una interfaz gráfica simple y fácil de usar que podría emplearse por usuarios con poca experiencia en la predicción e investigación energética.

Darvishan et al. (2018) utilizaron una red neuronal artificial de perceptrón multicapa con 78 pares de datos de análisis proximal para pruebas y entrenamiento. Alcanzaron un valor R^2 de 0.9993 y RMSE de 20,17 en la prueba. Este fue un modelo más preciso que todos los demás desde Patel et al. (2015).

Ighalo et al. (2020) evalúa el progreso de la investigación en la predicción del PCS de biomasa mediante modelos de redes neuronales artificiales, identificando brechas de conocimiento y sintetizando perspectivas futuras en el área de investigación. Concluye que la red neuronal artificial de perceptrón multicapa (MLPANN) es el modelo RNA más preciso para la predicción del PCS de biomasa. La precisión del modelo depende más de la arquitectura RNA que de la cantidad de datos. Las investigaciones basadas en datos de análisis finales (ya sea de forma individual o combinada con datos de análisis próximos) proporcionan modelos más precisos.

Tabla 1-2. Estado evolutivo de la investigación

TEMA	AUTOR	AÑO
Estimación del poder calorífico superior de los carbones mediante redes neuronales artificiales.	Patel et al.	2015
Una revisión sobre la predicción del consumo de energía	Zhao et al.	2015
Modelos de predicción del valor calorífico de la paja a partir del contenido de cenizas.	Huang et al.	2016
Aplicación de la estrategia MLP-RNA para predecir el poder calorífico superior de la biomasa en términos del análisis próximo	Keybondorian et al.	2017

Aplicación del algoritmo ANFIS-PSO como método novedoso para la estimación del poder calorífico superior de la biomasa.	Suleymani y Bemani	2018
Modelado del poder calorífico superior (PCS) de la biomasa sobre la base del análisis próximo utilizando mínimos cuadrados parciales difusos basados en la red iterativos junto con el análisis de componentes principales (PCA-INFPLS)	Hosseinpour et al.	2018
Aplicación de MLP-ANN como un nuevo método predictivo para la predicción del poder calorífico superior de la biomasa en términos del análisis final	Darvishan et al.	2018
Aplicación de redes neuronales artificiales para predecir el poder calorífico superior de la biomasa: una evaluación temprana	Ighalo et al.	2020

Realizado por: Martínez, Denisse, 2021.

2.2. Bases Teóricas

2.2.1. Biomasa

Los residuos de biomasa de origen biológico son en la actualidad una de las materias primas de mayor interés como fuente de energía renovable, especialmente en el contexto de la sostenibilidad y la reducción del impacto ambiental (Estiati et al., 2016, p.378). Aunque los combustibles fósiles como el petróleo, el carbón y el gas natural son las principales fuentes de energía en el mundo, se prevé que estas fuentes de energía se agotarán en los próximos 40 a 50 años. Además, los daños ambientales debidos a las emisiones de estas fuentes han llevado a reducir las emisiones de carbono y cambiar hacia el uso de una variedad de recursos energéticos renovables que son menos dañinos para el medio ambiente, como la solar, la eólica y la biomasa (Alakangas et al., 2015, p. 4278).

La competitividad económica de muchas industrias depende en gran medida de la cantidad de energía utilizada durante la producción. En la producción de energía renovable, la biomasa sólida se ha convertido en una de las fuentes más importantes para la generación de energía y calor. La biomasa está formada por materiales orgánicos que generan alguna forma de energía (mecánica, térmica, eléctrica, etc.) mediante algunos procesos de transformación (Alakangas et al., 2015, p. 4279). Esta materia orgánica tiene varios orígenes, como los residuos forestales, agrícolas e industriales o domésticos. Los principales tipos de compuestos orgánicos a partir de los cuales se produce la bioenergía son los siguientes: lípidos (grasas en general, aceites y ceras), extractivos (ácidos resínicos, terpenos, sesquiterpenos, ésteres y otros), azúcares / almidones y celulosa / lignocelulosa. Estos compuestos orgánicos varían según su origen e influyen en el potencial calorífico de estos materiales. Algunos cereales, como la soja, y las semillas, como el girasol y el

ricino, son ricos en lípidos y, por tanto, adecuados para la producción de biodiésel. Los azúcares y el almidón suelen estar presentes en las partes comestibles de los cultivos alimenticios, como el maíz. Las pulpas de lignocelulosa y celulosa, que tienen poco o ningún valor en la alimentación de los seres humanos, también se pueden utilizar como fuente de biocombustible y productos de alta energía. La materia sólida orgánica de disposición es variada y tiene varios orígenes, desde subproductos industriales, como tortas y salvados, hasta residuos agrícolas y municipales, como restos de poda de árboles (Alakangas et al., 2015, p. 4280).

Desde el punto de vista químico, los residuos de biomasa son generalmente compuestos que contienen invariablemente hemicelulosa, celulosa y lignina, y también extractos según su tipo y naturaleza. Al proporcionar la energía de activación de las moléculas en dichos compuestos, es posible reducirlas mediante reacciones exotérmicas a moléculas más pequeñas, como gas combustible (hidrógeno, por ejemplo) y aceites. Las tecnologías más desarrolladas para la obtención de energía a partir de combustibles son las basadas en tratamientos termoquímicos, como la pirólisis, la gasificación y la combustión (Bordoloi et al., 2016, p.85). El nivel de eficiencia y emisión de estos procesos depende de la composición y propiedades de la biomasa, las condiciones de operación y el tipo de equipo utilizado. Dado que la biomasa es estacional en muchos casos, la viabilidad de cualquier tratamiento termoquímico requiere el ajuste de las condiciones de operación a las características de la energía, por lo que la caracterización de la biomasa debe ser rápida y confiable. Entre los parámetros más importantes que afectan la cinética de la degradación térmica se encuentra el poder calorífico superior (PCS) (Estiati et al., 2016, p.379).

2.2.2. Poder calorífico superior (PCS)

El poder calorífico superior (PCS) es el calor (energía) liberado en la combustión completa de una cantidad fija de combustible. El poder calorífico de un material se expresa por el contenido de energía liberado cuando el material se quema en el aire. Así, el calor generado durante la combustión de diferentes tipos de residuos puede variar en función de sus propiedades físicas y químicas o, en otras palabras, es la cantidad de calorías que libera una combustión completa de un material, expresada en calorías por gramo (cal/g) o kilocalorías / kg (kcal/kg). Cuanto mayor sea este parámetro, mayor será la energía contenida en el combustible. Se puede determinar el PCS de un material combustible a través de un calorímetro de bomba midiendo la evaporación y condensación del agua durante la combustión del material. Esta medición requiere mucho tiempo y, además, requiere condiciones específicas de preparación de la muestra para minimizar los resultados erróneos. Además de los medios analíticos, hay un número considerable de correlaciones disponibles en la literatura (Fotovat et al., 2015, p.39).

El poder calorífico superior (PCS) es uno de los parámetros más importantes para el diseño y funcionamiento de sistemas de energía alimentados con biomasa (Khodaei et al., 2015, p.2). El PCS indica la máxima cantidad de energía potencialmente recuperable de los residuos, y por ende es un parámetro que refleja la calidad de la biomasa y debe ser calculado para determinar la eficiencia de conversión en determinados procesos de conversión de biomasa (Xing et al., 2019, p.2).

El PCS es una propiedad esencial de los combustibles de biomasa para el diseño de sistemas de conversión térmica. El modelado matemático, la simulación y la optimización son herramientas clave para analizar y desarrollar cualquier proceso complejo como pirólisis, gasificación y combustión de biomasa (Xie et al., 2017, p.36).

El poder calorífico puede determinarse experimentalmente mediante el uso de un calorímetro de bomba adiabática. Este dispositivo mide el cambio de entalpía entre reactivos y productos (Sheng y Azevedo, 2015, p.500). Es posible que el calorímetro de bomba no siempre esté disponible, de ahí la necesidad de modelos rápidos y precisos para la predicción basados en datos fácilmente disponibles. Estos datos se pueden obtener a partir del análisis final, análisis próximo, análisis químico u otras propiedades de la biomasa como la densidad (Ighalo et al., 2020, p.3).

Los métodos de medición indirecta para calcular el valor calorífico incluyen métodos basados en correlación y métodos basados en modelos no lineales. Dado que la determinación experimental del poder calorífico es un proceso costoso que requiere instrumentación especial y analistas altamente capacitados, las correlaciones con base en análisis proximales y termogravimétricos para la predicción del poder calorífico superior se han vuelto una alternativa común y viable. La red neuronal artificial (RNA) y la regresión de vectores de soporte (RVS) son los modelos no lineales más utilizados. (Qi et al., 2019, p.1400).

2.2.3. Análisis termogravimétrico

El análisis termogravimétrico evalúa la pérdida de peso de una muestra cuando se aumenta la temperatura en atmósfera controlada. Puede ser una atmósfera oxidante (aire) o una atmósfera inerte (nitrógeno o helio) (Velázquez et al., 2018, p.2).

El análisis termogravimétrico (TGA), se realiza en un equipo denominado termobalanza, supone una herramienta muy útil y es una de las técnicas más utilizadas a escala laboratorio para el estudio de la degradación térmica de una muestra en fase sólida. Consiste en medir la variación de masa

que experimenta una sustancia en función de la temperatura mientras la muestra se calienta o se enfría con un programa de temperaturas dinámico o isoterma en una atmósfera controlada. La variación de masa puede ser una pérdida o una ganancia de la misma. El registro controlado de estos cambios nos dará información sobre si la muestra se descompone o reacciona con otros componentes (Fernández, 2017, p.37).

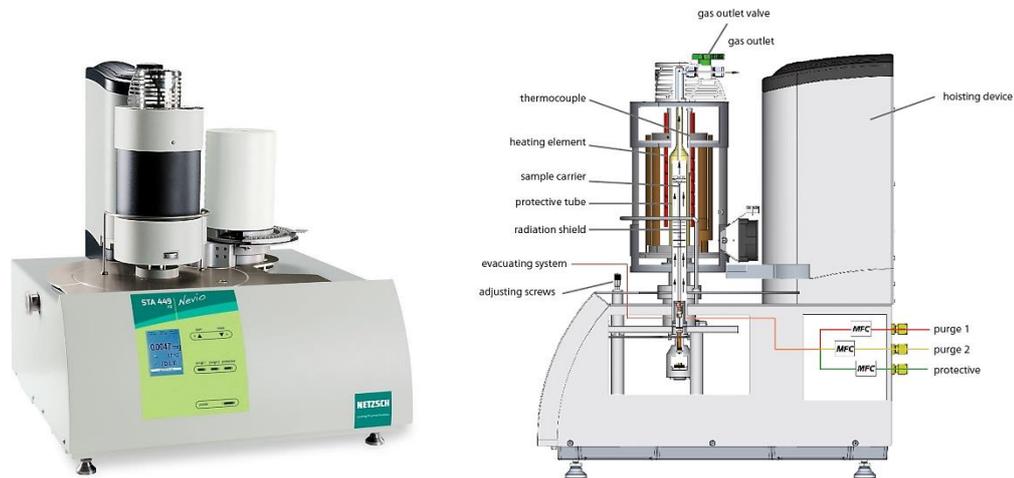


Figura 1-2. Termobalanza (TGA)

Fuente: NETZSCH, 2021

2.2.4. *Análisis proximal*

El análisis proximal proporciona información sobre el contenido de Carbono Fijo (FC), Materia Volátil (VM), contenido de Ceniza (Ash) y Humedad Relativa (H) de una muestra como la biomasa. Con estos datos y modelos apropiados se puede hacer el cálculo de propiedades como el poder calorífico superior (PCS), la densidad y entalpía, entre otras (Qi et al., 2019, p.1401).

Los análisis proximales de biomásas son necesarios para el diseño de procesos de producción de combustibles o generación de energía. Por ello es determinante, para la proyección de estos procesos de valorización conocer el poder calorífico superior (PCS) que proporciona el residuo a considerar, determinando así la cantidad de energía que se puede generar a partir de los mismos (Parikh et al., 2015, p.488).

2.2.5. *Redes neuronales artificiales*

Una red neuronal artificial es una herramienta computacional inspirada en el comportamiento de neuronas (Mulero et al., 2017,p.62). Dentro de una RNA existen numerosas conexiones entre las distintas neuronas que la forman. Estas conexiones simulan las conexiones neuronales del cerebro y al igual que estas pueden establecerse con mayor o menor intensidad. En el caso de las RNAs

estas intensidades son llamadas pesos sinápticos, de modo que cada entrada x_i de una neurona se encuentra afectada por un peso w_i (ver Figura 2-2), (Sinaluisa, 2017, citado en Rosario, 2020).

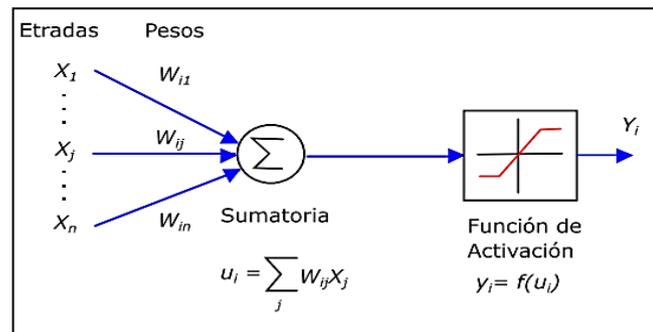


Figura 2-2. Estructura básica de una neurona artificial

Fuente: Sinaluisa, 2017, p.23.

2.2.5.1. Arquitectura de una red neuronal

Para comprender en qué consiste la arquitectura de una RNA, Ariza (2016) menciona que la topología o arquitectura de las RNAs hace referencia a la organización y disposición de las neuronas en la red formando capas de procesadores interconectados entre sí a través de sinapsis unidireccionales, la arquitectura de una RNA depende de cuatro parámetros principales: Número de capas del sistema, número de neuronas por capa, grado de conectividad entre las neuronas y el tipo de conexiones neuronales (Ariza, 2016, p.100).

La mejor arquitectura se debe encontrar mediante prueba y error. Este proceso de prueba y error es necesario ya que en la práctica no hay relación entre las neuronas en la capa de entrada y las de la capa de salida (Mulero et al., 2017, p.64).

En una red podemos diferenciar tres tipos de niveles o capas:

1. **Capa de entrada:** El número y tipo de neuronas de esta capa depende de los datos del problema que se esté abordando. Esta capa recibe los datos o señales procedentes del entorno, recibe los vectores de entrada y los redistribuye a las neuronas de la capa intermedia sin realizar ningún tipo de procesamiento sobre los datos, es sólo una receptora de información (Lóz & Velo, 2015, pp. 24-25).
2. **Capas intermedias u ocultas:** Pueden ser más de una dependiendo del problema, estas capas no tienen conexión directa con el entorno y mediante el tratamiento adecuado de estas capas se consigue la extracción de características, adaptabilidad, generalización..., es decir,

transforma los vectores de entrada en vectores intermedios, que caracterizan los patrones de entrenamiento (López & Velo, 2015, pp. 24-25).

3. **Capa de salida:** El número de neuronas de esta capa depende de las salidas de la red, es decir, sus neuronas proporcionan la respuesta de la red neuronal a partir de un estímulo de la capa intermedia (López & Velo, 2015, pp. 24-25).

4.

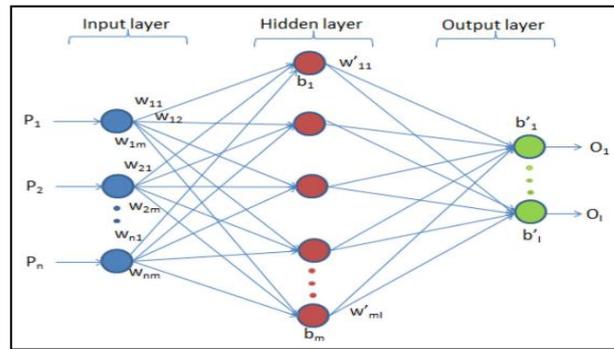


Figura 3-2. Arquitectura de una Red Neuronal

Fuente: Tran-Ngoc et al., 2019

El perceptrón multicapa constituye el modelo de RNA más utilizado en la práctica tanto para la resolución de problemas de clasificación como de regresión. Las redes multicapa (MLP) tienen la habilidad de caracterizar los patrones de entrenamiento generando su propio modelo de representación (Sinaluisa, 2017, p.27). El MLP tiene muchas capas conectadas entre sí, y cada nodo es una neurona con una función de activación no lineal. Perceptrón calcula un único resultado a partir de múltiples entradas, creando una combinación lineal de acuerdo a sus entradas, y luego determina el resultado utilizando la función de transferencia no lineal (Tran-Ngoc et al., 2019).

2.2.5.2. Algoritmo de entrenamiento

El proceso de entrenamiento es normalmente iterativo, actualizándose los pesos una y otra vez hasta que se alcanza el objetivo deseado. El entrenamiento de una red neuronal multicapa es formulado entonces como un problema de optimización no lineal con respecto a los pesos (Sinaluisa, 2017, pp. 28-33).

Dentro de los algoritmos de entrenamiento disponibles en el software Matlab, se tienen los siguientes: Levenberg-Marquardt, Bayesian Regularization y Scaled Conjugate Gradient (Jaiswal et al., 2018, p.1).

2.2.6. Redes neuronales en Matlab

Para implementar en Matlab una red neuronal artificial se lo puede realizar a través de tres funciones (Quintana, 2015, p. 24).

- 1) Mediante código desde la línea de comandos o desde el espacio de trabajo de Matlab (workspace).
- 2) Utilizando el conjunto de bloques incluidos en el toolbox de Control Systems de Neural Networks Blockset en Simulink.
- 3) Empleando la Interfaz Gráfica de Usuario (GUI por sus siglas en inglés) de RNAs, la cual se puede desplegar empleando el comando `nntool` (Neural Network Toolbox).

Al digitar el comando `nntool` en el espacio de trabajo de Matlab se abre la ventana Administradora de redes neuronales artificiales. Cuando se utiliza la interfaz gráfica de usuario (GUI), es posible exportar los resultados al espacio de trabajo. Del mismo modo, es posible importar resultados del área de trabajo para la GUI. Una vez que la ventana Network/Data Manager está en funcionamiento se puede crear una red, entrenarla, simularla y exportar los resultados al workspace (Quintana, 2015, p.25).

2.2.6.1. Flujo de trabajo típico para diseñar redes neuronales

Cada aplicación de red neuronal es única, pero el desarrollo de la red suele implicar los pasos siguientes:

1. Acceder a los datos y prepararlos
2. Crear la red neuronal
3. Configurar las entradas y salidas de la red
4. Ajustar los parámetros de la red (las ponderaciones y tendencias) para optimizar el rendimiento
5. Entrenar la red
6. Validar los resultados de la red
7. Integrar la red en un sistema de producción (MathWorks, 2020).

2.2.7. Ventajas de la inteligencia artificial en la predicción del PCS de biomasa

Se pueden derivar varias ventajas prácticas de la utilización de modelos RNA para la predicción de PCS de biomasa. Las predicciones del PCS se consideran una alternativa económicamente atractiva al análisis directo de biomasa (Callejón et al., 2016, p.949). Esta ventaja económica se magnifica cuando el valor PCS se determina para una amplia gama de materiales, aunque sea como una investigación preliminar para la elección de la materia prima basada en el potencial energético (Ighalo y Adeniyi, 2020, p.4). El PCS también llamado valor calorífico bruto se determina experimentalmente mediante el uso de un calorímetro de bomba adiabática. Este dispositivo mide

el cambio de entalpía entre reactivos y productos. Es posible que el calorímetro de bomba no siempre esté disponible, de ahí la necesidad de modelos rápidos y precisos para la predicción basados en datos fácilmente disponibles (Sheng y Azevedo, 2015, p.501).

Otra ventaja de la inteligencia artificial en la predicción del PCS de biomasa es su potencial de ahorro de tiempo sin comprometer la precisión. El uso de modelos RNA para predecir el PCS de biomasa es más rápido que el análisis directo de biomasa y más confiable que las predicciones por modelos empíricos. Los modelos de redes neuronales artificiales son bastante rápidos porque son tecnologías basadas en computadora. Las predicciones se pueden obtener en tiempo real en comparación con los análisis de laboratorio (Ahmad y Chen, 2020, p.3).

CAPÍTULO III

3. METODOLOGÍA

3.1. Análisis del diseño de la metodología

El presente estudio busca modelar un proceso experimental y predictivo, para ello, el análisis se realiza en condiciones de un estado estacionario, porque se emplea una muestra establecida de la cáscara de naranja para un análisis termogravimétrico y proximal, tomando como consideraciones de trabajo las establecidas en las variables del diseño.

El trabajo tiene dos enfoques; primero, tiene un enfoque experimental, ya que se realiza el análisis TGA a nivel de laboratorio para obtener los datos necesarios del análisis proximal de la cascara de naranja del cantón caluma y su correspondiente poder calorífico superior (la base de datos se complementará con una revisión bibliográfica de análisis proximales realizados en los residuos de cascara de naranja). En la Figura 1-3 se describe mediante etapas la metodología empleada en la experimentación.

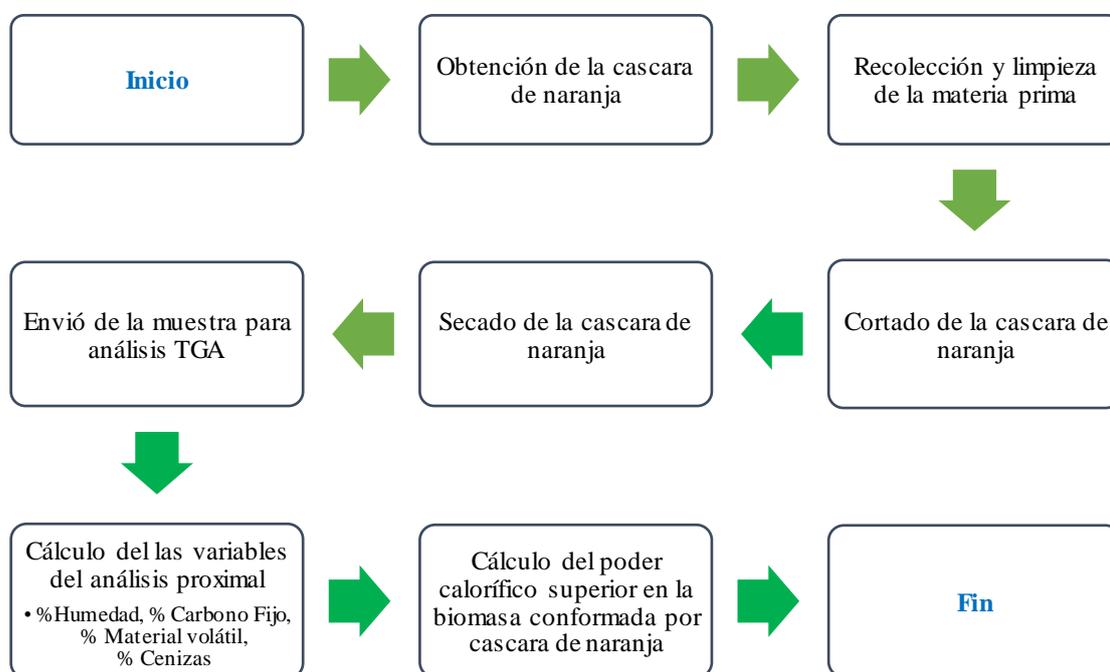


Figura 1-3. Etapas experimentales del proyecto, análisis TGA

Realizado por: Martínez, Denisse, 2021.

Luego, el proyecto aborda un enfoque predictivo en el diseño de la red neuronal mediante el software Matlab; puesto que, se pretende calcular mediante el uso de una red neuronal artificial el poder calorífico superior de los residuos de cáscara de naranja a partir del análisis termogravimétrico y datos proximales (% Humedad, % Carbono Fijo, % Material volátil, % Cenizas) recopilados por bibliografía. En la Figura 2-3 se describe mediante etapas la metodología empleada para modelar la predicción.

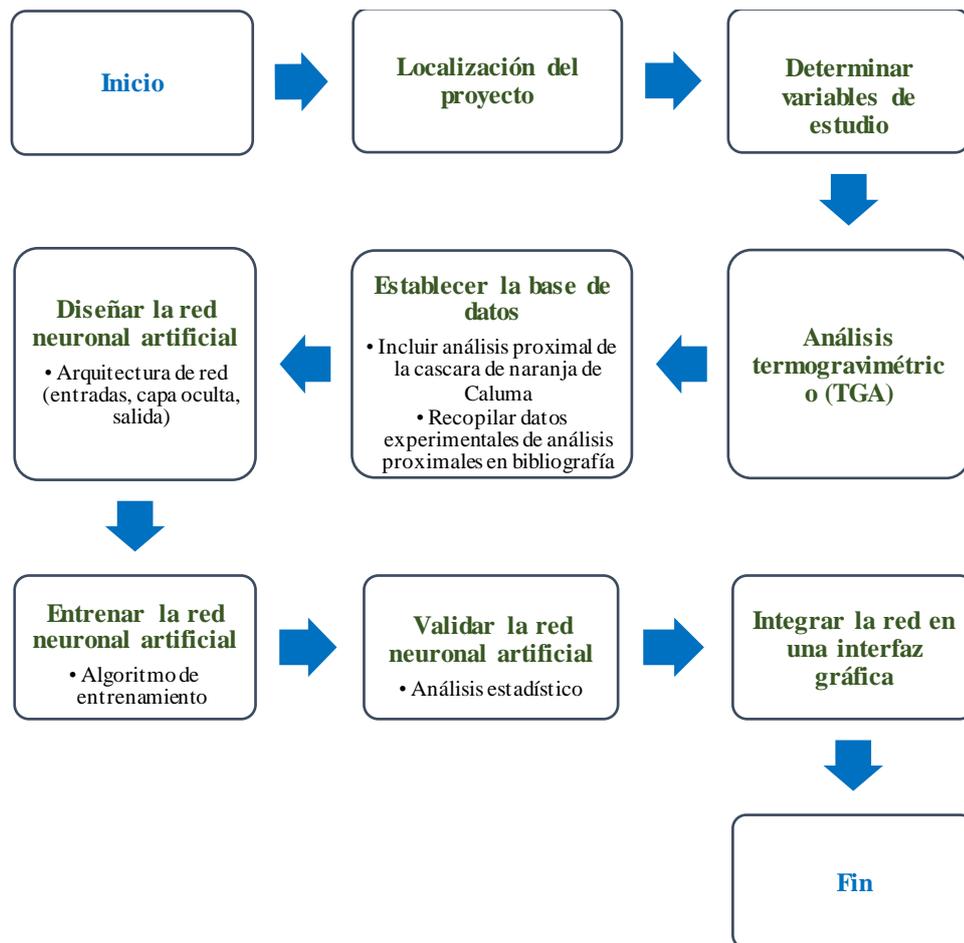


Figura 2-3. Etapas del diseño de la red neuronal artificial

Realizado por: Martínez, Denisse, 2021.

En este capítulo se desarrolla mediante etapas (Figura 2-3 y , la metodología empleada para modelar la predicción, descrita en la Tabla 1-3.

Tabla 1-3. Descripción de la metodología a desarrollar en la investigación

Objetivos	Desarrollo
<p>Recopilar datos experimentales reportados en bibliografía de los análisis proximales basados en TGA que se han realizado en los residuos de cáscara de naranja para determinación del poder calorífico superior.</p>	<p>a) Calcular el porcentaje de humedad, cenizas, materia volátil y carbono fijo presente en las cáscaras de naranja del cantón Caluma a partir de los datos obtenidos por el análisis TGA (temperatura, tiempo y peso).</p> <p>b) Revisión bibliográfica</p> <p>c) Recopilar una base de 100 datos conformada por los porcentajes de humedad, cenizas, materia volátil y carbono fijo obtenidos experimentalmente con la cáscara de naranja.</p> <p>d) Establecer la base de datos en Excel. El 90% de la base de datos se destinará para entrenamiento de la red y el 10% para su validación.</p>
<p>Establecer las variables independientes y dependiente de la red neuronal artificial, así como la topología de red (cantidad de neuronas en la capa oculta) que permita la mejor exactitud del modelo de predicción.</p>	<p>a) Las variables independientes serán las entradas de la red neuronal artificial</p> <ul style="list-style-type: none"> - % humedad - % carbono fijo - % materia volátil - % cenizas <p>Mientras que, la variable dependiente en la investigación será la salida de la red neuronal:</p> <ul style="list-style-type: none"> - Poder calorífico superior (PCS) <p>b) La topología de red se establecerá en función de la cantidad de neuronas que interactúan en la capa oculta de la RNA y el algoritmo de entrenamiento. Para ello se entrenará a la red variando el número de neuronas y el algoritmo, seleccionando así la mejor topología de red en función del MSE (error cuadrático medio) y R (correlación lineal). De los algoritmos de entrenamiento disponibles en el software Matlab, se tienen los siguientes:</p> <ul style="list-style-type: none"> - Levenberg-Marquardt - Bayesian Regularization - Scaled Conjugate Gradient
<p>Evaluar la capacidad de predicción de la red neuronal artificial a partir de datos experimentales reportados en bibliografía para el poder calorífico superior de la cáscara de naranja.</p>	<p>Para corroborar la exactitud de la red neuronal artificial resulta necesario realizar un análisis estadístico de la varianza, comparando los datos predichos por la red neuronal artificial con los datos reales obtenidos por experimentación y recopilados de bibliografía. Para ello se realizará un análisis Anova en el software estadístico SPSS. El análisis estadístico permitirá evaluar la capacidad de predicción de la red con un 95% de confianza.</p>
<p>Desarrollar una interfaz gráfica de usuario que permita interactuar fácilmente con los resultados de la red neuronal artificial.</p>	<p>La interfaz gráfica de usuario (GUI) se desarrollará a través de la línea de comandos en Matlab, con el comando “guide”.</p> <p>La GUI estará programada de manera que se interrelacione con la red neuronal artificial permitiendo al usuario ingresar datos de porcentaje de humedad, cenizas, materia volátil y carbono fijo de la cáscara de naranja para calcular el poder calorífico superior que presentan estos residuos.</p>

Realizado por: Martínez, Denisse, 2021.

3.2. Localización del proyecto

Este proyecto pretende ser implementado en:

Tabla 2-3. Localización del proyecto.

UBICACIÓN	Cantón Caluma, perteneciente a la Provincia de Bolívar, Ecuador.
LATITUD	-1.58333 m
LONGITUD	-79.1333 m
ALTITUD	380 m.s.n.m
CLIMA	Temperatura máxima: 21 °C
	Temperatura mínima: 18°C

Fuente: GAD Cantonal Caluma, 2021



Figura 3-3. Ubicación geográfica del proyecto

Fuente: Mapa obtenido de Google Maps, 2021.

3.3. Determinación de las variables de estudio

El poder calorífico superior (PCS) es una propiedad que permite valorar el potencial energético de los residuos de cáscara de naranja como posible fuente de energía para un proceso de conversión térmica. Ismail et al. (2017) mencionan que el PCS se puede calcular en función de análisis termogravimétricos y análisis proximales (contenido de Carbono Fijo, Materia Volátil, Ceniza y Humedad).

Tabla 3-3. Variables de estudio

Tipos de variables	Variable		Unidades
Independientes	Humedad	H	%
	Carbono fijo	CF	%
	Materia volátil	MV	%
	Cenizas	Cn	%
Dependiente	Poder calorífico superior	PCS	MJ/Kg

Realizado por: Martínez, Denisse, 2021.

3.4. Análisis termogravimétrico (TGA)

La caracterización termogravimétrica se obtiene mediante el análisis TGA de una muestra de biomasa conformada por cáscara de naranja. A la muestra seleccionada se le realiza un proceso de acondicionamiento previo a su análisis de la siguiente manera:

a) Obtención de la cáscara de naranja:

Separar la cascará de la naranja por métodos mecánicos para no tener perdida de materia prima y conservar su estructura.

b) Recolección y limpieza de la materia prima

Las cáscaras de naranja se recogen en los sitios de expendio de este y en los restaurantes del Cantón.

c) Cortado de la cáscara de naranja

Se realiza el cortado de la cáscara de naranja para disminuir su longitud y aumentar la superficie de contacto con el equipo termogravimétrico (termobalanza).

d) Envío de la muestra

Se envió una muestra con 12,94 gramos de cáscara de naranja para ser analizada en la termobalanza y obtener datos de degradación de la muestra en función de la temperatura y el tiempo.

e) Especificaciones del análisis TGA

Tabla 4-3. Especificaciones del análisis termogravimétrico

Muestra	Biomasa
Descripción	Cáscara de naranja
Tipo de ensayo	Termogravimetría
Equipo / máquina	Mettler Toledo TGA-1
Descripción del método	<ul style="list-style-type: none"> • Tasa de calentamiento de 15 °C/min • Programa de 25 a 900 °C • Atmósfera inerte (N₂) 20 ml/min

Realizado por: Martínez, Denisse, 2021

Fuente: Laboratorio de investigación UCE

3.5. Establecimiento de la base de datos

Se estableció una base de 100 datos en Microsoft Excel a partir de un análisis proximal realizado para la cascara de naranja del cantón Caluma en función del análisis TGA y 99 datos reportados en bibliografía (ver ANEXO B). El poder calorífico superior se puede calcular a partir de los análisis proximales mediante las ecuaciones descritas a continuación:

- **Humedad**

$$H = \frac{Phu - Pse}{Phu} * 100 \quad \text{Ec. 1-3}$$

Donde:

H = Porcentaje de humedad.

Phu = masa de la muestra húmeda (mg)

Pse = masa de la muestra seca (mg)

- **Cenizas**

$$Cn = \frac{Pcn}{Pim} * 100 \quad \text{Ec. 2-3}$$

Donde:

Cn = Porcentaje de cenizas

Pcn = masa de cenizas (mg)

Pim = masa inicial de la muestra (mg)

- **Materia volátil**

$$MV = C - H \quad \text{Ec. 3-3}$$

$$C = \frac{D - E}{D} * 100 \quad \text{Ec. 4-3}$$

Donde:

MV = Porcentaje de Materia volátil

C = Porcentaje de pérdida de masa

H = Porcentaje de Humedad

D = masa de la muestra (mg)

E = masa de la muestra después del calentamiento (mg)

- **Carbono fijo**

$$CF = 100 - (H + Cn + MV) \quad \text{Ec. 5-3}$$

Donde:

CF = Porcentaje de carbono fijo

H = Porcentaje de humedad

Cn = Porcentaje de cenizas

MV = Porcentaje de materia volátil

Es importante mencionar que se realizó el cálculo de porcentaje de humedad, materia volátil, cenizas y carbono fijo a partir del TGA de la cáscara de naranja, lo que permitió obtener el PCS de estos residuos; sin embargo, para establecer la base de datos se recopiló de bibliografía 99 datos con respecto a porcentaje de humedad, materia volátil, cenizas y carbono fijo (análisis proximales) obtenidos experimentalmente (ver ANEXO B) y se emplearon fórmulas de cálculo del PCS de la biomasa en función del análisis proximal; obteniendo un poder calorífico superior promediado para diseñar la red neuronal. Se estableció una base de datos en Excel, con 100 pares de datos que se emplearon en el entrenamiento y validación de la red neuronal artificial.

• **Poder calorífico superior en función del análisis proximal**

a) *Materia volátil y carbono fijo*

$$PCS = -10,81408 + 0,3133(MV + CF) \quad \text{Ec. 6-3}$$

$$PCS = -3,0368 + 0,2218MV + 0,2601CF \quad \text{Ec. 7-3}$$

$$PCS = 0,312CF + 0,1534MV \quad \text{Ec. 8-3}$$

$$PCS = 0,3543CF + 0,1708MV \quad \text{Ec. 9-3}$$

b) *Carbono fijo*

$$PCS = 0,196CF + 14,119 \quad \text{Ec. 10-3}$$

c) *Materia volátil y cenizas*

$$PCS = 35,43 - 0,1835MV - 0,3543Cn \quad \text{Ec. 11-3}$$

$$PCS = 0,3536CF + 0,1559MV - 0,0078Cn \quad \text{Ec. 12-3}$$

d) *Cenizas*

$$PCS = 19,914 - 0,2324Cn \quad \text{Ec. 13-3}$$

e) *Materia volátil, carbono fijo, humedad y cenizas*

$$PCS = -0,03Cn - 0,11H + 0,33MV + 0,35CF \quad \text{Ec. 14-3}$$

3.6. Diseño de la red neuronal artificial

3.6.1. Entradas y salidas de la red

Antes de diseñar la red neuronal primero se determinan los parámetros de entrada y salida de la red neuronal artificial (ver ANEXO C); para este caso de estudio se establecieron cuatro variables de entrada y una variable de salida como se describe en la siguiente tabla.

Tabla 5-3. Variables de entrada y salida de la red neuronal artificial

Entradas	Variables			Unidad
	1	Humedad	H	%
2	Cenizas	C	%	
3	Materia volátil	MV	%	
4	Carbono fijo	CF	%	
Salida	1	Poder calorífico superior	PCS	MJ/Kg

Realizado por: Martínez, Denisse, 2021.

3.6.2. Normalización de datos

Para iniciar con el diseño de la red neuronal artificial se importa la base de datos de Excel al espacio de trabajo de Matlab. Los datos son normalizados para reducir la redundancia de los mismos y mejorar el proceso de entrenamiento de la red neuronal artificial mediante la ecuación 15-3.

$$X_N = \frac{X - X_{min}}{X_{max} - X_{min}} \quad \text{Ec. 15-3}$$

Donde:

X_N = valor normalizado

X = valor que se desea normalizar

X_{max} = valor máximo

X_{min} = valor mínimo

3.6.3. Desarrollo de la red neuronal artificial

Con la base de datos normalizada,

- 1) Se utiliza la herramienta de Matlab Neural Net Fitting “nftool”, esta herramienta permite desarrollar redes de dos capas (feed forward networks). En la figura (Figura 4-3) se observa

el asistente de diseño de red mostrando una breve descripción sobre la herramienta Neural Net Fitting “nftool”.

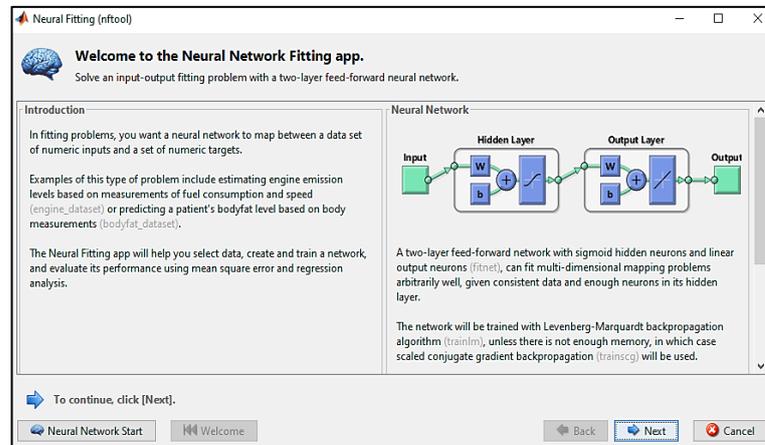


Figura 4-3. Asistente de diseño de la red neuronal en Matlab

Realizado por: Martínez, Denisse, 2021.

- 2) Se seleccionan los datos de entrada y los datos de salida normalizados de la red. En este caso se denominó a las entradas normalizadas como “Entradas_N” y a la salida normalizada como “Salida_N”.

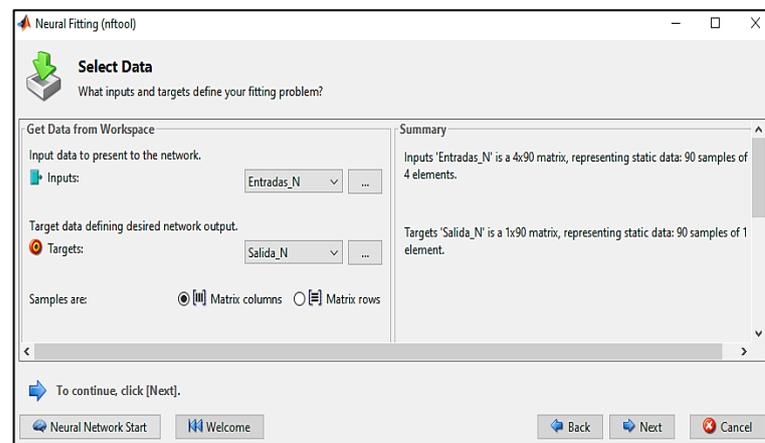


Figura 5-3. Asistente de selección de datos de entradas y salida normalizados.

Realizado por: Martínez, Denisse, 2021.

- 3) Se selecciona el porcentaje de datos que serán utilizados para realizar el entrenamiento, validación y prueba de la red (ver Figura 6-3). Cabe mencionar que la red neuronal realiza un entrenamiento, validación y prueba interna de la red donde la herramienta de diseño selecciona al azar los datos que pertenecerán al porcentaje establecido para un entrenamiento, validación y prueba. Sin embargo, con el propósito de evaluar la efectividad de predicción de

la red se validará la misma con un nuevo conjunto de datos que la red desconoce, como se explicará en el apartado posterior de validación de la red.

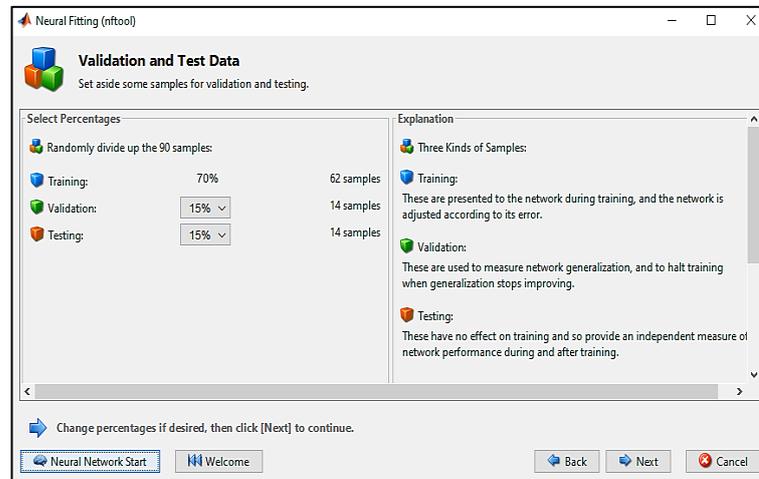


Figura 6-3. Selección del porcentaje de datos para entrenamiento, validación y prueba

Realizado por: Martínez, Denisse, 2021.

3.6.4. Selección del número de neuronas en la capa oculta

El número óptimo de neuronas se selecciona por el método de prueba y error, que consiste en aumentar neuronas o disminuir neuronas en función del error de predicción (MSE) y la correlación de los resultados (R) (Villada et al., 2016, p.146).

Dentro de la arquitectura de red también es posible variar el número de capas ocultas; sin embargo se opta por modificar primero el número de neuronas en la capa oculta y según el rendimiento de predicción de la red se modificará el número de capas ocultas ya que se ha demostrado en la mayoría de casos que una capa oculta es suficiente para resolver problemas de ajuste de datos (López et al., 2015, p.76).

En este caso se inició con una red conformada por:

- *Capa de entrada:* una capa de entrada con cuatro variables de entrada.
- *Capa de oculta:* una capa oculta con 5 neuronas (este número de neuronas el usuario modifica según la predicción)
- *Capa de salida:* una capa de salida con una variable de salida correspondiente al PCS.

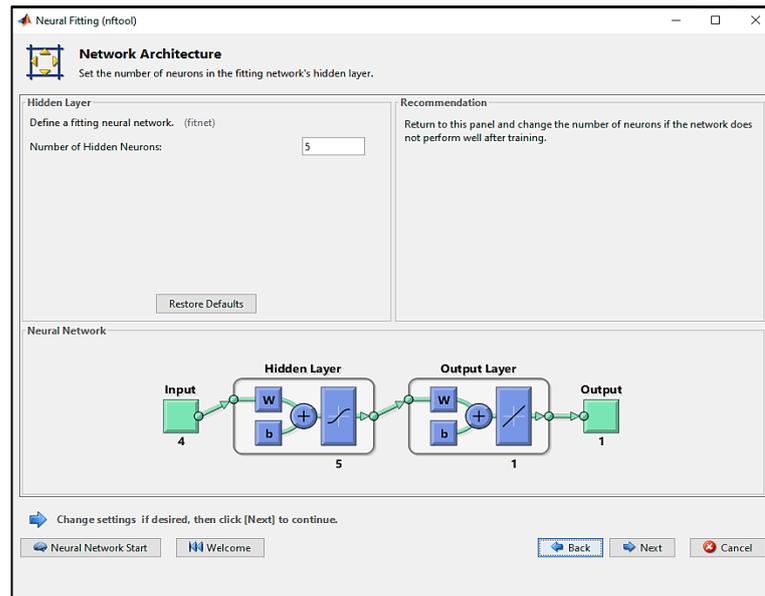


Figura 7-3. Selección del número de neuronas en la capa oculta
Realizado por: Martínez, Denisse, 2021.

3.7. Entrenamiento de la red neuronal artificial

Al entrenar la red neuronal artificial se establece el porcentaje de datos que se utilizarán para entrenar la red de toda la base de datos seleccionada. Por defecto la herramienta de diseño asigna un 70 % de los datos para entrenar la red, esta recomendación es bastante común y eficaz en el diseño de redes neuronales artificiales. Durante este proceso la red utilizará estos datos para aprender y disminuir el error de predicción.

3.7.1. Selección del algoritmo de entrenamiento

En el proceso de entrenamiento, resulta importante y necesario seleccionar el algoritmo de aprendizaje para la red (ver Figura 8-3). Para este estudio se seleccionó el algoritmo de Levenberg Marquardt (LM). Este algoritmo de entrenamiento es una técnica para problemas de mínimos cuadrados no lineales, es un método iterativo comúnmente usado en varias disciplinas para el ajuste de datos que busca alcanzar un mínimo en el error cuadrático medio basándose en el método de Gauss-Newton para garantizar una rápida convergencia, mejorando la predicción (Cornejo y Rebolledo, 2016, p.85). Se seleccionó este algoritmo porque permite a la red aprender rápidamente y se ajusta a la mayoría de los casos obteniendo buenos resultados.

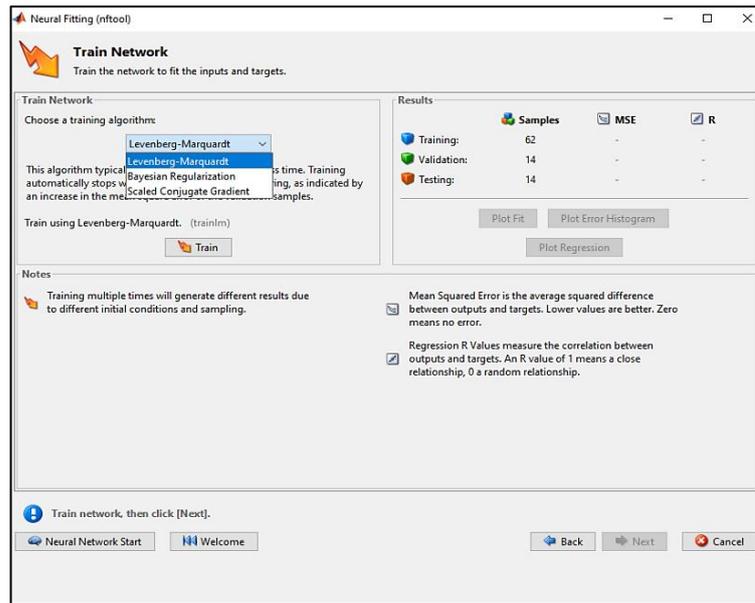


Figura 8-3. Selección del algoritmo de entrenamiento.

Realizado por: Martínez, Denisse, 2021.

Como se observa en la Figura 8-3, también se pueden elegir entre otros dos algoritmos de entrenamiento, el algoritmo de Bayesian Regularization y el de Scaled Conjugate Gradient, sin embargo, se entrenará la red neuronal usando estos algoritmos en caso de que el algoritmo de Levenberg Marquardt no presente buenos resultados; esto debido a que requieren mayor tiempo de entrenamiento y en ocasiones no se ajustan satisfactoriamente.

El asistente de diseño muestra una ventana (ver Figura 9-3) en la cual podemos observar el tiempo de entrenamiento y evaluar la predicción de la red mediante la opción *performance* donde se indica el error de predicción (MSE) y la *regression* donde se indica la correlación de los datos predichos.

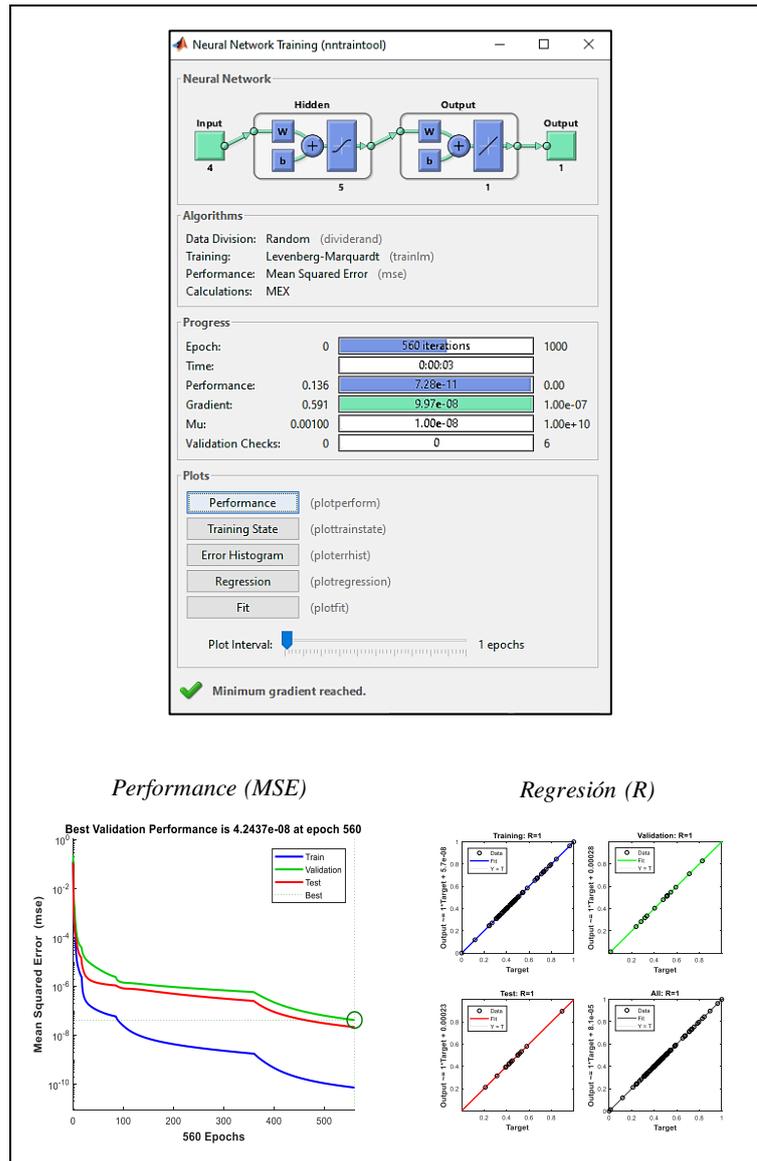


Figura 9-3. Proceso de entrenamiento de la red neuronal artificial

Realizado por: Martínez, Denisse, 2021.

3.8. Validación de la red neuronal artificial

3.8.1. Análisis estadístico

Para la proyección de los datos, la red neuronal artificial realiza una validación interna de los mismos, pero, es necesario evaluar la efectividad del modelo de predicción del poder calorífico superior en los residuos de cáscara de naranja mediante un análisis estadístico, donde se comparan los datos predichos por la red neuronal artificial con los datos reales del PCS. Para ello se emplea un nuevo conjunto con 10 pares de datos (estos datos la red desconoce porque no fueron incluido

durante el entrenamiento) y a estos datos se les realizará un análisis estadístico de comparación (análisis de varianza), corroborando el buen rendimiento de la red mediante el software SPSS.

3.8.1.1. Análisis de varianza

Uno de los métodos que permite comparar varias muestras es el análisis de la varianza (Anova). Este análisis se utiliza para contrastar la hipótesis de igualdad de medias de los datos a comparar, para realizar el análisis es necesario establecer dos hipótesis:

- *Hipótesis nula:* $\mu_A = \mu_B$
- *Hipótesis alternativa:* al menos dos medias entre el conjunto de datos son distintas

Donde μ_i representa la media del conjunto de datos del cual hemos tomado la muestra. El rechazo de la hipótesis nula indicará que las muestras analizadas provienen de datos con medias diferentes.

Tabla 6-3. Tabla ANOVA para el análisis de la varianza

Fuente	Suma de Cuadrados	Gl	Cuadrado Medio	Razón-F	Valor-P
Entre grupos	513,901	1	513,901	0,14	0,7104
Intra grupos	176784,	48	3682,99		
Total (Corr.)	177298,	49			

Fuente: IBM, 2020

El valor clave en la tabla Anova para aceptar o rechazar la hipótesis nula es el P-valor. P-valores pequeños ($< 0,05$) llevan al rechazo de la hipótesis nula, por tanto se aceptará la hipótesis nula si el valor-P es mayor o igual que 0,05; indicando que no existe una diferencia estadísticamente significativa entre las medias de los datos reales y predichos por la red neuronal con un nivel del 95% de confianza (IBD, 2020).

3.9. Integración de la red neuronal artificial en una interfaz gráfica de usuario

La interfaz gráfica de usuario se desarrolla utilizando la herramienta *guide* en el espacio de trabajo de Matlab, inmediatamente se abre una ventana asistente para crear la interfaz gráfica de usuario (Figura 10-3), se selecciona la opción *Blank GUI (Default)* para empezar a crear el panel de la interfaz que permitirá al usuario interactuar fácilmente con la red neuronal (Figura 11-3).

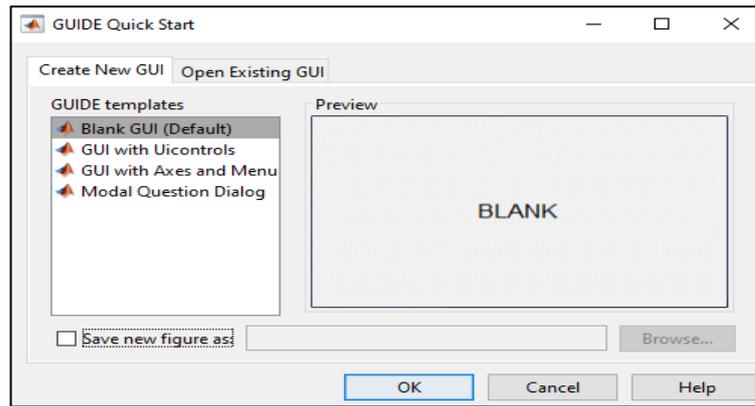


Figura 10-3. Ventana asistente de creación de la interfaz gráfica

Realizado por: Martínez, Denisse, 2021.

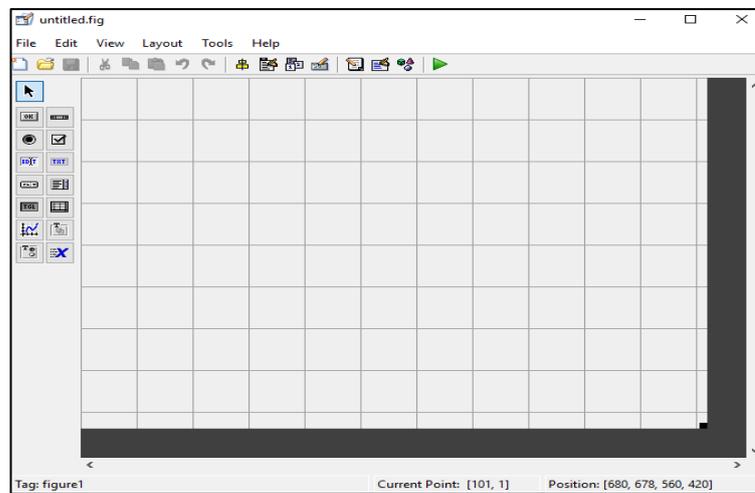


Figura 11-3. Ventana de diseño de la interfaz gráfica

Realizado por: Martínez, Denisse, 2021.

CAPÍTULO IV

4. GESTIÓN DEL PROYECTO

4.1. Cronograma

Tabla 1-4. Cronograma del proyecto

ACTIVIDAD	MESES																			
	MES 1				MES 2				MES 3				MES 4				MES 5			
	SEMANAS																			
	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4
Revisión bibliográfica de los análisis proximales realizados en la cáscara de naranja.	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■
Obtención de la cascara de naranja	■	■																		
Recolección y limpieza de la materia prima		■																		
Cortado y secado de la cáscara de naranja		■	■																	
Análisis termogravimétrico			■	■	■															
Establecimiento de la base de datos					■	■	■	■												
Diseño de la red neuronal en Matlab									■	■	■	■	■							
Análisis estadístico											■	■	■							
Desarrollo de la interfaz gráfica														■	■	■				
Estudio técnico y económico			■	■	■				■	■	■	■								
Redacción del trabajo final					■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■
Análisis de costos			■	■	■				■	■	■		■	■	■					
Presentación de resultados					■	■	■	■	■	■	■	■	■	■	■	■				

Realizado por: Martínez, Denisse, 2021

4.2. Presupuesto

Tabla 2-4. Presupuesto del proyecto

PRESUPUESTO				
CONCEPTO	CANTIDAD	VALOR UNITARIO	VALOR TOTAL	FINANCIAMIENTO
LOGÍSTICA				
Investigación bibliografía y aprendizaje (Internet)	5	20	100,00	x
Licencia estudiantil "Matlab y Simulink Student Suite"	1	55	55,00	x
Imprevistos	1	25	25	
SUBTOTAL			155,00	
ANÁLISIS DE LABORATORIO ACREDITADO				
Envío de muestras	1	5	5,00	x
Análisis termogravimétrico	1	80,00	80,00	x
SUBTOTAL			85,00	
TOTAL			240,00	

Realizado por: Martínez, Denisse, 2021

4.3. Recursos materiales

Tabla 3-4. Talento humano

Talento humano	Descripción
Estudiante: Lilibeth Martínez	Realiza la propuesta tecnológica que tiene por nombre "Diseño de una red neuronal artificial para la predicción del poder calorífico superior a partir del análisis termogravimétrico (TGA) de residuos de naranja"
Docentes de apoyo: Ing. Mabel Parada Ing. Mónica Andrade	Revisión y corrección del proyecto

Realizado por: Martínez, Denisse, 2021

Tabla 4-4. Recursos materiales utilizados en el proyecto

Equipo y software	Descripción	Uso
Termobalanza	Equipo / máquina: Mettler Toledo TGA-1 del área de investigación en la Facultad de Ingeniería Química en la Universidad Central del Ecuador	Análisis termogravimétrico de la biomasa conformada por cáscara de naranja
Matlab	Software simulador de redes neuronales artificiales	Diseñar la red neuronal artificial
SPSS	Software de análisis estadístico	Validar los resultados de la red neuronal artificial

Realizado por: Martínez, Denisse, 2021

4.4. Discusión y Análisis de Resultados

4.4.1. Análisis termogravimétrico

El análisis termogravimétrico realizado en la termobalanza (Mettler Toledo TGA-1) con una tasa de calentamiento de 15 °C/min en atmosfera inerte con incrementos de temperatura desde los 25 a 900 °C e inyección de nitrógeno a 20 ml/min permitió recopilar 100 datos de la variación del peso de una muestra de biomasa conformada por cascara de naranja del cantón Caluma en función de la temperatura y el tiempo como se describe en la siguiente tabla.

Tabla 5-4. Resultados del análisis termogravimétrico

Tiempo (s)	Temperatura (°C)	Masa (mg)
0	25	24,73
20	30	24,725
40	35	24,6865
60	40	24,6357
80	45	24,556
100	50	24,4479
120	55	24,2925
140	60	24,079
160	65	23,8169
180	70	23,4673
200	75	23,0514
220	80	22,5954
240	85	22,0587
260	90	21,4444
280	95	20,778
300	100	20,0558
320	105	19,2449
340	110	18,3764
360	115	17,4467
380	120	16,4548
400	125	15,4496
420	130	14,4321
440	135	13,4047
460	140	12,3952
480	145	11,4146
500	150	10,4855
520	155	9,64795
540	160	8,93704
560	165	8,47509
580	170	8,26494

600	175	8,13984
620	180	8,05155
640	185	7,97305
660	190	7,89755
680	195	7,83095
700	200	7,7391
720	205	7,63685
740	210	7,529
760	215	7,38415
780	220	7,21465
800	225	7,04965
820	230	6,8782
840	235	6,7212
860	240	6,5712
880	245	6,41433
900	250	6,26499
920	255	6,13049
940	260	5,99165
960	265	5,8715
980	270	5,76894
1000	275	5,65738
1020	280	5,54514
1040	285	5,44569
1060	290	5,33088
1080	295	5,22275
1100	300	5,09405
1120	305	4,96765
1140	310	4,8473
1160	315	4,70459
1180	320	4,55519
1200	325	4,38854
1220	330	4,20813
1240	335	4,0525
1260	340	3,937
1280	345	3,84835
1300	350	3,7906
1320	355	3,7342
1340	360	3,68945
1360	365	3,65405
1380	370	3,6095
1400	375	3,58
1420	380	3,54375
1440	385	3,5016
1460	390	3,47715
1480	395	3,4449

1500	400	3,40655
1520	405	3,38525
1540	410	3,3524
1560	415	3,31135
1580	420	3,28995
1600	425	3,25053
1620	430	3,21265
1640	435	3,17555
1660	440	3,13312
1680	445	3,08905
1700	450	3,0569
1720	455	3,01473
1740	460	2,9716
1760	465	2,93285
1780	470	2,88958
1800	475	2,85955
1820	480	2,8025
1840	485	2,76098
1860	490	2,73225
1880	495	2,6925
1900	500	2,64398

Realizado por: Martínez, Denisse, 2021

Fuente: Laboratorio de investigación UCE

4.4.2. *Análisis proximal de la biomasa*

Cálculos del análisis proximal realizado a la biomasa conformada por cáscara de naranja.

- **Humedad**

$$\%H = \frac{Phu - Pse}{Phu} \times 100$$

Donde:

%H = Porcentaje de humedad.

Phu = Peso de la muestra húmeda.

Pse = Peso de la muestra seca.

$$\%H = \frac{24.73 - 20.0558}{24.73} \times 100$$

$$\%H = \frac{24.73 - 20.0558}{24.73} \times 100$$

$$\%H = 18.90$$

- **Cenizas**

$$\%Cn = \frac{Pcn}{Pim} \times 100$$

Donde:

%Cn =Porcentaje de cenizas

Pcn =Peso de cenizas (mg)

Pim =Peso inicial de la muestra (mg)

$$\%Cn = \frac{2.64328}{24.73} \times 100$$

$$\%Cn = 10.69$$

- **Materia volátil**

$$\%M. V = \%C - \%H$$

$$\%C = \frac{D - E}{D} * 100$$

Donde:

%M. V = Porcentaje de Materia Volátil

%C = Pérdida de peso

%H = Porcentaje de Humedad

D =Peso de la muestra (mg)

E =Peso de la muestra después del calentamiento (mg)

$$\%C = \frac{20.0558 - 6.26499}{20.0558} * 100$$

$$\%C = 68.762$$

$$\%M. V = 68.762 - 18.90$$

$$\%M. V = 49.86$$

- **Carbono fijo**

$$\%C. F = 100 - (\%H + \%Cn + \%M. V)$$

$$\%C. F = 100 - (18.90 + 10.69 + 49.86)$$

$$\%C. F = 20.54$$

Donde:

%C. F = Porcentaje de carbono fijo

%H = Porcentaje de Humedad

%Cn =Porcentaje de cenizas

%M. V = Porcentaje de Materia Volátil

Tabla 6-4. Resultados del análisis proximal

% Humedad	% Cenizas	% Material volátiles	%Carbono fijo
18,90	10,69	49,86	20,54

Realizado por: Martínez, Denisse, 2021

Estos resultados conforman uno de los pares de datos utilizados para establecer la base de datos como se describe en el ANEXO B.

4.4.3. Poder calorífico superior de los residuos de cáscara de naranja

Cálculo del poder calorífico superior a partir del porcentaje de humedad, carbono fijo, materia volátil y cenizas comprendidos en el análisis proximal realizado a la cáscara de naranja.

1) Poder calorífico superior en función de materia volátil y carbono fijo

- $PCS = -10,81408 + 0,3133(MV + CF)$
 $PCS = -10,81408 + 0,3133(49,86 + 20,54)$
 $PCS = 11,2446 \text{ MJ/Kg}$
- $PCS = -3,0368 + 0,2218MV + 0,2601CF$
 $PCS = -3,0368 + 0,2218(49,86) + 0,2601(20,54)$
 $PCS = 13,3666 \text{ MJ/Kg}$
- $PCS = 0,312CF + 0,1534MV$
 $PCS = 0,312(20,54) + 0,1534(49,86)$
 $PCS = 14,0592 \text{ MJ/Kg}$
- $PCS = 0,3543CF + 0,1708MV$
 $PCS = 0,3543(20,54) + 0,1708(49,86)$
 $PCS = 15,7959 \text{ MJ/Kg}$

2) Poder calorífico superior en función del carbono fijo

- $PCS = 0,196CF + 14,119$
 $PCS = 0,196(20,54) + 14,119$
 $PCS = 18,1461 \text{ MJ/Kg}$

3) Poder calorífico superior en función de materia volátil y cenizas

- $PCS = 35,43 - 0,1835MV - 0,3543Cn$
 $PCS = 35,43 - 0,1835(49,86) - 0,3543(10,69)$
 $PCS = 22,4925 \text{ MJ/Kg}$
- $PCS = 0,3536CF + 0,1559MV - 0,0078Cn$
 $PCS = 0,3536(20,54) + 0,1559(49,86) - 0,0078(10,69)$
 $PCS = 14,9552 \text{ MJ/Kg}$

4) Poder calorífico superior en función de Cenizas

- $$PCS = 19,914 - 0,2324Cn$$

$$PCS = 19,914 - 0,2324(10,69)$$

$$PCS = 17,4293 \text{ MJ/Kg}$$

5) Poder calorífico superior en función de Materia volátil, carbono fijo, humedad y cenizas

- $$PCS = -0,03Cn - 0,11H + 0,33MV + 0,35CF$$

$$PCS = -0,03(10,69) - 0,11(18,90) + 0,33(49,86)$$

$$+ 0,35(20,54)$$

$$PCS = 21,2456 \text{ MJ/Kg}$$

Tabla 7-4. Resultados del poder calorífico superior en función del análisis proximal

Análisis proximal	PCS (MJ/Kg)
Materia volátil y carbono fijo	11,2446
	13,3666
	14,0592
	15,7959
Carbono fijo	18,1461
Materia volátil y cenizas	22,4925
	14,9552
Cenizas	17,4293
Materia volátil, carbono fijo, humedad y cenizas	21,2456
Promedio	16,5261

Realizado por: Martínez, Denisse, 2021

En la

Tabla 7-4 se resumen los cálculos del poder calorífico superior a partir del análisis proximal de los residuos de cascara de naranja en Caluma; estos resultados conforman uno de los pares de datos utilizados para establecer la base de datos como se describe en el ANEXO B.

Resulta necesario mencionar que, al diseñar la red neuronal artificial se emplearon los datos del poder calorífico superior promedio, con la finalidad de proporcionar a la red un conjunto de datos representativo de las diferentes ecuaciones que permiten calcular el PCS.

4.4.4. Base de datos de la red neuronal artificial

De la base de datos, el conjunto de datos empleados para entrenar la red neuronal artificial se encuentran tabulados en el ANEXO C, mientras que los datos empleados para validar la red neuronal se describen en el ANEXO D.

4.4.5. Desarrollo de la red neuronal artificial

En Matlab se normalizan los datos de las variables de entrada y los datos de salida de la red neuronal artificial. En el ANEXO E se presenta el script para la normalización de los datos de entrenamiento y en el ANEXO F la normalización de los datos de validación.

Luego de normalizar los datos, se desarrolla y entrena la red neuronal artificial como se observa en el script del ANEXO G. Dentro del script se tiene la variable “hiddenLayerSize”, fundamental para establecer el número de neuronas en la capa oculta de la red como se describe en el ANEXO G.

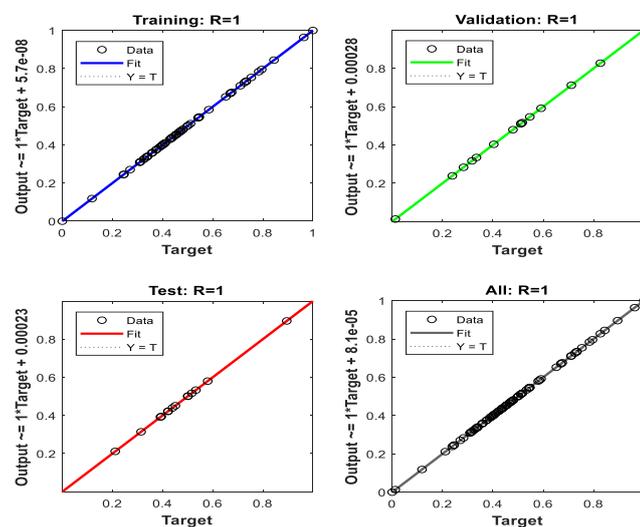


Gráfico 1-4. Correlación lineal en el entrenamiento de la red

Realizado por: Martínez, Denisse, 2021

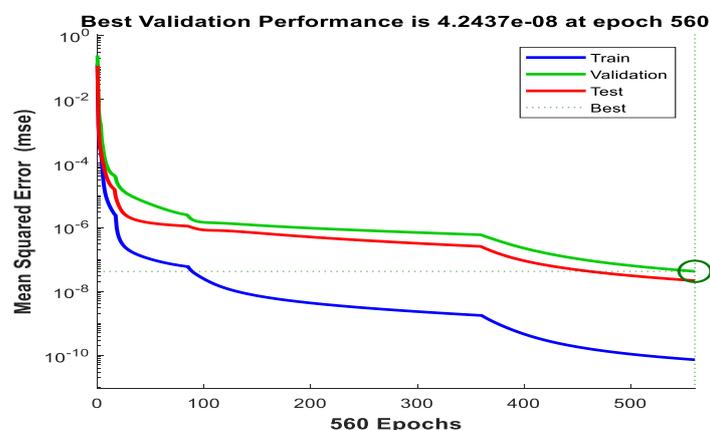


Gráfico 2-4. Error cuadrático medio en entrenamiento de la red

Realizado por: Martínez, Denisse, 2021

Una correlación lineal de 1 (ver Gráfico 1-4) y el error cuadrático medio de $4.2437e^{-08}$ (ver Gráfico 2-4) durante el entrenamiento con el algoritmo de Levenberg Marquardt permiten determinar que la mejor topología de red consta de 10 neuronas en la capa oculta. Los datos predichos durante el entrenamiento de la red neuronal se presentan en el ANEXO H.

4.4.6. Validación de la red neuronal artificial

Empleando 10 nuevos pares de datos (ver ANEXO D), se realiza un nuevo script con el objetivo de validar la red neuronal y evaluar la predicción del poder calorífico superior en los residuos de cáscara de naranja en función del aprendizaje de la red neuronal durante su entrenamiento. La programación se describe en el script del ANEXO I, donde la variable “net” contiene los parámetros aprendidos por la red neuronal y que permitirán calcular el poder calorífico superior a partir de los nuevos datos de entrada, es decir, datos que desconoce la red porque no los aprendió durante su entrenamiento. Los datos predichos por la red neuronal artificial durante para su validación por análisis estadístico de la varianza se observan en el ANEXO J con su correspondiente error en la predicción. El error porcentual promedio en la predicción de la red es de 0,00083%.

4.4.6.1. Análisis de la varianza

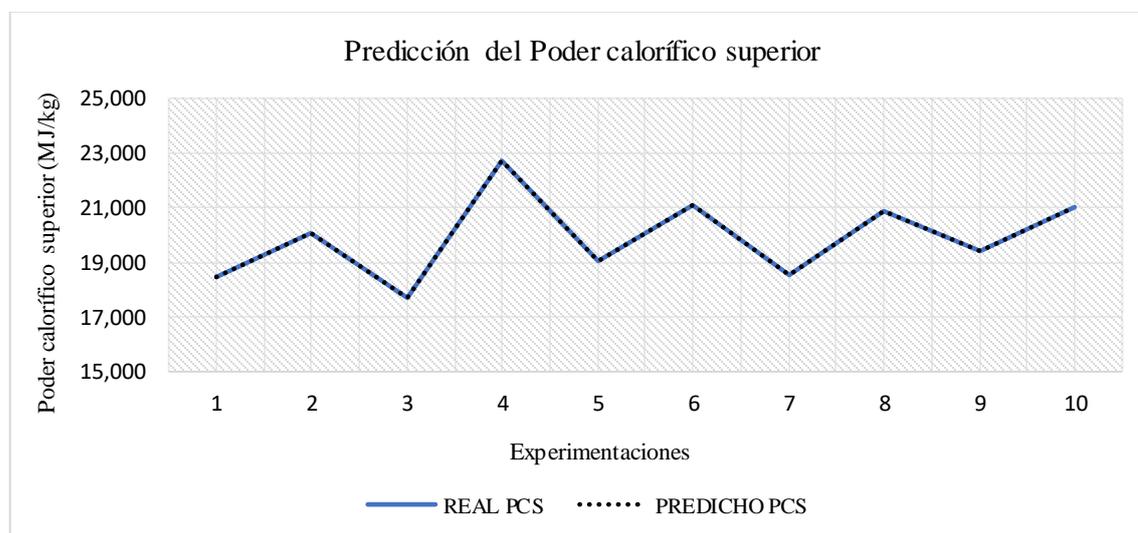


Gráfico 3-4. Poder calorífico superior real y predicho por la red neuronal artificial

Realizado por: Martínez, Denisse, 2021

Tabla 8-4. Análisis de la media en los datos reales y predichos

Variables	Casos	Media	Error estándar	Límite Inferior	Límite Superior
Poder calorífico superior real	10	19,8949	0,486197	19,1726	20,6172

Poder calorífico superior predicho	10	19,8948	0,486197	19,1725	20,6171
Total	20	19,8949			

Realizado por: Martínez, Denisse, 2021

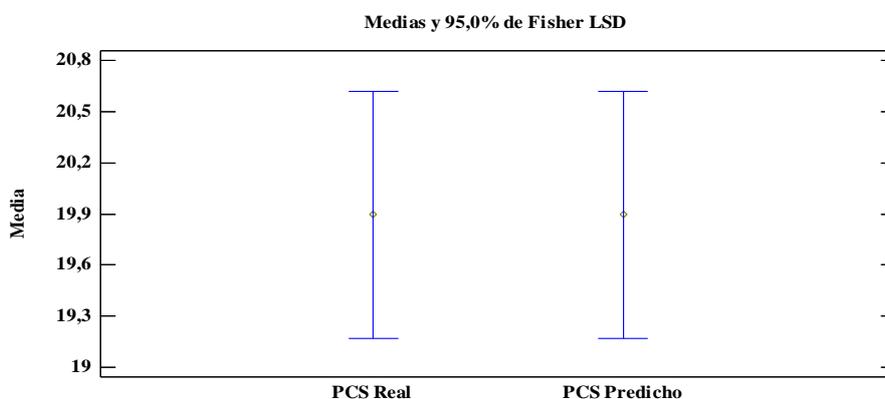


Gráfico 4-4. Gráfico de medias para los datos reales y predichos

Realizado por: Martínez, Denisse, 2021

En la Tabla 8-4 y el Gráfico 4-4 se describe las medias de 19,8949 para los datos reales y de 19,8948 para los predichos del poder calorífico superior, además en la tabla se muestra el error estándar de cada media, el cual es una medida de la variabilidad de su muestreo. El error estándar es el resultado de dividir la desviación estándar mancomunada entre el número de observaciones en cada nivel. La tabla también muestra un intervalo alrededor de cada media. Los intervalos mostrados actualmente están basados en el procedimiento de la diferencia mínima significativa (LSD) de Fisher. Están contruidos de tal manera que, si dos medias son iguales, sus intervalos se traslaparán un 95,0% de las veces. Puede ver gráficamente los intervalos seleccionando en el Gráfico 4-4.

Tabla 9-4. Análisis de la varianza en los datos reales y predichos

Fuente	Suma de Cuadrados	Gl	Cuadrado Medio	Razón-F	Valor p
Poder calorífico superior real	3,33099E-8	1	3,33099E-8	1,40913E-8	0,9999
Poder calorífico superior predicho	42,5497	18	2,36387		
Total	42,5497	19			

Realizado por: Martínez, Denisse, 2021

En la Tabla 9-4 se observa una razón-F, que en este caso es igual a 1,40913E-8, es el cociente entre el estimado entre grupos y el estimado dentro de grupos. Puesto que existe un valor p 0,9999 que es mayor que el nivel de significancia de 0,05 se acepta la hipótesis nula de igualdad de medias, lo cual confirma con un 95% de confianza, que no existe una diferencia estadísticamente significativa entre las medias de los datos reales y los datos predichos por la red neuronal.

4.4.7. Desarrollo y validación de la interfaz gráfica de usuario

Al diseñar la interfaz gráfica en Matlab, se crea un archivo con las correspondientes líneas de comandos para la codificación de la interfaz; un script donde es posible interconectar la interfaz gráfica con la red neuronal artificial. El script descrito en el ANEXO K detalla la programación de la interfaz gráfica que permitirá al usuario predecir el poder calorífico superior en los residuos de cáscara de naranja.

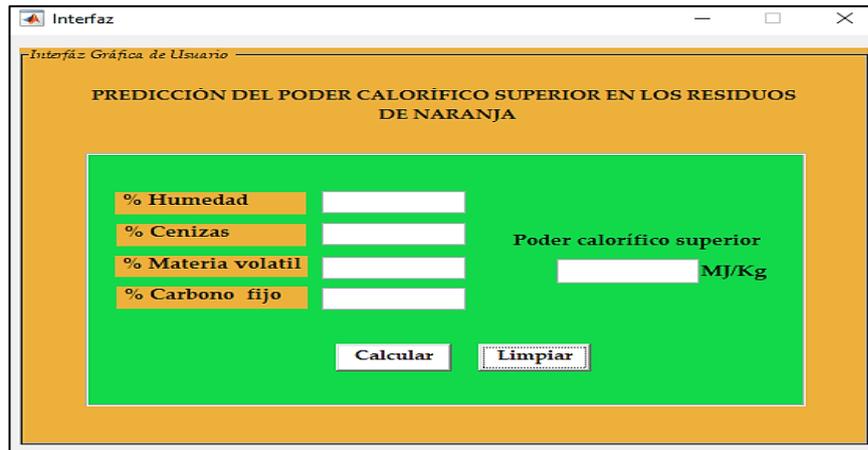


Figura 1-4. Interfaz gráfica de usuario para la red neuronal artificial

Realizado por: Martínez, Denisse, 2021

Con la finalidad de validar la predicción de la red mediante la interfaz gráfica de usuario se ingresaron datos del análisis próximo realizado por Morales et al. (2019) con la cascara de naranja para evaluar su poder calorífico superior como se observa en la siguiente figura.

Residuo de Fruta	Ht (%)	Cz (%)	MV (%)	CF (%)	IC	PCS (MJ/kg)
Cáscara de guanábana	78,12	6,22	73,07	20,71	3,53	18,83
Semilla de guanábana	62,48	1,58	88,28	10,14	8,71	18,24
Cáscara de mango	73,85	3,29	82,50	14,22	5,80	18,70
Semilla de mango	54,36	1,36	83,77	14,87	5,63	19,05
Cáscara de naranja	71,27	4,06	71,08	24,86	2,86	19,34
Semilla de naranja	63,70	3,26	92,45	4,29	21,55	15,86
Cáscara de maracuyá	88,99	8,03	78,25	13,72	5,70	18,04
Semilla de maracuyá	80,46	1,36	80,98	17,66	4,59	19,35
Cáscara de						

Figura 2-4. Análisis próximo y PCS de la cascara de naranja

Fuente: Morales et al., 2019

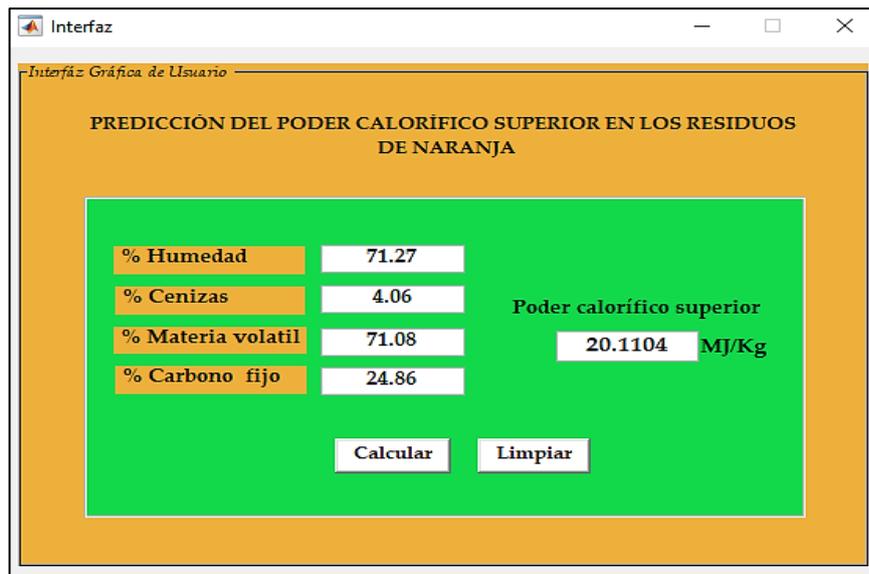


Figura 3-4. Predicción de la red mediante la interfaz gráfica

Realizado por: Martínez, Denisse, 2021

Tabla 10-4. Predicción del poder calorífico superior en la cáscara de naranja

Variable	Real (Morales et al., 2019)	Predicho (Modelo de predicción)	Error (%)	Unidades
Poder Calorífico Superior	19,34	20,1104	3,98	MJ/kg

Realizado por: Martínez, Denisse, 2021

En la Figura 2-4 se describen un poder calorífico superior de 19,34 MJ/kg para una biomasa conformada por cascara de naranja con un contenido de humedad de 71,27%, cenizas de 4,06%, materia volátil de 71,08% y de carbono fijo de 24,86%. Estos resultados se contrastan con el valor de 20,1104 MJ/kg predicho mediante la interfaz gráfica de la red neuronal artificial que se observa en la Figura 3-4. En la Tabla 10-4 se evalúa la predicción, determinándose un error del 3,98% en la predicción del poder calorífico superior.

CONCLUSIONES

- Adquiriendo la licencia de “Matlab y Simulink Student Suite” se diseñó una red neuronal artificial prealimentada (Feedforward Neural Networks) con aprendizaje supervisado para predecir con una precisión razonable el poder calorífico superior de los residuos de cáscara de naranja del cantón Caluma. La red fue entrenada y validada a partir del análisis termogravimétrico y proximal de estos residuos.
- Se recopiló un conjunto de 110 datos experimentales mediante análisis termogravimétrico y análisis proximal que se han realizado en los residuos de cáscara de naranja. De los cuales, 100 datos se emplearon para entrenar la red neuronal y 10 datos para validar la predicción de la red.
- La red neuronal artificial trabaja con 4 variables de entrada correspondientes al % Humedad, % Carbono Fijo, % Materia Volátil y % Cenizas en los residuos de cáscara de naranja; opera con 10 neuronas en la capa oculta, y predice el poder calorífico superior como variable de salida. Además, la red se entrenó con el algoritmo de Levenberg Marquardt, obteniendo una correlación lineal de 1 y un error cuadrático medio de $2,97 \times 10^{-10}$.
- Los resultados del poder calorífico superior predicho se compararon estadísticamente con los resultados calculados a partir de diferentes análisis proximales realizados y reportados en bibliografía. Con un valor p de 0,999 se acepta la hipótesis nula de igualdad de medias, evidenciando que no existe una diferencia estadística significativa entre la media de los datos experimentales y los predichos por la red.
- La interfaz gráfica permite al usuario interactuar fácilmente con la red neuronal artificial al ingresar datos de % Humedad, % Carbono Fijo, % Materia Volátil y % Cenizas presentes en una muestra de cáscara de naranja para calcular el poder calorífico superior de estos residuos; brindando la posibilidad de utilizar estos residuos como una nueva fuente de bioenergía en procesos de conversión termoquímica.

RECOMENDACIONES

- Emplear la metodología desarrollada para diseñar redes neuronales que permitan calcular el poder calorífico superior de otras biomasas. Además, de los residuos de biomasa agrícola, existe una generación constante de residuos domésticos orgánicos y de residuos industriales.
- Utilizar el modelo de predicción en proyectos relacionados con la pirólisis o gasificación de biomasa que use los residuos de cáscara de naranja como fuente de bioenergía.
- Comparar los resultados del modelo de predicción con otra red neuronal que prediga el PCS a partir de diferentes análisis elementales realizados en los residuos de cáscara de naranja, es decir, en función de sus componentes elementales (C, H, N, O, S).
- Basarse en el modelo de predicción desarrollado para predecir no sólo el poder calorífico superior; con datos del análisis proximal, TGA y modelos apropiados también se puede calcular propiedades como la densidad, entalpía, energía de activación, entre otras.

GLOSARIO

Algoritmo de entrenamiento: un algoritmo inteligente que puede obtener sensibilidad de un conjunto proporcionado de datos de entrenamiento (Kim et al., 2015, p.102).

Algoritmo de Levenberg-Marquardt: una técnica estándar para problemas de mínimos cuadrados no lineales, ampliamente adoptada para entrenar redes neuronales artificiales. Similar al algoritmo de retropropagación, pero con la diferencia de que el error se estima según la Matriz de Hesse. Esta matriz da información de varias direcciones a donde ir durante el entrenamiento de la red para encontrar el mínimo de la función de error (Vicen et al., 2015, p.934).

Análisis de la varianza: es una forma conceptualmente simple, poderosa y popular de realizar pruebas estadísticas en experimentos que involucran a dos o más grupos. Analiza toda la variabilidad del conjunto de datos dividiendo la varianza entre grupos versus la varianza dentro de los grupos. Si la variabilidad entre los grupos es mucho mayor que la variabilidad dentro de los grupos (valor- $P < 0,05$), entonces al menos uno de los grupos tiene una media que es significativamente diferente de los demás (Smalheiser, 2017, p.149).

Análisis proximal: análisis que comprende porcentajes en masa de humedad, cenizas, materia volátil y carbono fijo, que se obtienen de una serie de pruebas estandarizadas (Niksa, 2020).

Análisis termogravimétrico: es una técnica de análisis térmico que mide el cambio de peso de un material en función de la temperatura y el tiempo, en un entorno controlado (Abraham et al. 2020).

Bioenergía: es una de las energías renovables más utilizadas, especialmente para la generación de calor y energía combinados; y la conversión en biocombustibles (Martinez et al., 2020, p.136).

Biomasa: material orgánico no fósil de origen biológico, por ejemplo, residuos forestales, madera y desechos de madera, cultivos y desechos agrícolas, desechos municipales e industriales. La biomasa vegetal puede reemplazar el uso de combustibles fósiles o petróleo, por combustión para la generación de energía (bioenergía), en la producción de combustibles líquidos (biocombustibles) y en la producción de materiales como los bioplásticos (Henry, 2016, p.177).

Interfaz gráfica de usuario: una pantalla gráfica que se utiliza entre un usuario y el proceso subyacente para que el usuario pueda manipular el proceso sin mucho conocimiento sobre el proceso en sí (Azad, 2017, p.10). Interfaz persona-computadora basada en una pantalla que utiliza representaciones visuales para establecer la comunicación entre la computadora y el usuario. Las GUI normalmente utilizan objetos visuales como iconos, botones y otros widgets para construir un lenguaje visual (Kratky, 2014, p.62).

Poder calorífico: El poder calorífico es básicamente una medida de energía o calor liberado (kJ o kcal) cuando 1 kg de combustible se quema por completo en presencia de aire u oxígeno (Battle et al., 2016, p.114).

Poder calorífico superior: el poder calorífico más alto en una muestra se llama poder calorífico superior (PCS) (Speight, 2020, p.398).

Red neuronal artificial: una red de muchos procesadores simples ("unidades" o "neuronas") que imita una red neuronal biológica. Las unidades están conectadas por canales de comunicación unidireccionales, que transportan datos numéricos. Las redes neuronales se pueden entrenar para encontrar relaciones no lineales en los datos y se utilizan en aplicaciones como robótica, reconocimiento de voz, procesamiento de señales o diagnóstico médico (Vicen et al., 2015, p.934).

BIBLIOGRAFÍA

ABRAHAM, J.; et al. *Characterization of green nanoparticles from plants* [En línea], 2020. S.l.: Elsevier Inc. [Consulta: 6 marzo 2021]. ISBN 9780128223482. Disponible en: <http://dx.doi.org/10.1016/B978-0-12-822348-2.00002-4>.

AHMAD, T. & CHEN, H. "A review on machine learning forecasting growth trends and their real-time applications in different energy systems". *Sustainable Cities and Society* [En línea], 2020, 54, p. 102010. [Consulta: 10 enero 2021]. ISSN 22106707. Disponible en: <https://doi.org/10.1016/j.scs.2019.102010>.

AKKAYA, E. "ANFIS based prediction model for biomass heating value using proximate analysis components". *Fuel* [En línea], 2016, 180, pp. 687-693. [Consulta: 10 enero 2021]. ISSN 00162361. Disponible en: <http://dx.doi.org/10.1016/j.fuel.2016.04.112>.

ALAKANGAS, E.; et al. "EUBIONET III - Solutions to biomass trade and market barriers". *Renewable and Sustainable Energy Reviews* [En línea], 2015, 16 (6), pp. 4277-4290. [Consulta: 6 marzo 2021]. ISSN 13640321. DOI 10.1016/j.rser.2012.03.051.

ARIZA, A. Métodos utilizados para el pronóstico de demanda de energía eléctrica en sistemas de distribución [En línea] (Trabajo de titulación). (Grado) Universidad Tecnológica de Pereira, Colombia, 2016. pp.1-145. [Consulta: 10 enero 2021]. Disponible en: <http://repositorio.utp.edu.co/dspace/bitstream/handle/11059/3862/62131A719.pdf?sequence=1>

AZAD, A. "The modular design of an internet-based laboratory". *Handbook of Research on Digital Information Technologies: Innovations, Methods, and Ethical Issues* [En línea], 2017, pp. 1-13. [Consulta: 10 enero 2021]. Disponible en: 10.4018/978-1-59904-970-0.ch001.

BATTLE, T.; et al. *The Direct Reduction of Iron* [En línea], 2016. 1. S.l.: Elsevier Ltd. [Consulta: 6 marzo 2021]. ISBN 9780080969886. Disponible en: <http://dx.doi.org/10.1016/B978-0-08-096988-6.00016-X>.

BORDOLOI, N.; et al. "Pyrolysis of Mesua ferrea and Pongamia glabra seed cover: Characterization of bio-oil and its sub-fractions". *Bioresource Technology* [En línea], 2014, 178, [Consulta: 6 marzo 2021]. pp. 83-89. ISSN 0960-8524. Disponible en: 10.1016/j.biortech.2014.10.079.

CALLEJÓN, A.; et al. "Greenhouse crop residues: Energy potential and models for the prediction of their higher heating value". *Renewable and Sustainable Energy Reviews* [en línea], 2016, 15 (2), pp. 948-955. [Consulta: 10 enero 2021]. ISSN 13640321. Disponible en: 10.1016/j.rser.2010.11.012.

CERÓN, I. & CARDONA, C. "Evaluación del proceso integral para la obtención de aceite esencial y pectina a partir de la cáscara de naranja". *Ingeniería y Ciencia - ing.cienc.* [En línea], 2015, 7 (13), pp. 65-86. [Consulta: 2 noviembre 2020]. Disponible en: <http://publicaciones.eafit.edu.co/index.php/ingciencia/article/view/401>.

CORNEJO, O. & REBOLLEDO, R. "Estimación de parámetros en modelos no lineales: algoritmos y aplicaciones. *Revista EIA* [En línea], 2016, 13(25), pp. 81-98. ISSN 1794-1237. Disponibles: 10.24050/reia.v13i25.1019.

DARVISHAN, A.; et al. "Application of MLP-ANN as a novel predictive method for prediction of the higher heating value of biomass in terms of ultimate analysis". *Energy Sources, Part A: Recovery, Utilization and Environmental Effects* [en línea], 2018, 40 (24), pp. 2960-2966. [Consulta: 10 enero 2021]. ISSN 15567230. Disponible en: <https://doi.org/10.1080/15567036.2018.1514437>.

DE, S.; et al. "Development of an artificial neural network model for the steam process of a coal biomass cofired combined heat and power (CHP) plant in Sweden". *Energy* [En línea], 2017, 32 (11), pp. 2099-2109. ISSN 03605442. DOI 10.1016/j.energy.2007.04.008.

ESTIATI, I.; et al. "Fitting performance of artificial neural networks and empirical correlations to estimate higher heating values of biomass". *Fuel* [en línea], 2016, 180, pp. 377-383. [Consulta: 15 diciembre 2020]. ISSN 00162361. Disponible en: <http://dx.doi.org/10.1016/j.fuel.2016.04.051>.

FERNÁNDEZ, M. *Valorización de biomasa residual de origen animal mediante procesos termoquímicos* [en línea], 2017. Ciudad Real, España: Universidad de Castilla-La Mancha.

FOTOVAT, F.; et al. "A CPFV model for a bubbly biomass-sand fluidized bed". *Powder Technology* [En línea]. 2015, 275, pp. 39-50. [Consulta: 10 enero 2020]. ISSN 1873328X. Disponible en: 10.1016/j.powtec.2015.01.005.

GARCÍA, R.; et al. "Spanish biofuels heating value estimation. Part II: Proximate analysis data". *Fuel* [En línea], 2015, 117, pp.1139-1147. [Consulta: 15 diciembre 2020]. ISSN 00162361. Disponible en: <http://dx.doi.org/10.1016/j.fuel.2013.08.049>.

HEIDARI, E.; et al. "Accurate prediction of nanofluid viscosity using a multilayer perceptron artificial neural network (MLP-ANN)". *Chemometrics and Intelligent Laboratory Systems* [En línea], 2016, 155, pp. 73-85. [Consulta: 10 enero 2021]. ISSN 18733239. Disponible en: <http://dx.doi.org/10.1016/j.chemolab.2016.03.031>.

HENRY, R. *Biofuels from Crop Plants* [En línea], 2016. Second Edi. S.l.: Elsevier. [Consulta: 6 marzo 2021]. ISBN 9780123948083. Disponible en: <http://dx.doi.org/10.1016/B978-0-12-394807-6.00169-6>.

HOSSEINPOUR, S.; et al. "Biomass higher heating value (HHV) modeling on the basis of proximate analysis using iterative network-based fuzzy partial least squares coupled with principle component analysis (PCA-INFPLS)". *Fuel* [En línea], 2018, 222, pp. 1-10. [Consulta: 10 enero 2021]. ISSN 00162361. Disponible en: <https://doi.org/10.1016/j.fuel.2018.02.126>.

HOSSEINPOUR, S.; et al. *Estimation of biomass higher heating value (HHV) based on the proximate analysis by using iterative neural network-adapted partial least squares (INNPLS)* [En línea], 2017 S.l.: Elsevier Ltd. [Consulta: 15 diciembre 2020]. ISBN 9826328081. Disponible en: <http://dx.doi.org/10.1016/j.energy.2017.07.075>.

HUANG, C.; et al. "Models predicting calorific value of straw from the ash content". *International Journal of Green Energy* [En línea], 2016, 5 (6), pp. 533-539. [Consulta: 10 enero 2021]. ISSN 15435075. Disponible en [10.1080/15435070802498507](https://doi.org/10.1080/15435070802498507).

IBD. *Analysis of variance (ANOVA)*. [Blog], 2020. [Consulta: 19 enero 2021]. Disponible en: [https://www.ibm.com/support/knowledgecenter/SSEP7J_11.1.0/com.ibm.swg.ba.cognos.ug_ca_dshb.doc/analysis_of_variance_\(anova\).html](https://www.ibm.com/support/knowledgecenter/SSEP7J_11.1.0/com.ibm.swg.ba.cognos.ug_ca_dshb.doc/analysis_of_variance_(anova).html).

IGHALO, J.; et al. "Application of artificial neural networks in predicting biomass higher heating value: an early appraisal". *Energy Sources, Part A: Recovery, Utilization and Environmental Effects* [En línea], 2020, 15(1), pp. 1-8. [Consulta: 10 enero 2021]. ISSN 15567230. Disponible en: <https://doi.org/10.1080/15567036.2020.1809567>.

ISMAIL, H.; et al. "Pyrolysis of waste tires: A modeling and parameter estimation study using Aspen Plus®". *Waste Management* [En línea], 2017, 60, pp. 482-493. [Consulta: 10 enero 2021]. ISSN 18792456. Disponible en: <http://dx.doi.org/10.1016/j.wasman.2016.10.024>.

JAISWAL, P.; et al. "Comparative study of various training algorithms of artificial neural network". *Proceedings - IEEE 2018 International Conference on Advances in Computing, Communication Control and Networking, ICACCCN 2018* [En línea], 2018, pp. 1097-1101. [Consulta: 10 enero 2021]. Disponible en: [10.1109/ICACCCN.2018.8748660](https://doi.org/10.1109/ICACCCN.2018.8748660).

KASMURI, N.; et al. "Integrated advanced nonlinear neural network-simulink control system for production of bio-methanol from sugar cane bagasse via pyrolysis". *Energy* [En línea], 2019, 168, pp. 261-272. [Consulta: 15 diciembre 2021]. ISSN 03605442. Disponible en: [10.1016/j.energy.2018.11.056](https://doi.org/10.1016/j.energy.2018.11.056).

KEYBONDORIAN, E.; et al. "Application of MLP-ANN strategy to predict higher heating value of biomass in terms of proximate analysis". *Energy Sources, Part A: Recovery, Utilization and Environmental Effects* [en línea], 2017, 39(22), pp. 2105-2111. [Consulta: 10 enero 2021]. ISSN 15567230. Disponible en: <https://doi.org/10.1080/15567036.2017.1403519>.

KHODAEI, H. "An overview of processes and considerations in the modelling of fixed-bed biomass combustion". *Energy* [En línea], 2015, 88, pp. 946-972. [Consulta: 15 diciembre 2020]. ISSN 03605442. Disponible en: <http://dx.doi.org/10.1016/j.energy.2015.05.099>.

KIM, D.; et al. "Nonlinear Vibration Control of 3D Irregular Structures Subjected to Seismic Loads". *IG-Global* [En línea], 2015, pp. 103-119. [Consulta: 10 enero 2021]. Disponible en: [10.4018/978-1-4666-9479-8.ch003](https://doi.org/10.4018/978-1-4666-9479-8.ch003).

KRATKY, A. "Time-Windows: Reconnecting the window-metaphor of the GUI to real space". *Handbook of Research on Interactive Information Quality in Expanding Social Network Communications* [En línea], 2014, pp. 57-69. [Consulta: 15 diciembre 2020]. Disponible en: [10.4018/978-1-4666-7377-9.ch004](https://doi.org/10.4018/978-1-4666-7377-9.ch004).

LÓPEZ, P. & VELO, R. "Estimación de la velocidad del viento mediante redes neuronales". *XI Congreso Internacional De Ingeniería De Proyectos*. Santiago de Compostela [En línea], 2015, España: Universidad de Santiago de Compostela, pp. 1083-1092.

LÓPEZ, R.; et al. *Las Redes Neuronales Artificiales* [en línea]. 2015. S.l.: Netbiblo. [Consulta: 19 enero 2021]. Metodología y Análisis de Datos en Ciencias Sociales. ISBN 9788497452465. Disponible en: <https://books.google.com.ec/books?id=X0uLwi1Ap4QC>.

MAJUMDER, A.; et al. "Development of a new proximate analysis based correlation to predict calorific value of coal". *Fuel* [En línea], 2016, 87 (13-14), pp. 3077-3081. [Consulta: 15 diciembre 2020]. ISSN 00162361. Disponible en: 10.1016/j.fuel.2008.04.008.

MARTINEZ, E. & KOK, S. "Life Cycle Analysis of Renewable Energy". *Reference Module in Earth Systems and Environmental Sciences* [En línea]. 2020. S.l.: Elsevier, pp. 135-450. [Consulta: 6 marzo 2021]. Disponible en: <https://linkinghub.elsevier.com/retrieve/pii/B9780128197271000169>.

MATHWORKS. Redes neuronales artificiales. [Blog] 2020. [Consulta: 15 diciembre 2020]. Disponible en: <https://es.mathworks.com/discovery/neural-network.html>.

MONTALVO, W. Diagnóstico de la tecnología local de la producción de la naranja (citrus sinensis) en caluma provincia de bolívar [En línea] (Trabajo de titulación). (Grado), Universidad de Guayaquil, Ecuador, 2018. pp.1-75. [Consulta: 2 noviembre 2020]. Disponible en: [http://repositorio.ug.edu.ec/bitstream/redug/29043/1/Montalvo Pinela Wilfrido Alexander.pdf](http://repositorio.ug.edu.ec/bitstream/redug/29043/1/Montalvo%20Pinela%20Wilfrido%20Alexander.pdf).

MORALES, D.; et al. "Red inalámbrica de biosensores enzimáticos para la detección de contaminantes en aguas". *Revista Politécnica* [En línea], 2019, 15 (29), pp. 9-22. [Consulta: 6 marzo 2021]. ISSN 1900-2351. Disponible en: 10.33571/rpolitec.v15n29a1.

MULERO, Á.; et al. "Artificial neural network for the correlation and prediction of surface tension of refrigerants". *Fluid Phase Equilibria* [En línea], 2017, 451, pp. 60-67. [Consulta: 15 diciembre 2020]. ISSN 03783812. DOI 10.1016/j.fluid.2017.07.022.

MUTLU, A., & YUCEL, O. "An artificial intelligence based approach to predicting syngas composition for downdraft biomass gasification". *Energy* [En línea], 2018, 165, pp. 895-901. [Consulta: 15 diciembre 2020]. ISSN 03605442. Disponible en: <https://doi.org/10.1016/j.energy.2018.09.131>.

NETZSCH. *Termobalanza (TGA)*. [Blog], 2021. [Consulta: 11 enero 2021]. Disponible en: <https://www.netzsch-thermal-analysis.com/es/productos-soluciones/termogravimetria-simultanea-calorimetria-de-barrido-diferencial/sta-449-f3-nevio/>.

NHUCHHEN, D., & ABDUL, P. "Estimation of higher heating value of biomass from proximate analysis: A new approach". *Fuel* [En línea], 2015, 99, pp. 55-63. [Consulta: 15 diciembre 2020]. ISSN 00162361. Disponible en: <http://dx.doi.org/10.1016/j.fuel.2012.04.015>.

NIKSA, S. "Fuel quality, thermophysical properties, and transport coefficients". *Process Chemistry of Coal Utilization* [En línea], 2020, pp. 23-52. [Consulta: 11 enero 2021]. Disponible en: [10.1016/b978-0-12-818713-5.00002-2](https://doi.org/10.1016/b978-0-12-818713-5.00002-2).

ÖZYUĞURAN, A., & YAMAN, S. "Prediction of Calorific Value of Biomass from Proximate Analysis". *Energy Procedia* [En línea], 2017, 107, pp. 130-136. [Consulta: 15 diciembre 2020]. ISSN 18766102. Disponible en: [10.1016/j.egypro.2016.12.149](https://doi.org/10.1016/j.egypro.2016.12.149).

PARIKH, J.; et al. "A correlation for calculating HHV from proximate analysis of solid fuels". *Fuel* [En línea], 2015, 84 (5), pp. 487-494. [Consulta: 14 diciembre 2020]. ISSN 00162361. Disponible en: [10.1016/j.fuel.2004.10.010](https://doi.org/10.1016/j.fuel.2004.10.010).

PATEL, S.; et al. "Estimation of gross calorific value of coals using artificial neural networks". *Fuel* [En línea], 2015, 86 (3), pp. 334-344. [Consulta: 10 enero 2021]. ISSN 00162361. Disponible en: [10.1016/j.fuel.2006.07.036](https://doi.org/10.1016/j.fuel.2006.07.036).

PRINS, M. "From coal to biomass gasification: Comparison of thermodynamic efficiency". *Energy* [En línea], 2015, 32 (7), pp. 1248-1259. [Consulta: 15 diciembre 2020]. ISSN 03605442. Disponible en: [10.1016/j.energy.2006.07.017](https://doi.org/10.1016/j.energy.2006.07.017).

QI, M.; et al. "Estimation of low calorific value of blended coals based on support vector regression and sensitivity analysis in coal-fired power plants". *Fuel* [En línea], 2019, 236, pp. 1400-1407. [Consulta: 14 diciembre 2020]. ISSN 00162361. Disponible en: <https://doi.org/10.1016/j.fuel.2018.09.117>.

QUINTANA, A. Implementación de un sistema de redes neuronales en Matlab para la predicción del equilibrio líquido – vapor de mezclas binarias selectas [En línea] (Trabajo de titulación). Universidad de San Buenaventura, Colombia. 2015. [Consulta: 24 enero 2021]. Disponible en: [http://bibliotecadigital.usbcali.edu.co/bitstream/10819/2611/1/Implementación de un sistema de redes_Asnaldo Quintana_USBCTG_2015.pdf](http://bibliotecadigital.usbcali.edu.co/bitstream/10819/2611/1/Implementación%20de%20un%20sistema%20de%20redes%20Asnaldo%20Quintana_USBCTG_2015.pdf)

SHENG, C. & AZEVEDO. "Estimating the higher heating value of biomass fuels from basic analysis data". *Biomass and Bioenergy* [En línea], 2015, 28 (5), pp. 499-507. [Consulta: 6 marzo 2021]. ISSN 09619534. Disponible en: [10.1016/j.biombioe.2004.11.008](https://doi.org/10.1016/j.biombioe.2004.11.008).

SMALHEISER, N. "Analysis of Variance (ANOVA)". *Data Literacy* [En línea], 2017, pp. 149-155. [Consulta: 6 marzo 2021]. DOI [10.1016/B978-0-12-811306-6.00011-7](https://doi.org/10.1016/B978-0-12-811306-6.00011-7). Disponible en: <https://doi.org/10.1016/B978-0-12-811306-6.00011-7>

SPEIGHT, J. *Analysis of gas and condensate from tight formations* [En línea], 2020. S.l.: s.n. [Consulta: 6 marzo 2021]. ISBN 9780128133156.

SULEYMANI, M., & BEMANI, A. "Application of ANFIS-PSO algorithm as a novel method for estimation of higher heating value of biomass". *Energy Sources, Part A: Recovery, Utilization and Environmental Effects* [en línea], 2018, 40 (3), pp. 288-293. [Consulta: 10 enero 2021]. ISSN 15567230. Disponible en: <https://doi.org/10.1080/15567036.2017.1413453>.

TOOR, S.; et al. "Hydrothermal liquefaction of biomass: A review of subcritical water technologies". *Energy* [en línea], 2015, 36 (5), pp. 2328-2342. [Consulta: 15 diciembre 2020]. ISSN 03605442. DOI [10.1016/j.energy.2011.03.013](https://doi.org/10.1016/j.energy.2011.03.013). Disponible en: <http://dx.doi.org/10.1016/j.energy.2011.03.013>.

TRAN-NGOC, H. "An efficient artificial neural network for damage detection in bridges and beam-like structures by improving training parameters using cuckoo search algorithm". *Engineering Structures* [En línea], 2019, 199, pp. 109637. ISSN 18737323. DOI [10.1016/j.engstruct.2019.109637](https://doi.org/10.1016/j.engstruct.2019.109637).

UZUN, H.; et al. "Improved prediction of higher heating value of biomass using an artificial neural network model based on proximate analysis". *Bioresour. Technol.* [en línea], 2017, 234, pp. 122-130. [Consulta: 15 diciembre 2020]. ISSN 18732976. Disponible en: <http://dx.doi.org/10.1016/j.biortech.2017.03.015>.

VELÁZQUEZ, B. "Development of biomass fast proximate analysis by thermogravimetric scale". *Renewable Energy* [En línea], 2018, 126, pp. 954-959. [Consulta: 10 diciembre 2020]. ISSN 18790682. Disponible en: [10.1016/j.renene.2018.04.021](https://doi.org/10.1016/j.renene.2018.04.021).

VICEN, R.; et al. "Intelligent Radar Detectors". *Encyclopedia of Artificial Intelligence* [En línea], 2015, pp. 933-935. [Consulta: 5 diciembre 2020]. Disponible en: [10.4018/9781599048499.ch137](https://doi.org/10.4018/9781599048499.ch137).

VILLADA, F.; et al. "Redes neuronales artificiales aplicadas a la predicción del precio del oro". *Informacion Tecnologica* [En línea], 2016, 27 (5), pp. 143-150. ISSN 07180764. Disponible en: 10.4067/S0718-07642016000500016.

WEN, X.; et al. "Large eddy simulation of piloted pulverised coal combustion using extended flamelet/progress variable model". *Combustion Theory and Modelling* [En línea], 2017, 21 (5), pp. 925-953. [Consulta: 15 diciembre 2020]. ISSN 17413559. Disponible en: <http://dx.doi.org/10.1080/13647830.2017.1314552>.

XIE, J.; et al. "Simulation on gasification of forestry residues in fluidized beds by Eulerian-Lagrangian approach". *Bioresource Technology* [En línea], 121, pp. 36-46. [Consulta: 10 enero 2021]. ISSN 09608524. DOI 10.1016/j.biortech.2012.06.080.

XING, J.; et al. "Predicting kinetic parameters for coal devolatilization by means of Artificial Neural Networks". *Proceedings of the Combustion Institute* [En línea], 2019, 37 (3), pp. 2943-2950. [Consulta: 15 diciembre 2020]. ISSN 15407489. DOI 10.1016/j.proci.2018.05.148. Disponible en: <https://doi.org/10.1016/j.proci.2018.05.148>.

XING, J.; et al. "Comprehensive study on estimating higher heating value of biomass from proximate and ultimate analysis with machine learning approaches". *Energy* [En línea], 2019, 188, pp. 116077. [Consulta: 15 diciembre 2020]. ISSN 03605442. Disponible en: <https://doi.org/10.1016/j.energy.2019.116077>.

YU, Z.; et al. "Unsteady natural convection heat transfer from a heated horizontal circular cylinder to its air-filled coaxial triangular enclosure". *Fuel* [En línea], 2017, 90 (3), pp. 1128-1132. [Consulta: 14 diciembre 2020]. ISSN 00162361. DOI 10.1016/j.fuel.2010.11.031. Disponible en: <http://dx.doi.org/10.1016/j.fuel.2010.11.031>.

ZHAO, H.; et al. "A review on the prediction of building energy consumption". *Renewable and Sustainable Energy Reviews* [En línea], 2015, 16 (6), pp. 3586-3592. [Consulta: 10 enero 2021]. ISSN 13640321. Disponible en: <http://dx.doi.org/10.1016/j.rser.2012.02.049>.

ANEXOS

ANEXO A: ANÁLISIS TGA EN LABORATORIO DE INVESTIGACIÓN DE LA UCE



UNIVERSIDAD CENTRAL DEL ECUADOR
FACULTAD DE INGENIERÍA QUÍMICA
ÁREA DE INVESTIGACIÓN



REPORTE DE RESULTADOS DE LABORATORIO

Lugar y fecha: Quito, 30 de noviembre de 2020

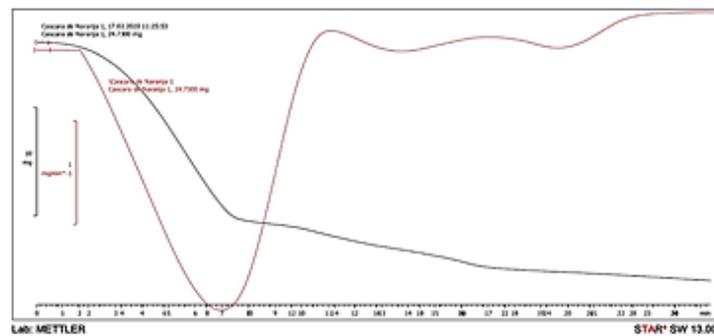
1. Datos del solicitante:

Nombre: Dennisse Lilibeth Martínez Valencia
Dirección: Quinindé
Cédula / Pasaporte / RUC: 0802413278
Teléfono: 0981154310
Persona de contacto: Dennisse Lilibeth Martínez Teléfono: 0981154310

2. Especificaciones del ensayo

Muestra: Biomasa
Descripción: Cáscara de naranja
Tipo de ensayo: Termogravimetría
Equipo / máquina: Mettler Toledo TGA-1
Analista: Ing. Pablo Londoño
Descripción del método: <ul style="list-style-type: none">Tasa de calentamiento de 15 °C/minPrograma de 25 a 900 °CAtmósfera inerte (N₂) 20 ml/minResultados de TGA y dTGA (200 puntos)
Observaciones:

3. Resultados



ANEXO B: RESULTADOS DEL PODER CALORÍFICO SUPERIOR

Humedad (%)	Cenizas (%)	Materia Volátil (%)	Carbono Fijo (%)	PCS (MJ/Kg)	PCS Promedio	Referencias								
18,9	10,69	49,86	20,54	11,2446	18,1461	14,0592	15,7959	22,4925	14,9552	17,4293	13,3666	21,2456	16,52611	Análisis TGA Caluma
5,2	3,02	74,6	16,68	17,7839	17,3883	16,6478	18,6514	20,6709	17,5046	19,2122	17,8479	29,7934	19,50005	http://dx.doi.org/10.1016/j.jaap.2012.09.016
6,15	2,66	70,33	20,86	17,7557	18,2076	17,2969	19,4031	21,5820	18,3198	19,2958	17,9881	29,7536	19,95585	https://doi.org/10.1016/j.fuel.2020.117642
9,2	2,99	70,33	13,07	15,3151	16,6807	14,8665	16,6431	21,4651	15,5627	19,2191	15,9619	26,6817	18,04399	https://doi.org/10.1016/j.jaap.2009.06.001
7,05	4,55	77,11	18,73	19,2126	17,7901	17,6724	19,8064	19,6683	18,6089	18,8566	18,9379	31,0898	20,18255	https://doi.org/10.1016/j.jaap.2008.06.009
1,5	2,3	74,1	23,6	19,7953	18,7446	18,7301	21,0178	21,0178	19,8792	19,3795	19,5369	32,4790	21,17558	https://doi.org/10.1016/j.fuel.2018.03.028
5,1	3,6	78,4	21,6	20,5159	18,3526	18,7658	21,0436	19,7681	19,8322	19,0774	19,9705	32,7630	21,12101	https://dx.doi.org/10.1021/acs.iecr.9b06989
2	2,2	75,9	19,9	19,2001	18,0194	17,8519	20,0143	20,7229	18,8523	19,4027	18,9738	31,7260	20,52926	https://doi.org/10.1016/j.tca.2017.10.013
21,5	3,5	68,3	28,2	19,4194	19,6462	19,2756	21,6569	21,6569	20,5922	19,1006	19,4470	29,9390	21,19264	https://doi.org/10.1016/j.biortech.2011.10.004
8,62	3,6	75,8	20,6	19,3880	18,1566	18,0549	20,2452	20,2452	19,0733	19,0774	19,1337	31,1678	20,50468	https://www.researchgate.net/publication/325498626
7,4	2,91	76,49	20,6	19,6042	18,1566	18,1608	20,3631	20,3631	19,1863	19,2377	19,2867	31,5504	20,65654	https://doi.org/10.1016/j.jaap.2014.08.017
3,06	2,63	77,22	19,93	19,6230	18,0253	18,0637	20,2504	20,3283	19,0653	19,3028	19,2744	32,0426	20,66398	https://doi.org/10.1016/j.jaap.2015.06.015
3,1	2,6	73,9	26,1	20,5159	19,2346	19,4795	21,8694	20,9482	20,7297	19,3098	20,1428	33,1030	21,70364	https://doi.org/10.1016/j.jaap.2015.06.015
0,4	3,3	61,1	38,9	20,5159	21,7434	21,5095	24,2182	23,0490	23,2548	19,1471	20,6331	33,6350	23,07843	https://doi.org/10.1016/j.jaap.2015.06.015
0,5	4	55,1	44,9	20,5159	22,9194	22,4611	25,3192	23,9020	24,4355	18,9844	20,8629	33,7230	23,68037	https://doi.org/10.1016/j.jaap.2015.06.015
0,5	5	44,2	55,8	20,5159	25,0558	24,1899	27,3193	25,5478	26,5827	18,7520	21,2803	33,9110	24,79497	https://doi.org/10.1016/j.jaap.2015.06.015
0,3	5,6	37,8	62,2	20,5159	26,3102	25,2049	28,4937	26,5096	27,8433	18,6126	21,5255	34,0430	25,45096	https://doi.org/10.1016/j.jaap.2015.06.015
0,2	6,6	27,6	72,4	20,5159	28,3094	26,8226	30,3654	28,0270	29,8520	18,3802	21,9161	34,2280	26,49074	https://doi.org/10.1016/j.jaap.2015.06.015
0,2	7,9	17,3	82,7	20,5159	30,3282	28,4562	32,2555	29,4565	31,8782	18,0780	22,3106	34,3950	27,51934	https://doi.org/10.1016/j.jaap.2015.06.015
0,1	8,7	11,7	88,3	20,5159	31,4258	29,3444	33,2831	30,2006	32,9791	17,8921	22,5251	34,4940	28,07334	https://doi.org/10.1016/j.jaap.2015.06.015

9,2	2,94	74,79	13,07	16,7125	16,6807	15,5506	17,4048	20,6644	16,2584	19,2307	16,9511	28,1550	18,62314	https://doi.org/10.1016/j.jaap.2014.07.012
5,7	3,02	74,6	16,68	17,7839	17,3883	16,6478	18,6514	20,6709	17,5046	19,2122	17,8479	29,7384	19,49394	https://doi.org/10.1016/j.jaap.2012.09.016
0,18	2,91	76,49	20,6	19,6042	18,1566	18,1608	20,3631	20,3631	19,1863	19,2377	19,2867	32,3446	20,74478	https://doi.org/10.1016/j.biortech.2016.05.006
11,3	3	50,9	34,8	16,0357	20,9398	18,6657	21,0234	25,0270	20,2172	19,2168	17,3043	27,6440	20,67487	https://doi.org/10.1016/j.jenvman.2018.02.092
6,8	4	48,3	40,9	17,1323	22,1354	20,1700	22,7405	25,1498	21,9610	18,9844	18,3142	29,3860	21,77484	https://doi.org/10.1016/j.jenvman.2018.02.092
4,5	6,9	33,4	55,2	16,9443	24,9382	22,3460	25,2621	26,8564	24,6720	18,3104	18,7288	29,6400	23,07758	https://doi.org/10.1016/j.jenvman.2018.02.092
7	9,4	11,9	71,7	15,3778	28,1722	24,1959	27,4358	29,9159	27,1350	17,7294	18,2518	27,9700	24,02043	https://doi.org/10.1016/j.jenvman.2018.02.092
74,26	2,77	76,49	19,4	19,2283	17,9214	17,7864	19,9379	20,4127	18,7630	19,2703	18,9746	23,7800	19,56383	https://doi.org/10.1080/00102202.2019.1582526
9,23	6,2	73,2	20,6	18,5735	18,1566	17,6561	19,8011	19,8011	18,6477	18,4731	18,5570	30,1647	19,98122	https://doi.org/10.21577/0103-5053.20200094
9,2	2,94	77,7	13,1	17,6336	16,6866	16,0064	17,9125	20,1304	16,7227	19,2307	17,6044	29,1258	19,00589	http://cdigital.dgb.uanl.mx/te/1080240833.pdf
6,8	3,2	68,32	26,5	18,8930	19,3130	18,7483	21,0580	21,7595	19,9965	19,1703	19,0092	30,9766	20,99161	https://doi.org/10.1016/j.cam.2019.03.009
8,8	5	76	19	18,9494	17,8430	17,5864	19,7125	19,7125	18,5278	18,7520	18,7619	30,6120	20,05084	https://doi.org/10.1016/j.joei.2015.02.011
10,7	10,7	70,4	18,9	17,1636	17,8234	16,6962	18,7206	18,7206	17,5749	17,4273	17,4938	28,3490	18,88549	https://doi.org/10.1016/j.joei.2015.02.011
10,5	10,5	68,7	20,8	17,2263	18,1958	17,0282	19,1034	19,1034	17,9833	17,4738	17,6109	28,4810	19,13401	https://doi.org/10.1016/j.joei.2015.02.011
12,2	12,2	64,7	23,1	16,6937	18,6466	17,1322	19,2351	19,2351	18,1597	17,0787	17,3220	27,7280	19,02567	https://doi.org/10.1016/j.joei.2015.02.011
11,6	11,6	65,8	22,6	16,8816	18,5486	17,1449	19,2458	19,2458	18,1591	17,2182	17,4359	28,0000	19,09777	https://doi.org/10.1016/j.joei.2015.02.011
11,8	11,8	58,7	29,5	16,8190	19,9010	18,2086	20,4778	20,4778	19,4905	17,1717	17,6558	28,0440	19,80513	https://doi.org/10.1016/j.joei.2015.02.011
8,41	1,91	74,21	23,88	19,9175	18,7995	18,8344	21,1358	21,1358	19,9984	19,4701	19,6342	31,8649	21,19894	http://dx.doi.org/10.1016/j.energy.2016.08.090
15	3,15	74,21	22,64	19,5290	18,5564	18,4475	20,6964	20,6964	19,5503	19,1819	19,3116	30,6688	20,73761	http://dx.doi.org/10.1016/j.energy.2016.08.090
4,25	3,95	75,31	20,74	19,2784	18,1840	18,0234	20,2111	20,2111	19,0437	18,9960	19,0614	31,5253	20,50384	http://dx.doi.org/10.1016/j.energy.2016.08.090
4	5,1	76,15	18,75	18,9181	17,7940	17,5314	19,6495	19,6495	18,4620	18,7288	18,7301	31,0990	20,06250	http://dx.doi.org/10.1016/j.energy.2016.08.090
7,37	5,05	75,69	19,26	18,9338	17,8940	17,6200	19,7517	19,7517	18,5710	18,7404	18,7608	30,7565	20,08663	http://dx.doi.org/10.1016/j.energy.2016.08.090

6,41	2,88	80,96	16,16	19,6136	17,2864	17,4612	19,5535	19,5535	18,3134	19,2447	19,1233	31,5813	20,19231	http://dx.doi.org/10.1016/j.energy.2016.08.090
14,2	2,61	80,7	16,69	19,6982	17,3902	17,5867	19,6968	19,6968	18,4624	19,3074	19,2035	30,8322	20,20825	http://dx.doi.org/10.1016/j.energy.2016.08.090
9,18	3,74	82,32	13,94	19,3442	16,8512	16,9772	18,9992	18,9992	17,7337	19,0448	18,8476	30,9226	19,74663	http://dx.doi.org/10.1016/j.energy.2016.08.090
5,3	7,07	79,94	12,88	18,2664	16,6435	16,2814	18,2171	18,2561	16,9619	18,2709	18,0440	30,0931	19,00382	http://dx.doi.org/10.1016/j.energy.2016.08.090
9,4	8,1	71,6	20,3	17,9782	18,0978	17,3170	19,4216	19,4216	18,2773	18,0316	18,1241	29,4560	19,56946	http://dx.doi.org/10.1016/j.energy.2016.08.090
8	5,5	79,7	14,8	18,7928	17,0198	16,8436	18,8564	18,8564	17,6156	18,6358	18,4901	30,4360	19,50517	http://dx.doi.org/10.1016/j.energy.2016.08.090
6,18	6,62	78,7	14,7	18,4481	17,0002	16,6590	18,6502	18,6431	17,4156	18,3755	18,2423	30,2376	19,29685	http://dx.doi.org/10.1016/j.energy.2016.08.090
9,1	20,6	63,3	16,1	14,0619	17,2746	14,7334	16,5159	16,5159	15,4008	15,1266	15,1908	24,9050	16,63608	http://dx.doi.org/10.1016/j.energy.2016.08.090
10,5	16,87	73,97	9,16	15,2305	15,9144	14,2049	15,8795	15,8795	14,6393	15,9934	15,7523	25,9550	16,60542	http://dx.doi.org/10.1016/j.energy.2016.08.090
8,6	13,94	71,08	13,94	15,8227	16,8512	15,2530	17,0794	17,4479	15,9018	16,6743	16,3545	26,9712	17,59512	http://dx.doi.org/10.1016/j.energy.2016.08.090
9,96	16,71	76,75	16,71	18,4669	17,3942	16,9870	19,0293	15,4260	17,7436	16,0306	18,3326	29,5791	18,77659	http://dx.doi.org/10.1016/j.energy.2016.08.090
9,79	11,6	72,92	15,49	16,8848	17,1550	16,0188	17,9428	17,9393	16,7550	17,2182	17,1658	28,0602	18,34888	http://dx.doi.org/10.1016/j.energy.2016.08.090
5,68	14,96	70,73	14,31	15,8290	16,9238	15,3147	17,1507	17,1507	15,9701	16,4373	16,3731	27,2758	17,60280	http://dx.doi.org/10.1016/j.energy.2016.08.090
8,93	11,01	80,89	8,1	17,0665	15,7066	14,9357	16,6858	16,6858	15,3890	17,3553	17,0114	28,2161	17,67248	http://dx.doi.org/10.1016/j.energy.2016.08.090
5,08	15,8	66,42	17,79	15,5689	17,6058	15,7393	17,6475	17,6440	16,5222	16,2421	16,3223	27,1123	17,82272	http://dx.doi.org/10.1016/j.energy.2016.08.090
12,08	14,05	68,87	17,08	16,1141	17,4667	15,8936	17,8144	17,8144	16,6667	16,6488	16,6811	26,9548	18,00607	http://dx.doi.org/10.1016/j.energy.2016.08.090
1,55	10,02	73,72	16,26	17,3767	17,3060	16,3818	18,3523	18,3523	17,1643	17,5854	17,5435	29,5475	18,84552	http://dx.doi.org/10.1016/j.energy.2016.08.090
1,1	12,9	70,5	16,6	16,4744	17,3726	15,9939	17,9228	17,9228	16,7601	16,9160	16,9178	28,5670	18,31637	http://dx.doi.org/10.1016/j.energy.2016.08.090
2,03	13,45	71,93	14,62	16,3020	16,9845	15,5955	17,4655	17,4655	16,2786	16,7882	16,7199	28,2271	17,98077	http://dx.doi.org/10.1016/j.energy.2016.08.090
7,46	17,62	66,66	15,71	14,9924	17,1982	15,1272	16,9516	16,9551	15,8099	15,8191	15,8346	26,1471	17,20391	http://dx.doi.org/10.1016/j.energy.2016.08.090
4,64	18,33	66,74	14,9	14,7637	17,0394	14,8867	16,6783	16,6889	15,5304	15,6541	15,6416	26,1789	17,00690	http://dx.doi.org/10.1016/j.energy.2016.08.090
8,43	14,83	68,25	16,92	15,8697	17,4353	15,7486	17,6519	17,6519	16,5074	16,4675	16,5019	27,0723	17,87850	http://dx.doi.org/10.1016/j.energy.2016.08.090

10,6	12,76	69,34	17,9	16,5182	17,6274	16,2216	18,1852	18,1852	17,0400	16,9486	16,9986	27,5984	18,36925	http://dx.doi.org/10.1016/j.energy.2016.08.090
7,4	6,37	74,84	18,79	18,5202	17,8018	17,3429	19,4400	19,4400	18,2620	18,4336	18,4500	30,2686	19,77324	http://dx.doi.org/10.1016/j.energy.2016.08.090
13,4	4,5	79	16,5	19,1061	17,3530	17,2666	19,3392	19,3392	18,1154	18,8682	18,7771	30,2360	19,82229	http://dx.doi.org/10.1016/j.energy.2016.08.090
8,02	11,24	81,03	8,21	17,1448	15,7282	14,9915	16,7487	16,5787	15,4480	17,3018	17,0711	28,3940	17,71186	http://dx.doi.org/10.1016/j.energy.2016.08.090
8,4	8,5	73	18,5	17,8529	17,7450	16,9702	19,0230	19,0230	17,8560	17,9386	17,9665	29,3860	19,30678	http://dx.doi.org/10.1016/j.energy.2016.08.090
7,94	5,97	83,92	10,29	18,7019	16,1358	16,0838	17,9793	17,9155	16,6751	18,5266	18,2531	30,2426	18,94597	http://dx.doi.org/10.1016/j.energy.2016.08.090
9,29	14,73	70,82	14,56	15,9355	16,9728	15,4065	17,2547	17,2157	16,0744	16,4907	16,4581	27,0028	17,64568	http://dx.doi.org/10.1016/j.energy.2016.08.090
10,14	7	76,17	16,83	18,3228	17,4177	16,9354	18,9727	18,9727	17,7714	18,2872	18,2352	29,7012	19,40181	http://dx.doi.org/10.1016/j.energy.2016.08.090
9,2	10,46	78,74	10,79	17,2357	16,2338	15,4452	17,2717	17,2752	16,0093	17,4831	17,2342	28,4349	18,06924	http://dx.doi.org/10.1016/j.energy.2016.08.090
4,1	6,3	76,4	17,3	18,5421	17,5098	17,1174	19,1785	19,1785	17,9789	18,4499	18,4085	30,6270	19,66562	http://dx.doi.org/10.1016/j.energy.2016.08.090
1,97	5,2	36,27	56,56	18,2696	25,2048	23,2105	26,2341	26,9321	25,6135	18,7055	19,7191	31,3924	23,92019	https://doi.org/10.1016/j.jaap.2013.06.016
6,18	7,35	22,5	63,97	16,2770	26,6571	23,4101	26,5076	28,6971	26,0702	18,2059	18,5923	28,9142	23,70350	https://doi.org/10.1016/j.jaap.2013.06.016
6,31	8,28	18,62	69,03	16,6467	27,6489	24,3937	27,6376	29,0796	27,2473	17,9897	19,0478	29,3626	24,33932	https://doi.org/10.1016/j.jaap.2013.06.016
3,01	1,82	42,32	52,85	19,0027	24,4776	22,9811	25,9530	27,0195	25,2713	19,4910	20,0961	32,0774	24,04106	https://doi.org/10.1016/j.jaap.2013.06.016
4,02	3,13	27,69	65,16	18,2758	26,8904	24,5776	27,8156	29,2399	27,3330	19,1866	20,0530	31,4076	24,97550	https://doi.org/10.1016/j.jaap.2013.06.016
7,85	3,99	20,86	72,43	18,4137	28,3153	25,7981	29,2248	30,1885	28,8322	18,9867	20,4290	31,2511	25,71549	https://doi.org/10.1016/j.jaap.2013.06.016
2,31	33,28	36,95	25,62	8,7891	19,1405	13,6616	15,3882	16,8586	14,5602	12,1797	11,8225	19,9080	14,70093	https://doi.org/10.1016/j.jaap.2013.06.016
1,16	40,46	20,16	29,21	4,6535	19,8442	12,2061	13,7924	17,3957	13,1560	10,5111	9,0322	15,5349	12,90290	https://doi.org/10.1016/j.jaap.2013.06.016
1,7	46,31	20,35	31,64	5,4744	20,3204	12,9934	14,6858	15,2881	13,9993	9,1516	9,7064	16,2132	13,09251	https://doi.org/10.1016/j.jaap.2013.06.016
8,3	8,93	38,09	48,39	16,2801	23,6034	20,9407	23,6503	25,2766	22,9793	17,8387	17,9978	28,3253	21,87691	https://doi.org/10.1016/j.jaap.2013.06.016
3,51	9,36	31,28	55,85	16,4837	25,0656	22,2236	25,1303	26,3739	24,5521	17,7387	18,4277	29,2030	22,79984	https://doi.org/10.1016/j.jaap.2013.06.016
5,67	10,64	19,42	64,27	15,4060	26,7159	23,0313	26,0878	28,0967	25,6705	17,4413	17,9872	27,9602	23,15520	https://doi.org/10.1016/j.jaap.2013.06.016

15,3	3,8	75	21,2	19,3254	18,2742	18,1194	20,3212	20,3212	19,1592	19,0309	19,1123	30,3730	20,44852	https://doi.org/10.1016/j.biortech.2011.10.004
10,4	9,7	73,2	17,1	17,4769	17,4706	16,5641	18,5611	18,5611	17,3828	17,6597	17,6467	28,7060	18,89210	https://doi.org/10.1016/j.biortech.2011.10.004
7,3	8,14	71,14	16,21	16,5527	17,2962	15,9704	17,8939	19,4918	16,7591	18,0223	16,9583	28,1025	18,56079	función objetivo
13,68	31,55	69,011	14,2	15,2559	16,9022	15,0167	16,8181	11,5883	15,5338	12,5818	15,9633	25,2923	16,10583	función objetivo
9	8,43	70,97	16,12	16,4712	17,2785	15,9162	17,8330	19,4203	16,6985	17,9549	16,8972	27,8192	18,47655	función objetivo
21,72	4,93	74,15	20,74	18,9150	18,1840	17,8455	20,0130	20,0768	18,8552	18,7683	18,8041	29,1914	20,07259	función objetivo
8	12,6	70,38	14,34	15,7287	16,9296	15,2704	17,1016	18,0511	15,9446	16,9858	16,3033	26,9864	17,70016	función objetivo
3,71	10,12	31,21	55,76	16,4336	25,0480	22,1847	25,0864	26,1174	24,5034	17,5621	18,3888	29,1036	22,71423	función objetivo
11,06	10,37	75,86	16,54	18,1348	17,3608	16,7974	18,8170	17,8356	17,5942	17,5040	18,0910	29,2951	19,04778	función objetivo
8,63	2,74	74,13	23,8	19,8674	18,7838	18,7971	21,0937	20,8564	19,9512	19,2772	19,5956	31,7614	21,10932	función objetivo
9,42	3,77	74,71	12,99	16,6623	16,6650	15,5134	17,3628	20,3850	16,2111	19,0379	16,9126	28,0515	18,53352	función objetivo
7,13	4,42	68,2	26,39	18,8210	19,2914	18,6956	20,9985	21,3493	19,9294	18,8868	18,9540	30,8256	20,86129	función objetivo
5,41	3,8	74,52	16,61	17,7369	17,3746	16,6137	18,6129	20,4092	17,4613	19,0309	17,8120	29,6960	19,41640	función objetivo
4,4	4,7	78,3	21,5	20,4533	18,3330	18,7192	20,9911	19,3967	19,7727	18,8217	19,9223	32,7390	21,01656	función objetivo

Realizado por: Martínez, Denisse, 2021

**ANEXO C: BASE DE DATOS DE ENTRENAMIENTO DE LA RED NEURONAL
ARTIFICIAL**

Variables de Entrada				Variable de salida
Humedad (%)	Cenizas (%)	Materia volátil (%)	Carbono Fijo (%)	PCS promedio
18,90	10,69	49,86	20,55	16,5261
5,20	3,02	74,60	16,68	19,5001
6,15	2,66	70,33	20,86	19,9558
9,20	2,99	70,33	13,07	18,0440
7,05	4,55	77,11	18,73	20,1825
1,50	2,30	74,10	23,60	21,1756
5,10	3,60	78,40	21,60	21,1210
2,00	2,20	75,90	19,90	20,5293
21,50	3,50	68,30	28,20	21,1926
8,62	3,60	75,80	20,60	20,5047
7,40	2,91	76,49	20,60	20,6565
3,06	2,63	77,22	19,93	20,6640
3,10	2,60	73,90	26,10	21,7036
0,40	3,30	61,10	38,90	23,0784
0,50	4,00	55,10	44,90	23,6804
0,50	5,00	44,20	55,80	24,7950
0,30	5,60	37,80	62,20	25,4510
0,20	6,60	27,60	72,40	26,4907
0,20	7,90	17,30	82,70	27,5193
0,10	8,70	11,70	88,30	28,0733
9,20	2,94	74,79	13,07	18,6231
5,70	3,02	74,60	16,68	19,4939
0,18	2,91	76,49	20,60	20,7448
11,30	3,00	50,90	34,80	20,6749
6,80	4,00	48,30	40,90	21,7748
4,50	6,90	33,40	55,20	23,0776
7,00	9,40	11,90	71,70	24,0204
74,26	2,77	76,49	19,40	19,5638
9,23	6,20	73,20	20,60	19,9812
9,20	2,94	77,70	13,10	19,0059
6,80	3,20	68,32	26,50	20,9916
8,80	5,00	76,00	19,00	20,0508
10,70	10,70	70,40	18,90	18,8855
10,50	10,50	68,70	20,80	19,1340
12,20	12,20	64,70	23,10	19,0257
11,60	11,60	65,80	22,60	19,0978
11,80	11,80	58,70	29,50	19,8051
8,41	1,91	74,21	23,88	21,1989
15,00	3,15	74,21	22,64	20,7376
4,25	3,95	75,31	20,74	20,5038
4,00	5,10	76,15	18,75	20,0625
7,37	5,05	75,69	19,26	20,0866
6,41	2,88	80,96	16,16	20,1923
14,20	2,61	80,70	16,69	20,2083
9,18	3,74	82,32	13,94	19,7466

5,30	7,07	79,94	12,88	19,0038
9,40	8,10	71,60	20,30	19,5695
8,00	5,50	79,70	14,80	19,5052
6,18	6,62	78,70	14,70	19,2968
9,10	20,60	63,30	16,10	16,6361
10,50	16,87	73,97	9,16	16,6054
8,60	13,94	71,08	13,94	17,5951
9,96	16,71	76,75	16,71	18,7766
9,79	11,60	72,92	15,49	18,3489
5,68	14,96	70,73	14,31	17,6028
8,93	11,01	80,89	8,10	17,6725
5,08	15,80	66,42	17,79	17,8227
12,08	14,05	68,87	17,08	18,0061
1,55	10,02	73,72	16,26	18,8455
1,10	12,90	70,50	16,60	18,3164
2,03	13,45	71,93	14,62	17,9808
7,46	17,62	66,66	15,71	17,2039
4,64	18,33	66,74	14,90	17,0069
8,43	14,83	68,25	16,92	17,8785
10,60	12,76	69,34	17,90	18,3692
7,40	6,37	74,84	18,79	19,7732
13,40	4,50	79,00	16,50	19,8223
8,02	11,24	81,03	8,21	17,7119
8,40	8,50	73,00	18,50	19,3068
7,94	5,97	83,92	10,29	18,9460
9,29	14,73	70,82	14,56	17,6457
10,14	7,00	76,17	16,83	19,4018
9,20	10,46	78,74	10,79	18,0692
4,10	6,30	76,40	17,30	19,6656
1,97	5,20	36,27	56,56	23,9202
6,18	7,35	22,50	63,97	23,7035
6,31	8,28	18,62	69,03	24,3393
3,01	1,82	42,32	52,85	24,0411
4,02	3,13	27,69	65,16	24,9755
7,85	3,99	20,86	72,43	25,7155
2,31	33,28	36,95	25,62	14,7009
1,16	40,46	20,16	29,21	12,9029
1,70	46,31	20,35	31,64	13,0925
8,30	8,93	38,09	48,39	21,8769
3,51	9,36	31,28	55,85	22,7998
5,67	10,64	19,42	64,27	23,1552
15,30	3,80	75,00	21,20	20,4485
10,40	9,70	73,20	17,10	18,8921
7,30	8,14	71,14	16,21	18,5608
13,68	31,55	69,01	14,20	16,1058

Realizado por: Martínez, Denisse, 2021

ANEXO D: BASE DE DATOS PARA VALIDAR LA RED NEURONAL ARTIFICIAL

Variables de Entrada				Variable de salida
Humedad (%)	Cenizas (%)	Materia volátil (%)	Carbono Fijo (%)	PCS promedio
9,00	8,43	70,97	16,12	18,4766
21,72	4,93	74,15	20,74	20,0726
8,00	12,60	70,38	14,34	17,7002
3,71	10,12	31,21	55,76	22,7142
11,06	10,37	75,86	16,54	19,0478
8,63	2,74	74,13	23,80	21,1093
9,42	3,77	74,71	12,99	18,5335
7,13	4,42	68,20	26,39	20,8613
5,41	3,80	74,52	16,61	19,4164
4,40	4,70	78,30	21,50	21,0166
9,00	8,43	70,97	16,12	18,4766
21,72	4,93	74,15	20,74	20,0726

Realizado por: Martínez, Denisse, 2021

ANEXO E: NORMALIZACIÓN DE LOS DATOS DE ENTRENAMIENTO

% 01. EXTRACCIÓN DE BASE DE DATOS DE EXCEL

%Leer base de datos de Excel

```
Extraer=readtable('Datos.xlsx','Sheet','DataE');
```

%Convertir la tabla a Matriz Numérica

```
Data = table2array(Extraer);
```

%-----ENTRADAS-----

% 02. NORMALIZACIÓN DE ENTRADAS

```
entradas=Data(1:4,:);
```

%-----HUMEDAD-----

```
H_max=max(entradas(1,:));
```

```
H_min=min(entradas(1,:));
```

```
H_N=[(entradas(1,1:end)-H_min)/(H_max-H_min)];
```

%-----CENIZAS-----

```
C_max=max(entradas(2,:));
```

```
C_min=min(entradas(2,:));
```

```
C_N=[(entradas(2,1:end)-C_min)/(C_max-C_min)];
```

%-----MATERIA VOLATIL-----

```
MV_max=max(entradas(3,:));
```

```
MV_min=min(entradas(3,:));
```

```
MV_N=[(entradas(3,1:end)-MV_min)/(MV_max-MV_min)];
```

%-----CARBONO FIJO-----

```
CF_max=max(entradas(4,:));
```

```
CF_min=min(entradas(4,:));
```

```
CF_N=[(entradas(4,1:end)-CF_min)/(CF_max-CF_min)];
```

%-----ENTRADAS NORMALIZADAS -----

```
Entradas_N=[H_N;C_N;MV_N;CF_N];
```

%-----SALIDA-----

%Parámetro de Salida

```
salida=Data(5,:);
```

%-----Energía de activación-----

```
PCS_max=max(salida(1,:));
```

```
PCS_min=min(salida(1,:));
```

```
PCS_N=[(salida(1,1:end)-PCS_min)/(PCS_max-PCS_min)];
```

```
Salida_N=PCS_N;
```

ANEXO F: NORMALIZACIÓN DE LOS DATOS DE VALIDACIÓN

%Leer Tabla Desde la Hoja de Excel

```
Extraer=readtable('Datos.xlsx','Sheet','Data V');
```

%Convertir la tabla a Matriz Numérica

```
Datav = table2array(Extraer);
```

%Cargar parámetros de la red neuronal artificial

```
load('Net10L.mat');
```

%Normalización de Parámetros de Entrada

```
entradasv=Datav(1:4,:);
```

%-----HUMEDAD-----

```
H_Nv =[(entradasv(1,1:end)-H_min)/(H_max-H_min)];
```

%-----CENIZAS-----

```
C_Nv =[(entradasv(2,1:end)-C_min)/(C_max-C_min)];
```

%-----MATERIA VOLATIL-----

```
MV_Nv =[(entradasv(3,1:end)-MV_min)/(MV_max-MV_min)];
```

%-----CARBONO FIJO-----

```
CF_Nv =[(entradasv(4,1:end)-CF_min)/(CF_max-CF_min)];
```

%-----ENTRADAS NORMALIZADAS -----

```
Entradas_Nva1=[H_Nv;C_Nv;MV_Nv;CF_Nv];
```

ANEXO G: DESARROLLO Y ENTRENAMIENTO DE LA RED NEURONAL ARTIFICIAL

```
%-----RED NEURONAL-----  
% Solve an Input-Output Fitting problem with a Neural Network  
% Script generated by Neural Fitting app  
% Created 16-Dec-2020 16:53:11  
%  
% This script assumes these variables are defined:  
%  
% Entradas_N - input data.  
% Salida_N - target data.  
  
x = Entradas_N;  
t = Salida_N;  
  
% Choose a Training Function  
% For a list of all training functions type: help nntrain  
% 'trainlm' is usually fastest.  
% 'trainbr' takes longer but may be better for challenging problems.  
% 'trainscg' uses less memory. Suitable in low memory situations.  
trainFcn = 'trainlm'; % Levenberg-Marquardt backpropagation.  
  
% Create a Fitting Network  
hiddenLayerSize = 10;  
net = fitnet(hiddenLayerSize,trainFcn);  
  
% Setup Division of Data for Training, Validation, Testing  
net.divideParam.trainRatio = 70/100;  
net.divideParam.valRatio = 15/100;  
net.divideParam.testRatio = 15/100;  
  
% Train the Network  
[net,tr] = train(net,x,t);  
  
% Test the Network  
y = net(x);  
e = gsubtract(t,y);  
performance = perform(net,t,y)  
  
% View the Network
```

```
view(net)
```

```
%-----RESULTADOS-----
```

```
%Predicción del poder calorífico superior normalizado----- --
```

```
PCS_pred_N = net(Entradas_N(1:end,:))
```

```
%Energía de activación predicha-----
```

```
PCS_pred = [PCS_pred_N(1,:).*(PCS_max-PCS_min)+PCS_min];
```

```
%-----GRÁFICOS DEL PCS REAL vs PREDICHO-----
```

```
% Valores reales del PCS y valores predichos por la red neuronal
```

```
Real= salida;
```

```
Prediccion= PCS_pred';
```

```
%Flujo molar de Destilado
```

```
figure;
```

```
plot(Real(1,:))
```

```
hold on
```

```
plot(Prediccion(1,:));grid;legend('Real','Predicción')
```

```
xlabel('Cantidad de datos')
```

```
ylabel('Poder calorífico superior (MJ/Kg)')
```

```
title('Predicción del Poder Calorífico Superior')
```

ANEXO H: RESULTADOS PREDICHOS POR LA RED NEURONAL EN EL ENTRENAMIENTO

PCS	PCS
Real	Predicho
16,526	16,526
19,500	19,500
19,956	19,956
18,044	18,044
20,183	20,183
21,176	21,176
21,121	21,121
20,529	20,529
21,193	21,193
20,505	20,505
20,657	20,657
20,664	20,664
21,704	21,703
23,078	23,078
23,680	23,680
24,795	24,795
25,451	25,452
26,491	26,492
27,519	27,520
28,073	28,073
18,623	18,623
19,494	19,494
20,745	20,745
20,675	20,675
21,775	21,775
23,078	23,077
24,020	24,021
19,564	19,564
19,981	19,981
19,006	19,006
20,992	20,992
20,051	20,051
18,885	18,885
19,134	19,134
19,026	19,026
19,098	19,098
19,805	19,805
21,199	21,199
20,738	20,738
20,504	20,504
20,063	20,063
20,087	20,087
20,192	20,192
20,208	20,208
19,747	19,747

19,004	19,004
19,569	19,570
19,505	19,505
19,297	19,297
16,636	16,636
16,605	16,606
17,595	17,595
18,777	18,777
18,349	18,349
17,603	17,603
17,672	17,672
17,823	17,823
18,006	18,006
18,846	18,845
18,316	18,316
17,981	17,981
17,204	17,204
17,007	17,007
17,878	17,878
18,369	18,369
19,773	19,773
19,822	19,822
17,712	17,712
19,307	19,307
18,946	18,946
17,646	17,646
19,402	19,402
18,069	18,069
19,666	19,666
23,920	23,920
23,704	23,703
24,339	24,339
24,041	24,041
24,975	24,976
25,715	25,715
14,701	14,701
12,903	12,903
13,093	13,093
21,877	21,877
22,800	22,800
23,155	23,155
20,449	20,449
18,892	18,892
18,561	18,561
16,106	16,106

Realizado por: Martínez, Denisse, 2021

ANEXO I: VALIDACIÓN DE LA RED NEURONAL ARTIFICIAL

% Validación de la red neuronal artificial

```
PropPred_val = net(Entradas_Nval(1:end,:));
```

% ----- RESULTADOS -----

% Poder Calorífico Superior predicho-----

```
PCS_predval = [PropPred_val(1,:).*(PCS_max-PCS_min)+PCS_min];
```

% ----- GRÁFICOS -----

% Parámetros de salida

```
salidasv=DataV(5,:);
```

```
Valor_RealVal=salidasv'
```

% Valores reales en bibliografía y valores predichos por la red

```
Realval= Valor_RealVal';
```

```
Prediccionval= PCS_predval';
```

```
figure;
```

```
plot(Realval(1,:))
```

```
hold on
```

```
plot(Prediccionval(1,:));grid;legend('Real','Predicción')
```

```
xlabel('Cantidad de datos de validación')
```

```
ylabel('Poder calorífico superior (MJ/Kg)')
```

```
title('Predicción del Poder Calorífico Superior')
```

ANEXO J: RESULTADOS PREDICHOS POR LA RED NEURONAL EN LA VALIDACIÓN

PCS	PCS	Error %
Real	Predicho	
18,477	18,476411	0,00075
20,073	20,0730484	0,00230
17,700	17,6999663	0,00109
22,714	22,7144806	0,00109
19,048	19,0478086	0,00014
21,109	21,1090966	0,00104
18,534	18,5334308	0,00047
20,861	20,8612374	0,00025
19,416	19,4163604	0,00019
21,017	21,0163437	0,00102
Promedio		0,00083

Realizado por: Martínez, Denisse, 2021

ANEXO K: DESARROLLO DE LA INTERFAZ GRÁFICA DE USUARIO

```
% -----Interfaz Gráfica de Usuario (GUI)-----  
  
function varargout = Interfaz(varargin)  
    gui_Singleton = 1;  
    gui_State = struct('gui_Name',    mfilename, ...  
                      'gui_Singleton', gui_Singleton, ...  
                      'gui_OpeningFcn', @Interfaz_OpeningFcn, ...  
                      'gui_OutputFcn', @Interfaz_OutputFcn, ...  
                      'gui_LayoutFcn', [], ...  
                      'gui_Callback', []);  
  
    if nargin && ischar(varargin{1})  
        gui_State.gui_Callback = str2func(varargin{1});  
    end  
  
    if nargout  
        [varargout{1:nargout}] = gui_mainfcn(gui_State, varargin{:});  
    else  
        gui_mainfcn(gui_State, varargin{:});  
    end  
  
    % --- Executes just before Interfaz is made visible.  
  
    function Interfaz_OpeningFcn(hObject, eventdata, handles, varargin)  
  
        % Choose default command line output for Interfaz  
        handles.output = hObject;  
  
        % Update handles structure  
        guidata(hObject, handles);  
  
        % Outputs from this function are returned to the command line.  
        function varargout = Interfaz_OutputFcn(hObject, eventdata, handles)  
  
            % Get default command line output from handles structure  
            varargout{1} = handles.output;  
  
    function Humedad_Callback(hObject, eventdata, handles)  
  
        % hObject    handle to Humedad (see GCBO)  
        if str2double(get(hObject,'String')) <= 0
```

```

    msgbox('El valor deber ser mayora cero y menora 100 %','Nota')
end
if str2double(get(hObject,'String')) >= 100
    msgbox('El valor deber ser mayora cero y menora 100 %','Nota')
end

if str2double(get(hObject,'String')) > 0 && str2double(get(hObject,'String')) < 100
H_dato=str2double(get(hObject,'String'))
    assignin('base','Humedad_dato',H_dato)
end

% --- Executes during object creation, after setting all properties.
function Humedad_CreateFcn(hObject, eventdata, handles)

if ispc && isequal(get(hObject,'BackgroundColor'), get(0,'defaultUicontrolBackgroundColor'))
    set(hObject,'BackgroundColor','white');
end

function Cenizas_Callback(hObject, eventdata, handles)

if str2double(get(hObject,'String')) <= 0
    msgbox('El valor deber ser mayora cero y menora 100 %','Nota')
end
if str2double(get(hObject,'String')) >= 100
    msgbox('El valor deber ser mayora cero y menora 100 %','Nota')
end

if str2double(get(hObject,'String')) > 0 && str2double(get(hObject,'String')) < 100
C_dato=str2double(get(hObject,'String'))
    assignin('base','Cenizas_dato',C_dato)
end

% --- Executes during object creation, after setting all properties.
function Cenizas_CreateFcn(hObject, eventdata, handles)
% hObject    handle to Cenizas (see GCBO)
% eventdata reserved - to be defined in a future version of MATLAB
% handles    empty - handles not created until after all CreateFcns called

% Hint: edit controls usually have a white background on Windows.

```

```
% See ISPC and COMPUTER.
if ispc && isequal(get(hObject,'BackgroundColor'), get(0,'defaultUicontrolBackgroundColor'))
    set(hObject,'BackgroundColor','white');
end
```

```
function MateriaVolatil_Callback(hObject,eventdata,handles)
```

```
if str2double(get(hObject,'String')) <= 0
    msgbox('El valor deber ser mayora cero y menor a 100 %','Nota')
end
```

```
if str2double(get(hObject,'String')) >= 100
    msgbox('El valor deber ser mayora cero y menor a 100 %','Nota')
end
```

```
if str2double(get(hObject,'String')) > 0 && str2double(get(hObject,'String')) < 100
MV_dato=str2double(get(hObject,'String'))
    assignin('base','Materia Volatil_dato',MV_dato)
end
```

```
% --- Executes during object creation, after setting all properties.
```

```
function CarbonoFijo_CreateFcn(hObject,eventdata,handles)
```

```
if ispc && isequal(get(hObject,'BackgroundColor'), get(0,'defaultUicontrolBackgroundColor'))
    set(hObject,'BackgroundColor','white');
end
```

```
function CarbonoFijo_Callback(hObject,eventdata,handles)
```

```
if str2double(get(hObject,'String')) <= 0
    msgbox('El valor deber ser mayora cero y menor a 100 %','Nota')
end
```

```
if str2double(get(hObject,'String')) >= 100
    msgbox('El valor deber ser mayora cero y menor a 100 %','Nota')
end
```

```
if str2double(get(hObject,'String')) > 0 && str2double(get(hObject,'String')) < 100
CF_dato=str2double(get(hObject,'String'))
    assignin('base','CarbonoFijo_dato',CF_dato)
end
```

```

% --- Executes during object creation, after setting all properties.
function CarbonoFijo_CreateFcn(hObject,eventdata,handles)

if ispc && isequal(get(hObject,'BackgroundColor'), get(0,'defaultUicontrolBackgroundColor'))
    set(hObject,'BackgroundColor','white');
end

function PCS_Callback(hObject,eventdata,handles)

function PCS_CreateFcn(hObject,eventdata,handles)

if ispc && isequal(get(hObject,'BackgroundColor'), get(0,'defaultUicontrolBackgroundColor'))
    set(hObject,'BackgroundColor','white');
end

% --- Executes on button press in Calcular.
function Calcular_Callback(hObject,eventdata,handles)

H_dato=str2double(get(handles.Humedad,'String'));
C_dato=str2double(get(handles.Cenizas,'String'));
MV_dato=str2double(get(handles.Materia Volatil,'String'));
CF_dato=str2double(get(handles.CarbonoFijo,'String'));

%Normalizar Entradas
H_Norm =(H_dato-0.1)/(74.26-0.1);
C_Norm =(C_dato-1.82)/(46.31-1.82);
MV_Norm =(MV_dato-11.7)/(83.92-11.7);
CF_Norm =(CF_dato-8.1)/(88.3-8.1);

%Variable con las entradas normalizadas
EntRNA=[H_Norm;C_Norm;MV_Norm;CF_Norm];
assignin('base','Entradas_RNA',EntRNA)

%Cargar la red neuronal artificial entrenada
Variables_RNA=load('Net10L.mat');
assignin('base','Variables_RNA',Variables_RNA);
RNA = getfield (Variables_RNA, 'net');
assignin('base','RNA',RNA);

```

```

%cargar salidas aprendida%
PCSmax = getfield (Variables_RNA, 'PCS_max');
PCSmin = getfield (Variables_RNA, 'PCS_min');

%Calculos de la red neuronal artificial
Calculos_RNA = RNA(EntRNA);
assignin('base','Calculos_RNA',Calculos_RNA)

%Resultados de la red neuronal artificial
PCS_predicho = Calculos_RNA(1,:).*(PCSmax-PCSmin)+PCSmin
assignin('base','PCS_Predicho',PCS_predicho)

%Mostrar resultado en Interfaz
set(handles.PCS,'String',PCS_predicho);

% --- Executes on button press in Limpiar.
function Limpiar_Callback(hObject, eventdata, handles)
%Limpiar Entradas
set(handles.Humedad,'String','');
set(handles.Cenizas,'String','');
set(handles.Materia Volatil,'String','');
set(handles.CarbonoFijo,'String','');
%Limpiar Salida
set(handles.PCS,'String','');

```