



ESCUELA SUPERIOR POLITÉCNICA DE CHIMBORAZO

FACULTAD DE CIENCIAS

CARRERA DE INGENIERÍA QUÍMICA

“PREDICCIÓN DE LA ENERGÍA DE ACTIVACIÓN PARA LOS RESIDUOS DE LA EMPRESA “REAL FLOWERS” EMPLEANDO REDES NEURONALES ARTIFICIALES”

Trabajo de titulación

Tipo: Propuesta Tecnológica

Presentado para optar el grado académico de:

INGENIERO QUÍMICO

AUTOR: JOSÉ LUIS CAYAMBE GUAMÁN

DIRECTOR: Ing. DARÍO FERNANDO GUAMÁN LOZADA

Riobamba – Ecuador

2021

© 2021, Cayambe Guaman José Luis

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, Cayambe Guaman José Luis, 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, 09 de septiembre de 2021

Digitally signed by JOSE LUIS
CAYAMBE GUAMAN
Date: 2021.10.11 12:18:44 ECT
Reason: ESPOCH
Location: Riobamba -Ecuador

ESPOCH DTIC

Cayambe Guaman José Luis

0604130518

ESCUELA SUPERIOR POLITÉCNICA DE CHIMBORAZO

FACULTAD DE CIENCIAS

CARRERA DE INGENIERÍA QUÍMICA

El Tribunal del Trabajo de Titulación certifica que: El trabajo Titulación; Tipo: Propuesta Tecnológica. **“PREDICCIÓN DE LA ENERGÍA DE ACTIVACIÓN PARA LOS RESIDUOS DE LA EMPRESA “REAL FLOWERS” EMPLEANDO REDES NEURONALES ARTIFICIALES”**., 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. Adrián Alejandro Rodríguez Pinos PRESIDENTE DEL TRIBUNAL	 Firmado electrónicamente por: ADRIAN ALEJANDRO RODRIGUEZ PINOS	2021-09-09
Ing. Darío Fernando Guaman Lozada DIRECTOR DE TRABAJO DE TITULACIÓN	 Firmado electrónicamente por: DARIO FERNANDO GUAMAN LOZADA	2021-09-09
Ing. Linda Mariuxi Flores Fiallos MIEMBRO DEL TRIBUNAL	 Firmado electrónicamente por: LINDA MARIUXI FLORES FIALLOS	2021-09-09

DEDICATORIA

A mis padres Gonzalo y Magdalena por el apoyo y ayuda incondicional durante todo este tiempo, a mis hermanos Mayra, Janeth y Javier, a mi abuelita Manuela quien siempre me ha sabido cuidar y apoyar, a mi familia en general por estar siempre conmigo y ser el motivo para salir adelante.

José Luis

AGRADECIMIENTO

A Dios por cuidarme y darme la fuerza para continuar, a mi familia, amigos y seres queridos, por estar conmigo siempre y apoyarme en cada etapa de mi vida.

A Nicole por estar junto a mí por su ayuda y cariño incondicional.

A la Escuela Superior Politécnica de Chimborazo, a los docentes de la Escuela de Ingeniería Química quienes nos instruyeron de conocimientos y valores los cuales formaron una parte importante en nuestra formación.

Al Ing. Darío Fernando Guaman Lozada tutor de la tesis por la ayuda fundamental para la realización de este proyecto.

Al Ing. Linda Mariuxi Flores Fiallos por el asesoramiento como miembro de la tesis quien con su ayuda se logró llevar de mejor manera el proyecto.

A los Ing. Sebastián Aguiar, Ing. Brayan Rosario por la guía y el apoyo en cada etapa de este trabajo de titulación.

José Luis

TABLA DE CONTENIDO

ÍNDICE DE TABLAS.....	vi
ÍNDICE DE FIGURAS.....	vii
ÍNDICE DE ANEXOS.....	ix
ÍNDICE DE ABREVIATURAS.....	x
RESUMEN	xii
SUMMARY	xiii

CAPÍTULO I

1	INTRODUCCIÓN.....	1
1.1	Antecedentes	1
1.2	Planteamiento del problema	3
1.3	Objetivos	4
1.3.1	<i>Objetivo General</i>	4
1.3.2	<i>Objetivos Específicos</i>	4
1.4	Justificación del proyecto.....	5
1.5	Alcance	6

CAPÍTULO II

2	MARCO TEÓRICO REFERENCIAL.....	7
2.1	Estado del arte	7
2.2	Bases Teóricas.....	8
2.2.1	<i>Reacciones de pirólisis de biomasa</i>	8

2.2.2	<i>Reacciones secundarias</i>	9
2.2.3	<i>Análisis termogravimétrico (TGA)</i>	9
2.2.4	<i>Modelos cinéticos</i>	10
2.2.5	<i>Inteligencia Artificial</i>	11
2.2.6	<i>Redes neuronales</i>	11
2.2.6.1	<i>Tipos de neuronas Artificiales</i>	12

CAPÍTULO III

3	METODOLOGÍA	13
3.1	Localización del proyecto	14
3.2	Determinación de variables de estudio	15
3.2.1	<i>Operacionalización de variables</i>	15
3.2.1.1	<i>Selección de variables</i>	15
3.3	Análisis termogravimétrico (TGA)	16
3.3.1	<i>Caracterización de tallos de rosas</i>	17
3.3.2	<i>Secado natural</i>	17
3.3.3	<i>Secado forzado</i>	17
3.3.4	<i>Molienda</i>	17
3.3.5	<i>Tamizado</i>	17
3.3.6	<i>Análisis termogravimétrico</i>	17
3.4	Establecimiento de la base de datos	19
3.4.1	Análisis de modelos cinéticos para el cálculo de la energía de activación	19
3.4.1.1	<i>Rampa 5 °C/min</i>	19
3.4.1.2	<i>Rampa 15°C/min</i>	21
3.5	Diseño de la red neuronal artificial	24
3.5.1	<i>Entradas y salidas en la red neuronal artificial</i>	25
3.5.2	<i>Normalización de datos</i>	25
3.5.3	<i>Red neuronal artificial (net fitting)</i>	25
3.5.4	<i>Entrenamiento de la red neuronal artificial</i>	26
3.5.5	<i>Análisis Estadístico</i>	28

CAPÍTULO IV

4	GESTIÓN DEL PROYECTO	29
4.1	Cronograma	29
4.2	Presupuesto	30
4.3	Recursos materiales	30
4.3.1	<i>Recursos humanos</i>	30
4.3.2	<i>Recursos materiales</i>	30
4.4	Resultados	31
4.4.1	<i>Análisis termogravimétrico</i>	31
4.4.2	<i>Resultados de la regresión simple de los modelos cinéticos</i>	32
4.4.3	<i>Resultados de la energía de activación</i>	35
4.4.4	<i>Desarrollo de la red neuronal artificial</i>	36
4.4.4.1	<i>Normalización de datos</i>	36
4.4.4.2	<i>Diseño de la red neuronal</i>	37
4.4.5	<i>Análisis estadístico de la red neuronal</i>	39
4.4.5.1	<i>Análisis ANOVA</i>	39
	CONCLUSIONES	40
	RECOMENDACIONES	41
	BIBLIOGRAFÍA	
	ANEXOS	

ÍNDICE DE TABLAS

Tabla 1-2: Modelos cinéticos propuestos	10
Tabla 1-3: Características geográficas de la empresa “REAL FLOWERS”	14
Tabla 2-3: Modelos cinéticos isoconversionales	15
Tabla 3-3: Variables de estudio	15
Tabla 4-3: Determinación de modelo cinético para el cálculo de la energía de activación	20
Tabla 5-3: Determinación de modelo cinético para el cálculo de la energía de activación	22
Tabla 6-3: Variables de entrada y salida de la red neuronal artificial.....	25
Tabla 1-4: Cronograma de actividades.....	29
Tabla 2-4: Presupuesto del proyecto	30
Tabla 3-4: Recursos humanos del proyecto	30
Tabla 4-4: Materiales utilizados en el proyecto.....	30
Tabla 5-4: Condiciones para el análisis termogravimétrico	31
Tabla 6-4: Resultado de los modelos cinéticos.....	32
Tabla 7-4: ANOVA.....	39
Tabla 8-4: Medias con intervalos de confianza del 95.0%	¡Error! Marcador no definido.

ÍNDICE DE FIGURAS

Figura 1-2: Resultado de análisis termogravimétrico	10
Figura 2-2: Arquitectura de una red neuronal.....	12
Figura 1-3: Metodología de trabajo.....	13
Figura 2-3: Ubicación geográfica del cantón Bolívar.....	14
Figura 3-3: Metodología del análisis termogravimétrico.....	16
Figura 4-3: Análisis TGA rampa 5 °C/min.....	19
Figura 5-3: DTG rampa 5 °C/min.....	19
Figura 6-3: Análisis de regresión simple para los modelos cinéticos.....	21
Figura 7-3: Análisis TGA rampa 15 °C/min.....	21
Figura 8-3: DTG rampa 15 °C/min.....	22
Figura 9-3: Análisis de regresión simple para los modelos cinéticos.....	23
Figura 8-3: Metodología de diseño de la red neuronal artificial	24
Figura 9-3: Variables de red.....	26
Figura 10-3: Proceso de entrenamiento de la red	27
Figura 11-3: Visualización de código.....	28
Figura 1-4: TGA de la rampa 15°C/min	32
Figura 2-4: Resultados de la regresión simple para la rampa 5°C/min.....	33
Figura 3-4: Resultados de la regresión simple para la rampa de 15 °C/min	34
Figura 4-4: Energía de activación rampa 5 °C/min.....	35
Figura 5-4: Energía de activación rampa 15 °C/min.....	36
Figura 6-4: Arquitectura de la red con 200 neuronas	37
Figura 7-4: Curva de aprendizaje con 30 neuronas	37
Figura 8-4: Correlación de la red de 30 neuronas.....	38

Figura 9-4: Comparación de la energía de activación real y la predicha por la red 39

ÍNDICE DE ANEXOS

ANEXO A. ANÁLISIS TERMOGRAVIMÉTRICO

ANEXO B: TOOL BOX MATLAB DE LA RED NEURONAL

ÍNDICE DE ABREVIATURAS

X_{\max}	Valor máximo
X_{\min}	Valor mínimo
X_{Norm}	Valor normalizado
X	Valor que se desea normalizar
°C	Centígrados
BR	Regularización Bayesiana
DAEM	Modelo de energía de activación distribuida
Ea	Energía de activación
F	Razón en análisis ANOVA
FWO	Flynn-Wall-Ozawa
KAS	Kissinger-Akahira-Sunose
KJ/mol	Kilojulio por mol
Mg	Miligramos
MSE	Error cuadrático medio
P	Peso
RNA	Red neuronal artificial
S	Segundos
t	Tiempo
T	Temperatura
TGA	Análisis Termogravimétrico
X	Valor que se desea normalizar

β

Tasa de calentamiento (°C/min)

RESUMEN

El trabajo tiene como objetivo predecir el comportamiento termogravimétrico de la energía de activación de los residuos de tallo de rosa mediante redes neuronales artificiales. Los datos del análisis termogravimétrico se obtuvieron a dos rampas de calentamiento de 5°C/min y 15 °C/min en intervalos de temperatura de 25 a 900°C con flujo de nitrógeno de 20 ml/min. El cálculo de la energía de activación se realizó en función de los modelos cinéticos propuestos, donde el modelo de energía de activación distribuida tuvo un factor de correlación para la rampa 5 °C/min de 0.967012 y un R² de 93.5113 %, para la rampa 15 °C/min el modelo de energía de activación distribuida tuvo un coeficiente de 0.955083 y un R² de 91.2184 %. La red neuronal artificial fue diseñada con 3 neuronas de entrada la temperatura (K), tiempo(s) y peso (mg), datos del análisis termogravimétrico, en la capa oculta tiene 200 neuronas y una neurona de salida que es la energía de activación (KJ/mol), el algoritmo de entrenamiento fue el de regularización Bayesiana con un coeficiente de correlación de 1 y un error cuadrático medio de 2.73E⁻³. Los resultados fueron evaluados mediante análisis estadístico comparativo de dos muestras, energía de activación real y la predicha por la red, donde el valor-P es mayor a 0.05, no existiendo una diferencia estadísticamente significativa entre las medias de las 2 variables. Se recomienda utilizar el modelo de predicción en proyectos de aprovechamiento de residuos agrícolas para la generación de energía debido a la disminución de tiempos de análisis en laboratorio.

Palabras clave: <INGENIERÍA Y TECNOLOGÍA QUÍMICA>, <TALLO DE ROSA>, <ANÁLISIS TERMOGRAVIMÉTRICO>, <REDES NEURONALES ARTIFICIALES>, <MATLAB (SOFTWARE)>, <ENERGÍA DE ACTIVACIÓN>, <MODELOS CINÉTICOS>

**LUIS ALBERTO
CAMINOS
VARGAS**

Firmado digitalmente por LUIS
ALBERTO CAMINOS VARGAS
(DN):
c=EC, l=RIOBAMBA,
serialNumber=0602766974, cn=LUIS
ALBERTO CAMINOS VARGAS
Fecha: 2021.03.29 17:25:44 -05'00'



**0879-DBRAI-UTP-
2021**

Abstract

The objective of this study was to predict the thermogravimetric behaviour of the activation energy of rose stem residues using artificial neural networks. The data of the thermogravimetric analysis were obtained at two heating ramps of 5°C / min and 15°C / min in temperature ranges from 25 to 900°C with a nitrogen flow of 20 ml/min. The calculation of the activation energy was carried out based on the proposed kinetic models, where the distributed activation energy model had a correlation factor for the 5 °C / min ramp of 0.967012 and an R2 of 93.5113%, for the 15 °C / min ramp, the distributed activation energy model had a coefficient of 0.955083 and an R2 of 91.2184%. The artificial neural network was designed with 3 input neurons temperature (K), time (s) and weight (mg), the data from the thermogravimetric analysis, in the hidden layer it has 200 neurons and an output neuron that is the activation energy (KJ / mol), the training algorithm was the Bayesian regularization algorithm with a correlation coefficient of 1 and a mean square error of 2.73E-3. The results were evaluated through the comparative statistical analysis of two samples, real activation energy and that predicted by the network, where the P-value is greater than 0.05, and there was no statistically significant difference between the means of the two variables. It is recommended to use the prediction model in projects for the use of agricultural residues for the generation of energy due to the reduction of analysis times in the laboratory.

Keywords: <CHEMICAL ENGINEERING AND TECHNOLOGY>, <ROSE STEM>, <THERMOGRAVIMETRIC ANALYSIS>, <ARTIFICIAL NEURONAL NETWORKS>, <MATLAB (SOFTWARE)>, <ACTIVATION ENERGY>, <KINETIC MODELS>

CAPÍTULO I

1 INTRODUCCIÓN

1.1 Antecedentes

Los recursos agrícolas en los últimos años se han convertido en la fuente principal para la generación de energía sostenible. La pirólisis es una técnica adecuada para la conversión de biomasa para la producción de energía. Además, la pirólisis también interviene en otros procesos de conversión térmica de la biomasa, como la oxidación y la gasificación, como principal reacción de descomposición térmica. Sin embargo, la variación en los componentes principales de cada fuente de biomasa diferente juega un papel importante en las propiedades de la biomasa, incluida su pirólisis. (Chayaporn et al. 2014).

Ahora y en un futuro próximo, los productos de desecho de la agricultura y la silvicultura, fáciles y baratos de recolectar, dominarán como fuente de bioenergía. En la Unión Europea, los residuos de madera representan el 94% de la biomasa utilizada actualmente para energía. A medio y largo plazo, los residuos de la agricultura y la silvicultura cultivos se desarrollarán respectivamente, en la industria de la bioenergía. Los biocombustibles sólidos tienen una baja densidad energética, lo que limita las aplicaciones comerciales a ubicaciones cercanas al lugar de producción. Una forma de resolver este problema es la conversión de la materia prima en combustible líquido. Estos líquidos tienen una mayor densidad energética y son fáciles de almacenar y transportar (Sunphorka, Chalerm-sinsuwan & Piumsomboon 2017).

Ha existido un gran interés en la pirólisis, especialmente la pirólisis rápida de biomasa para maximizar la producción de gas. La pirólisis puede ser un proceso en sí mismo y también es el primer paso de cualquier proceso de gasificación. Varios estudios en este campo han analizado el efecto de los parámetros experimentales en la distribución del producto. Algunos autores han intentado predecir el comportamiento térmico y cinético de las biomásas a partir de su composición utilizando una ley de aditividad. Rajeswara Rao y Sharma propusieron un método en el que la reacción de pirólisis es modelada por una ecuación de n -ésimo orden, para componentes de la biomasa y también para los principales materiales de biomasa. Descubrieron que los datos experimentales sobre diferentes materiales de biomasa se pueden predecir

satisfactoriamente a partir del comportamiento de sus componentes y de sus composiciones asumiendo que no hay interacción entre ellos(Couhert, Commandre & Salvador 2009).

Otro de los trabajos que se ha venido desarrollando dentro del área de predicción y simulación de biomasa como fuente potencial de generación de energía renovable es el siguiente “Predicción y optimización de la producción de gas de síntesis a partir de un modelo de proceso de gasificación de biomasa basado en la cinética”, mismo que presenta un método robusto para la predicción y optimización de la producción de gas de síntesis aprovechando el modelo de proceso basado en la cinética establecido y las técnicas de análisis de datos para construir un modelo sustituto. En comparación con el modelo de equilibrio ampliamente utilizado, en este trabajo, se desarrolló un modelo de proceso de gasificación de biomasa incorporando cinéticas de reacción de biomasa actualizadas e hidrodinámica de lecho denso. Una comparación paralela de las predicciones del modelo y los resultados experimentales ilustra un buen acuerdo en una amplia gama de condiciones de funcionamiento(Dang et al. 2021).

El aprovechamiento de residuos agrícolas ha traído consigo trabajos investigativos como es el caso de Modelización de equilibrio empírico y químico para la predicción de productos de gasificación de biomasa en lechos fluidizados burbujeantes donde desarrollaron y compararon dos enfoques para predecir la composición del gas obtenido por gasificación directa de biomasa (aire) en lechos fluidizados burbujeantes, a saber, modelos empíricos basados en resultados experimentales reportados en la literatura y modelos de equilibrio químico no estequiométrico. Para este trabajo, se compiló una extensa base de datos que contiene un conjunto de 19 resultados experimentales publicados de la literatura y se desarrolló un modelo de equilibrio químico no estequiométrico(Pio & Tarelho 2020).

Por último, el trabajo “Procesamiento de datos de análisis termogravimétrico para análisis cinético isoconversional de pirólisis de biomasa lignocelulósica” estudio de caso de tallo de maíz. El modelado de procesos de pirólisis de biomasa lignocelulósica se puede utilizar para determinar sus parámetros clave de funcionamiento y diseño. Esto requiere una cantidad significativa de información sobre los parámetros cinéticos de pirólisis, en particular la energía de activación. El análisis termogravimétrico (TGA) es la herramienta más comúnmente utilizada para obtener datos cinéticos experimentales, y el análisis cinético isoconversional es la más eficaz de procesar datos TGA para calcular las energías de activación efectivas para la pirólisis de biomasa lignocelulósica. Este artículo revisa el procedimiento general de procesamiento de datos de TGA para el análisis cinético isoconversional de la pirólisis de biomasa lignocelulósica utilizando el método isoconversional de Friedman(Cai et al. 2018).

1.2 Planteamiento del problema

Uno de los principales problemas que enfrenta hoy en día el campo científico e industrial es la búsqueda de alternativas que suplanten a combustibles fósiles, en este contexto la carencia de estudios que fortalezcan a este ha hecho retardar su puesta en marcha, tal es el caso de Ecuador donde se genera una gran cantidad de residuos de origen agrícola debido a que su economía en gran parte depende del sector primario y de los productos que genera esta. Sin embargo, estos residuos no han sido aprovechados de manera correcta razón por la cual han venido causando problemas medioambientales, debido a que se convierten en un foco de infección para cultivos, contaminan aguas de riego, encarecen los costes de producción, sin dejar a un lado el impacto paisajístico que causa el mal manejo de residuos agrícolas.

El caso de los tallos de rosas en Ecuador representa un residuo de difícil degradación debido a su alto contenido de fibra, tal es el caso de la empresa “REAL FLOWERS” ubicada en el cantón Bolívar de la provincia del Carchi, no cuenta con propuestas de investigación ni desarrollo tecnológico que permita aprovechar de mejor manera los tallos generados de su producción.

Comúnmente el conocimiento de parámetros cinéticos como la energía de activación, ha tomado mucho tiempo en laboratorio y cálculos engorrosos para su análisis, razones que limitan el rápido conocimiento sobre las potencialidades energéticas de los residuos agrícolas en este caso de los tallos de rosas como una alternativa a los combustibles de origen fósil.

1.3 Objetivos

1.3.1 Objetivo General

Realizar un modelo de predicción del comportamiento termogravimétrico de la energía de activación de los residuos de tallos de rosas mediante el uso de redes neuronales artificiales para la empresa “REAL FLOWERS”.

1.3.2 Objetivos Específicos

- Obtener datos de la degradación térmica mediante pruebas termogravimétricas no isotérmicas de los residuos de tallos de rosas.
- Cuantificar la energía de activación de los residuos de tallos de rosas en base a modelos cinéticos propuestos.
- Diseñar la estructura de la red neuronal artificial que permita obtener resultados con la mayor precisión respecto a la energía de activación.
- Validar los resultados predichos por la red neuronal utilizando un análisis estadístico frente a los calculados de forma convencional.

1.4 Justificación del proyecto

La biomasa es un recurso que potencialmente puede reemplazar a los combustibles fósiles, ya que se puede utilizar en ciclos cortos. Tiene el potencial de contribuir a la energía del futuro y es adecuado para países agrícolas. La descomposición térmica, como la pirólisis, la combustión y la gasificación, es un proceso de conversión para la transformación de biomasa en biocombustible.

Por tal motivo el conocimiento de parámetros cinéticos como energía de activación, en base a modelos propuestos es una de las variables más importante dentro del proceso de valoración energética de la biomasa en este caso tallos de rosa, para ello el uso de redes neuronales para la predicción de estos valores resulta de vital importancia, ya que disminuyen tiempos de operación dentro de un laboratorio y cálculos consecutivos que resultan un problema al momento de conocer con inmediatez el potencial de los residuos de tallo de rosas.

La cinética de la descomposición de la biomasa es la clave para comprender el mecanismo y diseñar un proceso de conversión adecuado. El análisis termogravimétrico no isotérmico (TGA) es uno de los mejores métodos para el estudio de la cinética de la pirólisis. Es así que la propuesta tecnológica “Predicción de la energía de activación para los residuos de la empresa “REAL FLOWERS” empleando redes neuronales artificiales”, es una herramienta muy importante para la empresa como principal recurso para para el mejor aprovechamiento de los residuos que se generan dentro de esta.

1.5 Alcance

La red neuronal que se diseñará tendrá la capacidad de predecir la energía cinética como parámetro cinético principal para la valoración energética de los residuos de tallos de rosas generados en la empresa “REAL FLOWERS”.

CAPÍTULO II

2 MARCO TEÓRICO REFERENCIAL

2.1 Estado del arte

Dentro de los estudios revisados para el conocimiento de la metodología de trabajo ubicamos al siguiente “Caracterización y predicción de productos de pirólisis de biomasa” en este estudio se estructuraron y analizaron algunos datos de la literatura sobre las características de pirólisis de la biomasa en atmósfera inerte, lo que constituye una guía para el comportamiento de conversión de una partícula de combustible dentro del rango de temperatura de 200–1000 ° C. Los datos del estudio de Conesa & Domene (2011) tanto para la distribución del producto pirolítico (rendimientos de carbón, líquidos totales, agua, gas total y especies de gas individuales) como para las propiedades (composición elemental y poder calorífico) que muestran una clara dependencia de la temperatura máxima. Se presenta un modelo empírico para la estequiometría de pirólisis de biomasa, donde se introducen parámetros empíricos para cerrar las ecuaciones de conservación que describen el proceso. La comparación de los resultados del modelo con los datos de la literatura muestra que la información sobre las propiedades del producto está bien correlacionada con la información sobre la distribución del producto. La capacidad de predicción del modelo se aborda brevemente, y los resultados muestran que los rendimientos de volátiles liberados de una biomasa específica se predicen con una precisión razonable. Los modelos de partículas del tipo presentado en este estudio pueden ser útiles como submodelo en modelos de reactores completos que simulan procesos de pirólisis, gasificación o combustión (Neves et al. 2011).

Para el desarrollo del modelo predictivo se toma como referencia el trabajo de Estiati et al. (2016) artículo de investigación “Ajuste del rendimiento de redes neuronales artificiales y correlaciones empíricas para estimar valores caloríficos más altos de biomasa” Este estudio evalúa la viabilidad de utilizar redes neuronales artificiales (ANN) y correlaciones empíricas para ajustar y estimar el valor calorífico bruto de la biomasa a partir de bases de datos de análisis próximas disponibles en la literatura. Matlab facilita el desarrollo de ANN, ya que proporciona una programación sencilla y muchas funciones que se pueden utilizar directamente. A partir de una base de datos de 100

registros y luego aumentando la base de datos a 225 y luego a 350, fue posible analizar las diferencias entre las características básicas de ajuste de las ANN y los modelos de correlación. Se utilizaron doce valores de HHV de biomasa disponibles en la literatura para verificar la validez de los ajustes. A partir de una base de datos de 100 registros y luego aumentando la base de datos a 225 y luego a 350, fue posible analizar las diferencias entre las características básicas de ajuste de las ANN y los modelos de correlación. Se utilizaron doce valores de HHV de biomasa disponibles en la literatura para verificar la validez de los ajustes.

Finalmente, el trabajo Sunphorka, Chalermssinsuwan & Piumsomboon (2017) “Modelo de red neuronal artificial para la predicción de parámetros cinéticos de pirólisis de biomasa a partir de sus constituyentes” aplicó redes neuronales artificiales (ANN) para construir la correlación entre biomasa constituyentes y los parámetros cinéticos (energía de activación, factor pre-exponencial k y orden de reacción) de pirólisis de biomasa. el conjunto de datos experimentales que se utilizaron para desarrollar y probar las ANN fueron seleccionados de una amplia gama de diferentes tipos de biomasa. Se desarrollaron tres modelos ANN, uno para cada uno de los tres modelos cinéticos parámetros. Se utilizó un total de 150 análisis termogravimétricos experimentales de una amplia gama de composiciones de biomasa para desarrollar y probar las redes. Las relaciones entre los principales componentes de la biomasa y los parámetros de salida no eran lineales y podrían predecirse potencialmente mediante los modelos ANN seleccionados ($R^2 > 0,9$). Utilizando un límite de error estándar medio de 0,001, se optimizaron el número de neuronas en la capa oculta y de salida y los pesos y sesgos de los parámetros del modelo, con 20, 17 y 30 neuronas

En base a los trabajos revisados anteriormente se define la metodología de trabajo para el trabajo de integración curricular mismo que enfoca directamente a la predicción de la energía de activación como parámetro principal de la cinética de la degradación térmica de los tallos de rosas

2.2 Bases Teóricas

2.2.1 Reacciones de pirólisis de biomasa

La biomasa consta principalmente de tres componentes: 30 a 60% de celulosa, 20 a 35% de hemicelulosa (polisacáridos) y 15 a 30% de lignina (un polímero de compuestos orgánicos cíclicos sustituidos con metoxi), junto con algunas resinas y minerales. La pirólisis de la biomasa es muy compleja debido a la diversidad, heterogeneidad y estabilidad térmica limitada de algunos de los componentes. La pirólisis de biomasa produce aproximadamente los productos esperados de la pirólisis de sus tres componentes constituyentes por separado, a pesar de los efectos

sinérgicos. El estudio de los componentes individuales forma así la base de las vías de reacción esperadas y determina las reacciones primarias y secundarias que se producen. El orden de estas reacciones, la velocidad de reacción y los rendimientos dependen de parámetros como la velocidad de calentamiento, la temperatura, el pretratamiento, los efectos catalíticos, etc. El estudio de las reacciones y el efecto de los parámetros son de vital importancia para impulsar las reacciones a altos rendimientos de los productos deseados y evitar reacciones secundarias (Van de Velden et al. 2010).

2.2.2 Reacciones secundarias

Las reacciones secundarias pueden ocurrir en la fase de vapor o entre la fase de vapor y la sólida para formar principalmente gas. Esto reducirá considerablemente el rendimiento de aceite deseado. Dos reacciones secundarias son importantes para la pirólisis: el agrietamiento (> 973 K) y el desplazamiento agua-gas. reacción (< 1083 K): $\text{H}_2\text{O} + \text{CO} \rightarrow \text{H}_2 + \text{CO}_2$ Sin embargo, estas reacciones secundarias están limitadas a temperaturas por debajo de 923 K, residencia veces < 2 s para los gases y vapores y cuando el carbón se quema rápidamente (Van de Velden et al. 2010).

2.2.3 Análisis termogravimétrico (TGA)

El análisis termogravimétrico no isotérmico (TGA) se considera la más eficaz y sencilla para estudiar el comportamiento de descomposición térmica de la combustión de biomasa y de otras materias primas que sean caso de estudio. Así, las variables de descomposición térmica y las condiciones operativas óptimas de la biomasa se pueden determinar bajo un rango de tasas de calentamiento, la pérdida de masa, la tasa de descomposición y el flujo de calor de las muestras de biomasa se pueden monitorear en tiempo real utilizando un analizador térmico para obtener termogravimétrico (TG), termogravimétrico derivado (DTG), durante el proceso de degradación térmica (Huang et al. 2018).

Las balanzas termogravimétricas (TG) avanzadas pueden procesar docenas de muestras en secuencia, mientras recopilan y analizan automáticamente los datos de rendimiento y composición de gas resueltos en el tiempo sin la intervención del operador. Debido a esto, TGA se usa ampliamente para la caracterización de biomasa y el estudio de la pirólisis de biomasa. En particular, la TGA se utiliza a menudo para comparar las propiedades de diferentes materias primas de biomasa para la conversión termoquímica, para rastrear la evolución del estado sólido a través de los procesos de conversión termoquímica, y medir la cinética aparente de las reacciones de conversión termoquímica. A pesar de las atractivas características de las balanzas TG, su configuración daña su precisión y fidelidad. Este trabajo demuestra los efectos de esta

configuración en los resultados de análisis típicos de termogravimetría de biomasa, incluidos los rendimientos de carbón, las predicciones cinéticas y las composiciones próximas(Barr et al. 2020).




Figura 1-2: Resultado de análisis termogravimétrico

Fuente: Cayambe, Jose.2021

2.2.4 Modelos cinéticos

Los métodos isoconversionales (también conocidos como métodos sin modelo) se utilizan ampliamente para estudios cinéticos de residuos sólidos. Diferentes supuestos y aproximaciones están involucrados en diferentes métodos. Estos métodos ayudan a evitar los errores causados por las diferentes etapas en las que se desarrolla la reacción de descomposición de biomasa.

Se han desarrollados múltiples modelos cinéticos, como el modelo de reacción global de un solo paso, de múltiples pasos, semi-global y el modelo de energía de activación distribuida (DAEM) el que se considera un enfoque más preciso y versátil para modelar el proceso(Chen et al. 2016)

Tabla 1-2: Modelos cinéticos propuestos

Método	Ecuación	Características
Arrhenius	$k = k_0 e^{-\frac{E_a}{RT}}$	La linealidad de la gráfica de Arrhenius en sistemas alimentarios se debe a una propiedad matemática de la ecuación del modelo(Ahmad et al. 2017).
Flynn-Wall-Ozawa (FWO)	$\ln\left(\frac{g(\alpha)}{1-g(\alpha)}\right) = \ln\left(\frac{k_0}{R}\right) - \frac{E_a}{RT} - \ln\left(\frac{1-g(\alpha)}{g(\alpha)}\right)$	Este modelo se aplica a residuos de procesos biológicos para el cálculo del potencial bioenergético.
Kissinger-Akahira-Sunose(KAS)	$\ln\left(\frac{g(\alpha)}{1-g(\alpha)}\right) = \ln\left(\frac{k_0}{R}\right) - \frac{E_a}{RT} - \ln\left(\frac{1-g(\alpha)}{g(\alpha)}\right) - \frac{2E_a}{RT} \ln\left(\frac{1-g(\alpha)}{g(\alpha)}\right)$	Los datos cinéticos se producen en función de la velocidad de

		reacción de primer orden. (Chee, A. & Lai Fui, B., 2016)
Friedman	$\frac{dC}{dt} = -k_1 C + k_2 C_0$	Se emplea en compuesto no orgánicos procedentes de otro tipo de materiales(Castro, Galv & Silva 2020)
DAEM	$\ln\left(\frac{C}{C_0}\right) = -k_1 t + \frac{k_2}{k_1} C_0$	La propia metodología DAEM no toma en cuenta la incertidumbre asociada a la validez de las hipótesis impuestas por el modelo(Soria-Verdugo, Goos & García-Hernando 2015).

Fuente: (Huang et al. 2018)

Realizado por: Cayambe, Jose. 2021

2.2.5 Inteligencia Artificial

El interés de los académicos en la idea de que el aprendizaje artificial y automático puede reemplazar a los humanos, para asumir roles en el lugar de trabajo y remodelar el proceso organizacional existente ha ido creciendo constantemente(Haefner et al. 2020).

La Inteligencia Artificial (IA) es un área del conocimiento compuesta por un conjunto de técnicas que se basan en imitar computacionalmente las distintas habilidades relacionadas con la inteligencia del ser humano, como, por ejemplo: reconocimiento de patrones, diagnóstico, clasificación, entre otros. (Januch 2012)

Los modelos más simples comenzaron como funciones de entrada-salida simples y anticipadas. Sin embargo, durante las siguientes décadas, estos se volvieron más sofisticados con la adición de funciones, capas adicionales y retroalimentación bidireccional, convirtiéndose eventualmente en los bloques de construcción de las redes neuronales profundas de hoy en día(Muthukrishnan et al. 2020).

2.2.6 Redes neuronales

Las redes neuronales se diseñaron inicialmente para simular neuronas en el cerebro humano, compuesto por neuronas o nodos artificiales. Un nodo tiene una función de activación, que define la salida de ese nodo en función de una entrada o un conjunto de entradas. Aunque en sus formas más tempranas tenían funciones de entrada-salida simples y anticipadas, con el tiempo se

volvieron más sofisticadas y eventualmente se convirtieron en los componentes básicos de las redes neuronales profundas de la actualidad (Muthukrishnan et al. 2020).




Figura 2-2: Arquitectura de una red neuronal

Fuente: (Muthukrishnan et al. 2020)

Una red neuronal consta de dos fases, una fase de entrenamiento y una fase de predicción. En la fase de entrenamiento, los parámetros variables w_{ij} de la red se cambian para que la ANN se ajuste mejor a la base de datos de entrenamiento. En la mayoría de los casos las funciones intrínsecas, que representan cómo la salida de una neurona contribuye a la activación de un nodo posterior, por ejemplo. El indicador de cambio. J representa un índice de rendimiento formulado J que corresponde a la distancia euclidiana entre el objetivo deseado y los resultados calculados que se integran en todos los conjuntos de datos de entrenamiento. Por tanto, un paso básico del aprendizaje corresponde a la minimización del valor absoluto J (Delgado et al. 2016).

2.2.6.1 Tipos de neuronas Artificiales

Se distinguen en dos tipos principales:

- Neuronas binarias
- Neuronas reales

Las neuronas binarias solamente pueden tomar valores dentro del intervalo $(0, 1)$ o $(-1, 1)$, mientras tanto que las neuronas reales pueden hacerlo dentro del rango $[0, 1]$ o $[-1, 1]$. Los pesos normalmente no están restringidos a un cierto intervalo, aunque para aplicaciones específicas puede ser esto necesario (Matich 2001).

CAPÍTULO III

3 METODOLOGÍA

El propósito fundamental del trabajo de integración curricular es la predicción de la energía de activación como parámetro importante dentro del estudio de la cinética de combustión o degradación de una biomasa en este caso tallo de rosa, en función de la pérdida de masa en intervalos de tiempo y temperatura que previamente fueron programados.

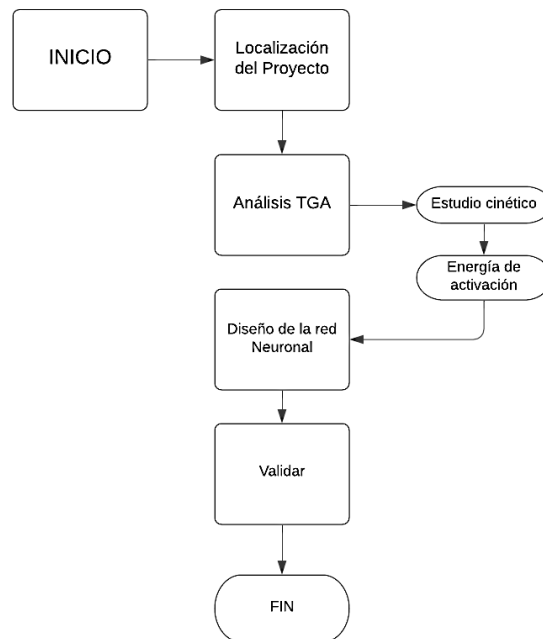


Figura 1-3: Metodología de trabajo

Realizado por: Cayambe, José, 2021.

El trabajo es de tipo experimental debido a que se fundamenta en el análisis termogravimétrico como variable principal para el desarrollo de una base de datos en función de modelos cinéticos propuestos, estudio que se lleva a cabo a dos rampas de calentamiento distintas de 5°C/min y 15°C/min en intervalos de temperatura de 25 a 900 °C con una corriente o flujo de nitrógeno de 20 ml/min en atmósfera inerte, es importante señalar que por evaluación estadística se ha de seleccionar el mejor modelo en función de su coeficiente de correlación para la obtención de la energía de activación en cada uno de los puntos que componen la recta.

3.1 Localización del proyecto

El Trabajo de Integración Curricular será implementado en la empresa “REAL FLOWERS” del cantón Bolívar de la provincia del Carchi cuyas características geográficas se muestran en la siguiente

¡Error! No se encuentra el origen de la referencia.

Tabla 1-3: Características geográficas de la empresa “REAL FLOWERS”

UBICACIÓN	Cantón: Bolívar.
LATITUD	1500 -4500 msnm
LONGITUD	36.034 Ha

Fuente: (PDYOT 2015)

Realizado por: Cayambe, José, 2021




Figura 2-3: Ubicación geográfica del cantón Bolívar

Fuente: Adaptado de Google Earth (2021)

3.2 Determinación de variables de estudio

La energía de activación es un parámetro muy importante al momento de estudiar la cinética de pirolisis de cualquier material en nuestro caso biomasa (tallo de rosas) en función de modelos propuestos isoconversionales como se indica en la **¡Error! No se encuentra el origen de la referencia.**

Tabla 2-3: Modelos cinéticos isoconversionales

Método	Ecuación
Flynn-Wall-Ozawa (FWO)	$\ln\left(\frac{g(x)}{g(0)}\right) = \frac{E_a}{R} \left(\frac{1}{T_0} - \frac{1}{T} \right) - 5331 - 1052 \frac{g(x)}{T^2}$
Kissinger-Akahira-Sunose(KAS)	$\frac{g(x)}{T^2} = \frac{E_a}{R} \left(\frac{1}{T_0} - \frac{1}{T} \right) \left(1 - \frac{g(x)}{g(0)} \right) - \frac{5331 - 1052 \frac{g(x)}{T^2}}{T^2}$
Friedman	$\frac{g(x)}{T^2} = \frac{E_a}{R} \left[\frac{1}{T_0} - \frac{1}{T} \right] - \frac{5331 - 1052 \frac{g(x)}{T^2}}{T^2}$
DAEM	$\ln\left(\frac{g(x)}{g(0)}\right) = \ln\left(\frac{1}{T} - \frac{1}{T_0}\right) + 06575 - \frac{E_a}{R} \left(\frac{1}{T} - \frac{1}{T_0} \right) - \frac{5331 - 1052 \frac{g(x)}{T^2}}{T^2}$

Fuente: (Huang et al. 2018)

3.2.1 Operacionalización de variables

3.2.1.1 Selección de variables

Tabla 3-3: Variables de estudio

Variable independiente	Variable dependiente
Tiempo (s)	Energía de activación (KJ/mol)
Temperatura (°C)	
Peso (mg)	
Rampa de calentamiento (°C/min)	

Realizado por: Cayambe, José, 2021

En función de cada una de las variables expuestas en la **¡Error! No se encuentra el origen de la referencia.** se evalúan mediante modelos cinéticos isoconversionales propuestos para la obtención de la energía de activación como variable de estudio del trabajo de integración curricular.

3.3 Análisis termogravimétrico (TGA)

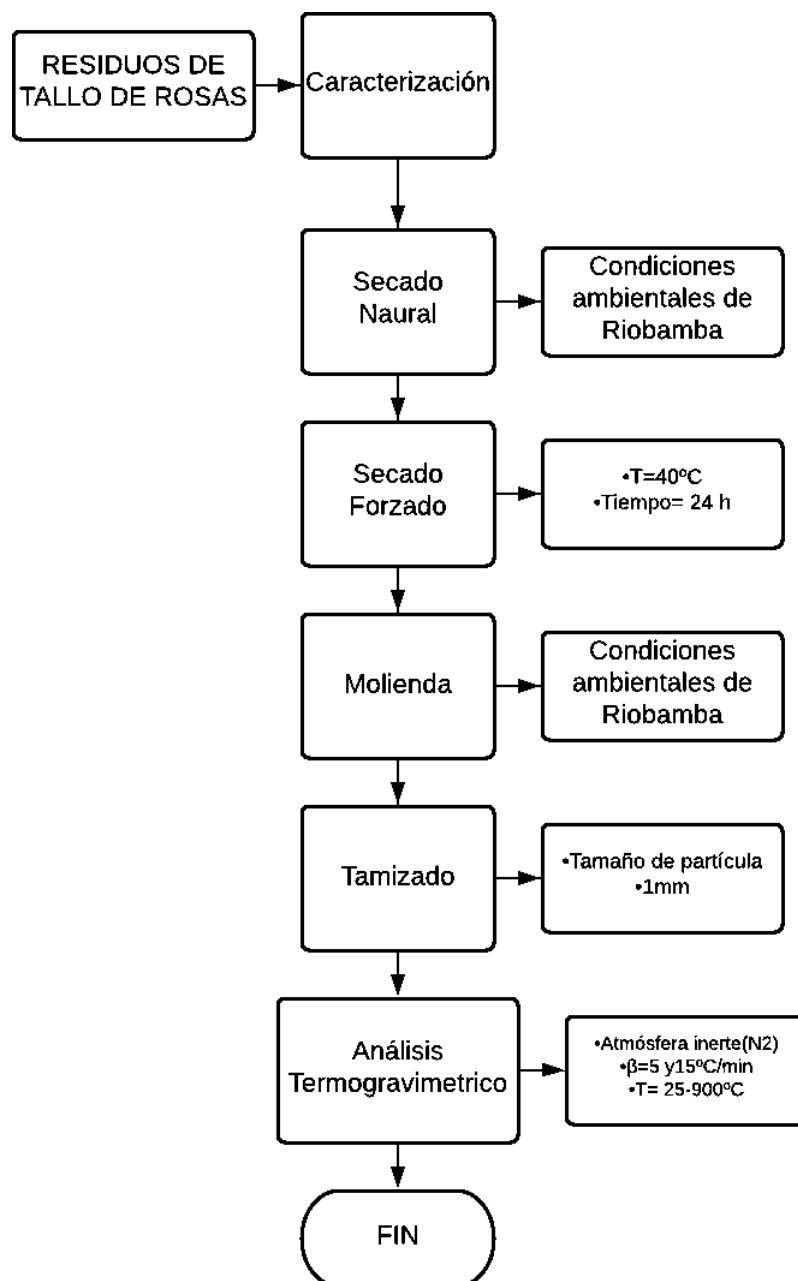


Figura 3-3: Metodología del análisis termogravimétrico

Realizado por: Cayambe, José, 2021

El análisis de la biomasa es la base para comprender la química de conversión y desarrollar nuevos procesos de biocombustibles. Proporciona la base para determinar el rendimiento del proceso en términos de eficiencia de conversión de carbono y eficiencia energética y facilita la optimización del proceso para maximizar el rendimiento del producto.

3.3.1 Caracterización de tallos de rosas

Se evaluó que la materia prima en este caso tallo de rosas que se encuentre en condiciones óptimas es decir que no contiene materiales distintos a este como residuos plásticos u otro material ajeno a su estructura.

3.3.2 Secado natural

Proceso que aprovechando las condiciones ambientales que faciliten la deshidratación de los tallos de rosas y obtener niveles de humedad que posibiliten el manejo de los mismos para el análisis termogravimétrico.

3.3.3 Secado forzado

Este procedimiento se lo llevo a cabo en el laboratorio de operaciones unitarias de la facultad de ciencias de la Escuela Superior Politécnica de Chimborazo en un secador de bandeja de temperatura controlada a 40 °C y un tiempo de 24 horas es importante verificar que la muestra se encuentra a un valor de humedad menor al 30% antes de ingresar a este proceso para evitar la formación de un material pastoso al momento de pasar por el tamiz.

3.3.4 Molienda

Proceso mecánico que permite disminuir el tamaño de partícula de una muestra en particular en este caso tallo de rosa, este procedimiento se lo llevo a cabo en el laboratorio de procesos industriales de la Escuela Superior Politécnica de Chimborazo.

3.3.5 Tamizado

Procedimiento que se lo realiza con el propósito de retener partículas con un tamaño no requerido, este se lo lleva a cabo en una torre de tamices del laboratorio de procesos industriales de la Escuela Superior Politécnica de Chimborazo

3.3.6 Análisis termogravimétrico

- El análisis termogravimétrico se realizó en el equipo TGA 1 STAR System en el Laboratorio de Catálisis de la Facultad de Ingeniería Química de la Universidad Central del Ecuador.

- Revisar que la presión total de los tanques de gas, nitrógeno y aire sintético no sea menor a 500 psi, esto para evitar la entrada de impurezas al equipo.
- La presión de entrada al equipo debe estar entre 2-3 psi, debido a que la presión máxima que puede soportar la Termobalanza es de 10 psi.
- Poner en funcionamiento el Minichiller.
- Encender la Termobalanza.
- Abrir el programa: STARe Software.
- Programar el proceso térmico, ya sea un proceso dinámico, un proceso isotérmico o una combinación de los dos anteriores.
- La velocidad de calentamiento puede ir desde 1 hasta 30 °C/min. Este trabajo se realizó utilizando velocidades de 10, 15 y 20°C/min.
- Seleccionar el tipo y flujo de gas a utilizar, para la presente investigación se trabajó con un flujo de 20 mL/min de nitrógeno y aire sintético.
- Abrir el horno de la termobalanza, colocar un crisol vacío, cerrar el horno y encender.
- Retirar el crisol, colocar la muestra dentro del crisol e introducirlos nuevamente en el horno del equipo.
- En el programa STARe Software presionar: Send Experiment y luego OK
- Terminado el ensayo el equipo automáticamente regresa a las condiciones iniciales.
- Observar en la ventana del programa STARe Software la evaluación de la curva y exportar los resultados.
- Para los residuos de tallo de rosa se lo llevo a cabo en las siguientes condiciones de temperatura en intervalos de 25 a 900 °C con distintas rampas de calentamiento de 5 y 15 °C/min

3.4 Establecimiento de la base de datos

3.4.1 Análisis de modelos cinéticos para el cálculo de la energía de activación

3.4.1.1 Rampa 5 °C/min

El análisis termogravimétrico es una pieza clave para el desarrollo del modelado cinético por ello se establece una metodología para el establecimiento de datos de estudio del termograma



Figura 4-3: Análisis TGA rampa 5 °C/min

Realizado por: Cayambe, José, 2021

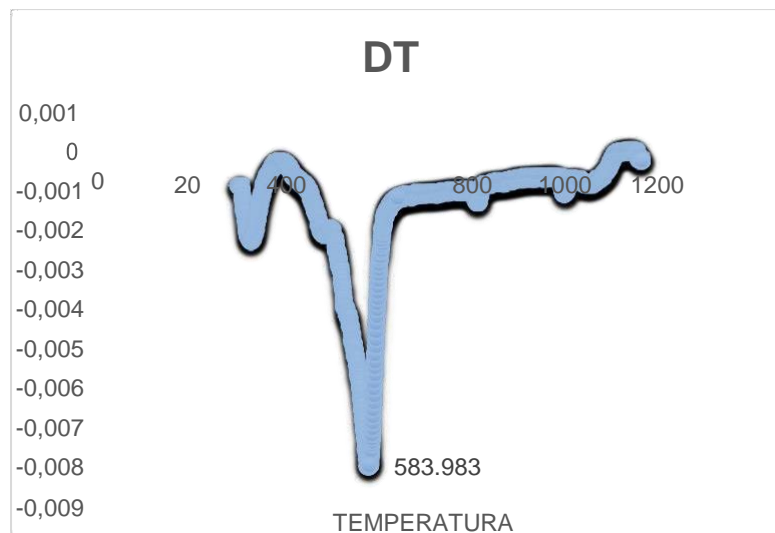


Figura 5-3: DTG rampa 5 °C/min

Realizado por: Cayambe, José, 2021

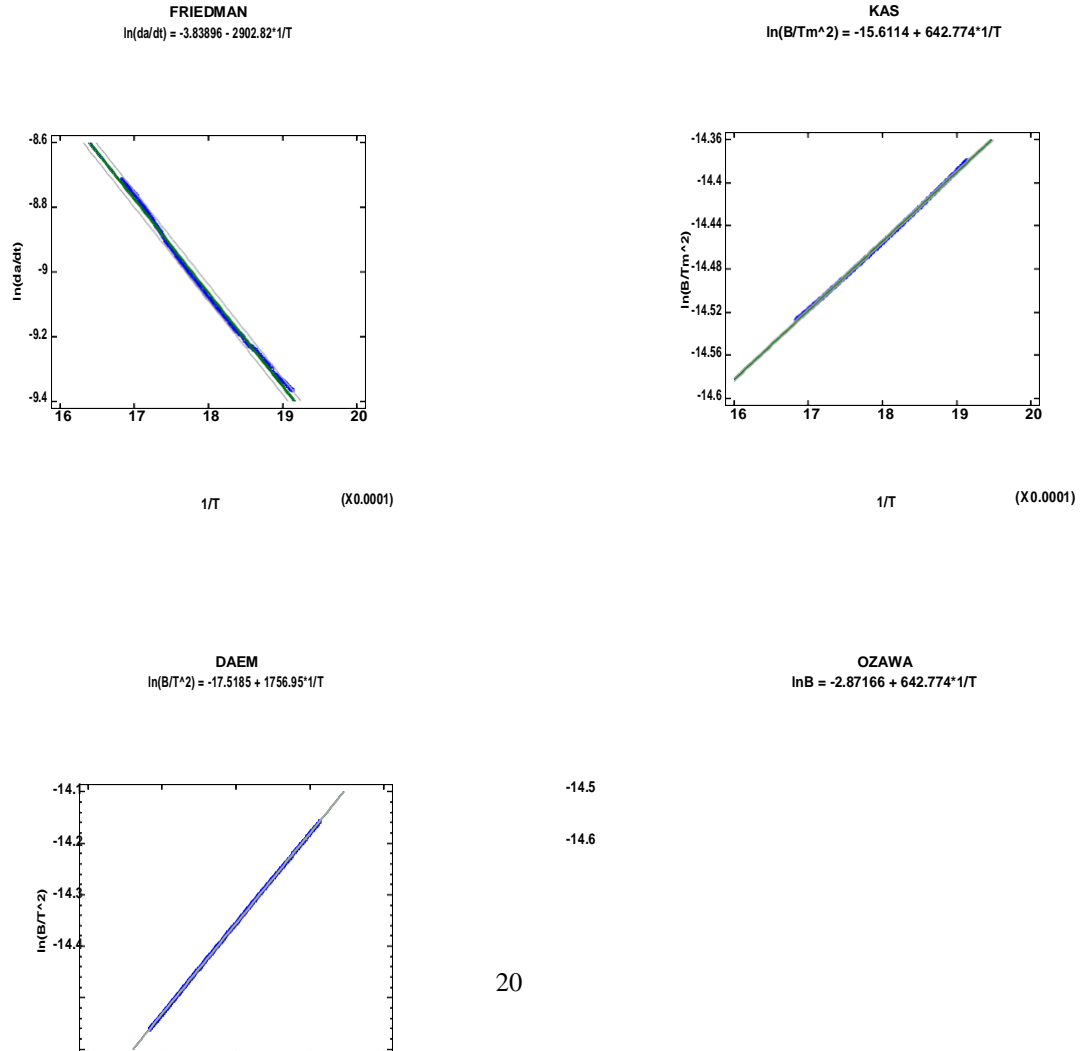
La Figura 4-3 permitió visualizar la etapa donde se aplicará los modelos cinéticos, es importante el desarrollo de esta porque disminuye el factor de correlación, mientras que la Figura 5-3 permitió determinar la temperatura máxima del proceso de la degradación de la biomasa.

La Figura 4-3 indica los parámetros obtenidos de la regresión simple de los modelos cinéticos utilizados para el tratamiento de los resultados termogravimétrico.

Tabla 4-3: Determinación de modelo cinético para el cálculo de la energía de activación

Método	Modelo cinético	Coefficiente de correlación	R ² (%)	R ² ajustada (%)
Flynn-Wall-Ozawa (FWO)	$\ln\left(\frac{g}{1-g}\right) = \ln\left(\frac{A}{B}\right) - \frac{5331 - 1052}{T}$	0.999816	99.9631	99.9628
Kissinger-Akahira-Sunose(KAS)	$\ln\left(\frac{g}{1-g}\right) = \ln\left(\frac{A}{B}\right) - \frac{2000}{T} \left(1 - \frac{1}{T}\right) - \frac{1}{T}$	0.999816	99.9631	99.9628
Friedman	$\ln\left(\frac{dg}{dt}\right) = \ln\left(\frac{A}{B}\right) - \frac{5331 - 1052}{T}$	0.997957	99.5919	99.5885
DAEM	$\ln\left(\frac{g}{1-g}\right) = \ln\left(\frac{A}{B}\right) + 0.6575 - \frac{1}{T}$	0.999994	99.9988	99.9987

Realizado por: Cayambe, José, 2021



16 17 18
16 20
-1.64

-1.68

-1.72

-1.76

-1.8

inc




Figura 6-3: Análisis de regresión simple para los modelos cinéticos.

Realizado por: Cayambe, José, 2021

De estos modelos se escoge el de mayor factor de correlación es decir el que más se acerca a 1, el que cumple con esta condición es el método de DAEM a. A partir de este modelo cinético se calculó la energía de activación para cada punto que compone la recta pendiente del modelo de DAEM ya que este se relaciona con la ecuación $y=ax+b$ donde x es la pendiente y corresponde a la energía de activación,

3.4.1.2 *Rampa 15°C/min*

El análisis de la rampa 15 °C/min se lo lleva a cabo con los modelos cinéticos propuestos para la anterior rampa, evaluando la energía de activación en función de los parámetros termogravimétricos como son temperatura (K), peso (mg), tiempo(s).

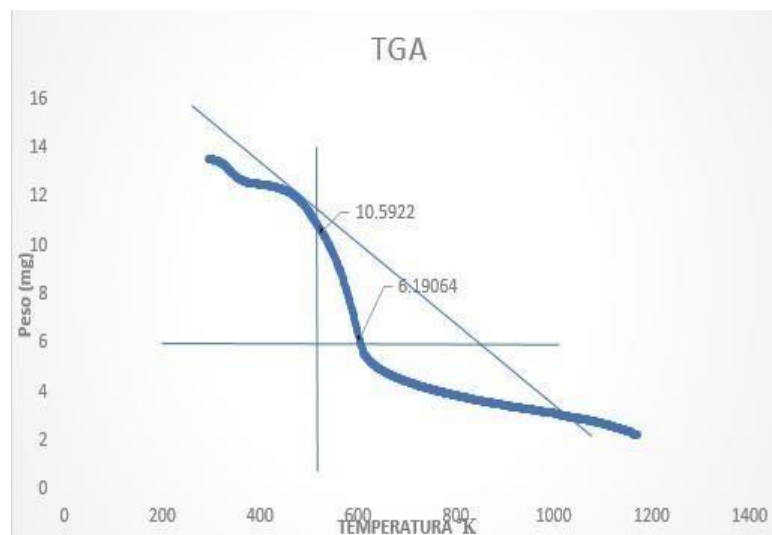


Figura 7-3: Análisis TGA rampa 15 °C/min

Realizado por: Cayambe, José, 2021

La Figura 7-3 nos permitió visualizar los datos exactos para el planteamiento de los modelos cinéticos, el desarrollo de esta figura a partir de los resultados del análisis termogravimétrico permite disminuir el error en la regresión simple

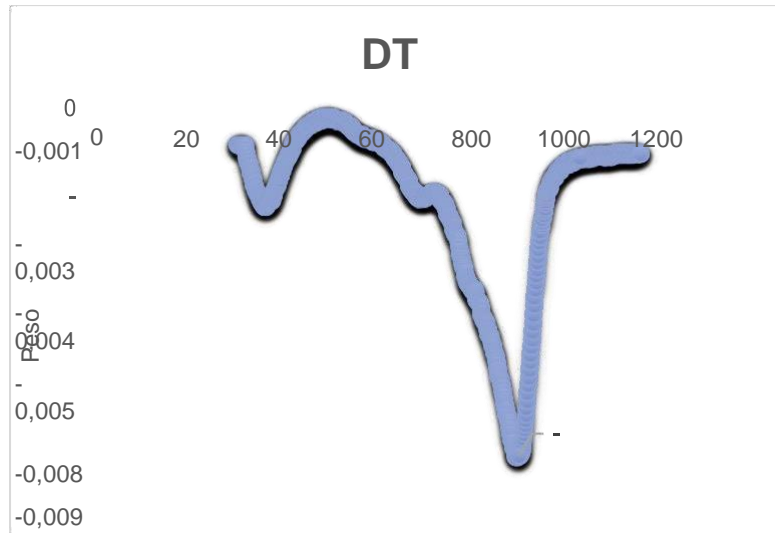


Figura 8-3: DTG rampa 15 °C/min

Realizado por: Cayambe, José, 2021

La Figura 8-3 permitió conocer la temperatura máxima del proceso de la degradación de la biomasa

La Tabla 5-3 muestra los diferentes modelos cinéticos con sus respectivos factores estadísticos que determinaron que modelo será el adecuado para el cálculo de la energía de activación. De esta manera se escogió el modelo cinético de DAEM para el cálculo de la energía de activación.

Para mejorar la predicción de la red neuronal y encontrar la energía de activación que más se ajuste al tipo de muestra utilizamos los valores del TGA y DTGA, con la finalidad de determinar en qué punto de la degradación térmica los valores se ajustan más al modelo cinético de DAEM, esto se realiza para cada uno de los resultados de los análisis termogravimétricos.

Tabla 5-3: Determinación de modelo cinético para el cálculo de la energía de activación

Método	Modelo cinético	Coficiente de correlación	R ² (%)	R ² ajustada (%)
Flynn-Wall-Ozawa (FWO)	$\ln(-\ln(1 - \frac{w}{w_0})) = \frac{E_a}{R} \left(\frac{1}{T} - \frac{1}{T_0} \right) - 5331 - 1052 \ln\left(\frac{w_0}{w}\right)$	0.999787	99.9573	99.9566
Kissinger-Akahira-Sunose (KAS)	$\frac{d \ln(-\ln(1 - \frac{w}{w_0}))}{dT} = \frac{E_a}{R} \left(\frac{1}{T^2} - \frac{1}{T_0^2} \right) - \frac{2}{T_0} \ln\left(\frac{w_0}{w}\right) - \frac{1}{T_0}$	0.999787	99.9573	99.9566
Friedman	$\frac{d \ln(-\ln(1 - \frac{w}{w_0}))}{dT} = \frac{E_a}{R} \left[\frac{1}{T^2} - \frac{1}{T_0^2} \right] - \frac{1}{T_0}$	0.996575	99.3163	99.3052
DAEM	$\ln\left(\frac{w_0}{w}\right) = \frac{E_a}{R} \left(\frac{1}{T} - \frac{1}{T_0} \right) + 0.6575 - \frac{1}{T_0}$	0.999991	99.9982	99.9981

Realizado por: Cayambe, José, 2021

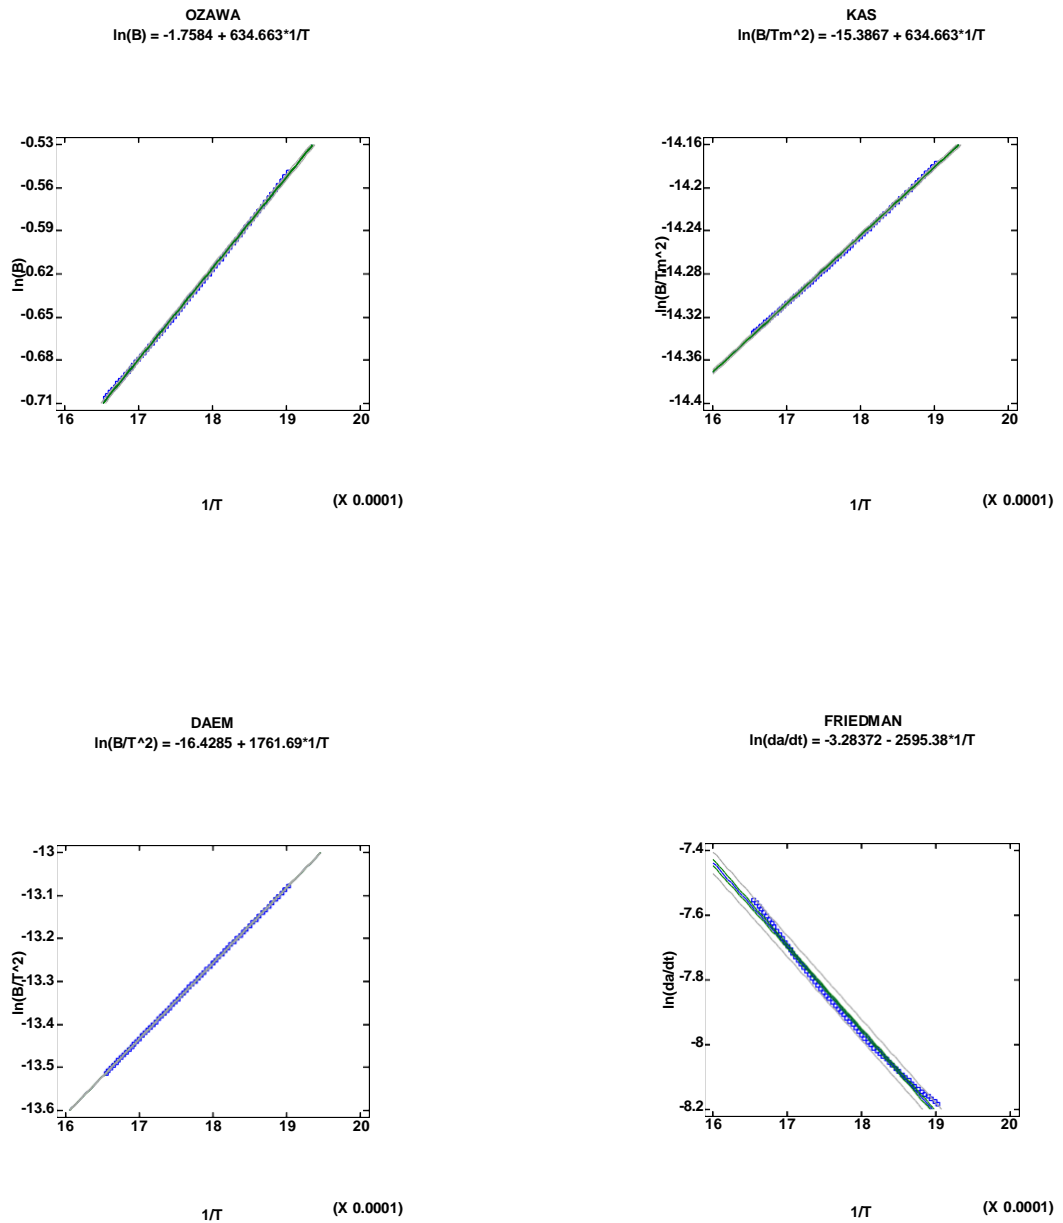


Figura 9-3: Análisis de regresión simple para los modelos cinéticos

Realizado por: Cayambe, José, 2021

En función de los modelos evaluados representados en la Figura 9-3 el método de DAEM es el que mejor se ajusta a los datos, es decir su factor de correlación se acerca a 1 lo que hace de este un modelo óptimo para el cálculo de la energía de activación.

3.5 Diseño de la red neuronal artificial

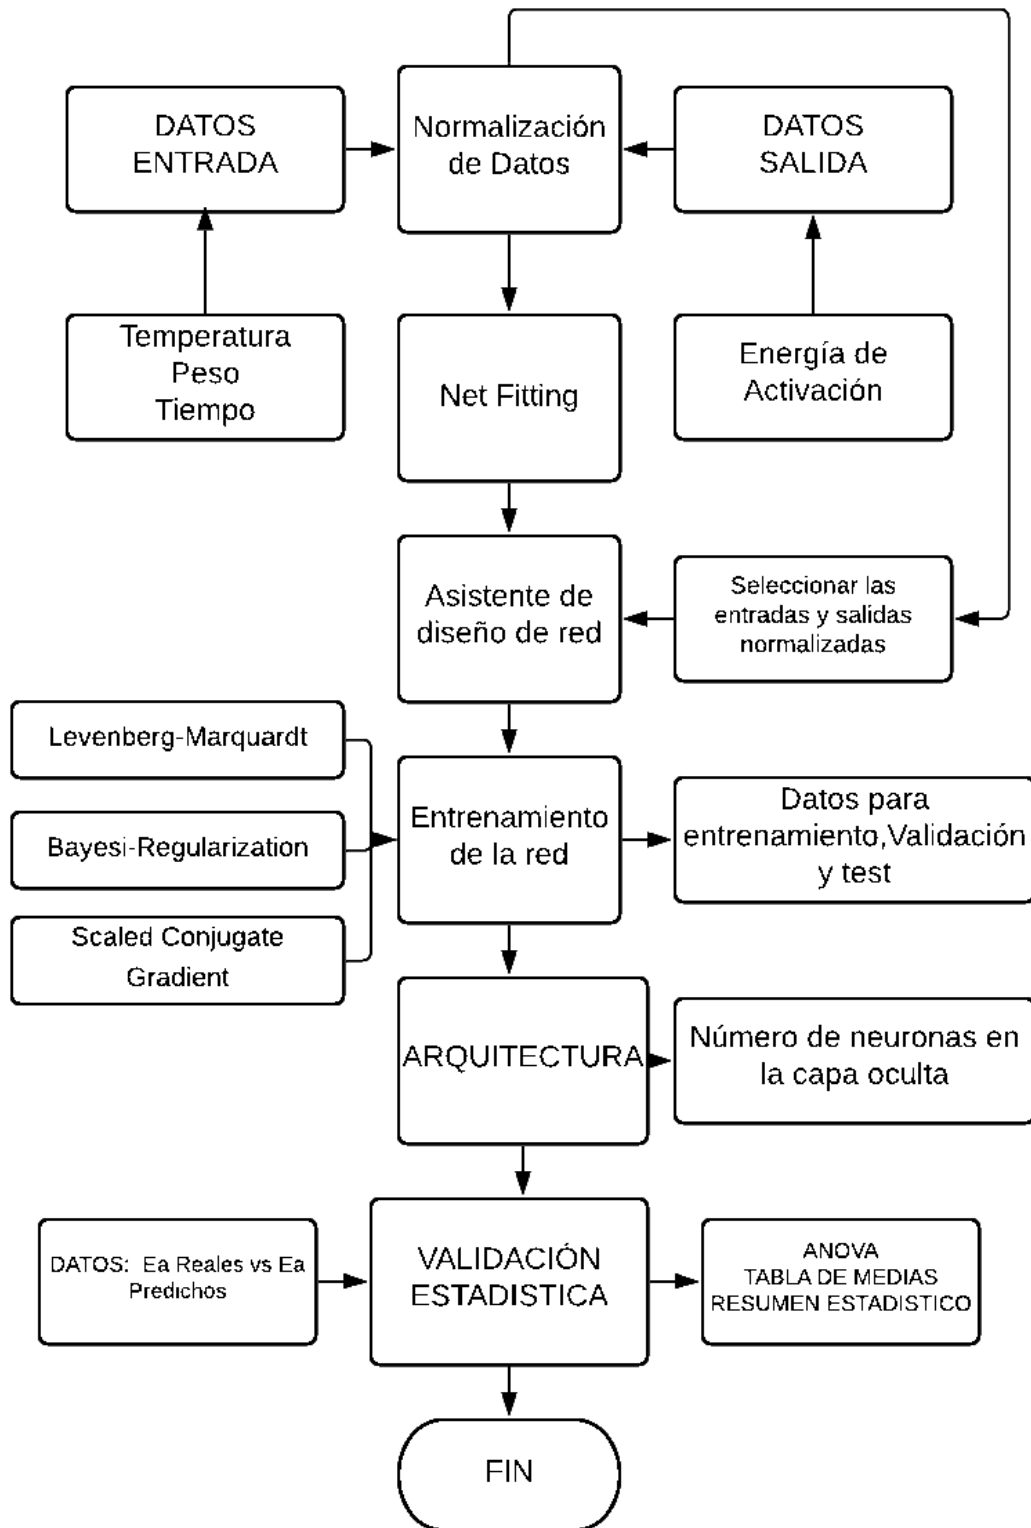


Figura 8-3: Metodología de diseño de la red neuronal artificial

Realizado por: Cayambe, José, 2021

3.5.1 Entradas y salidas en la red neuronal artificial

Las variables de entrada como de salida se establecen antes de iniciar con el diseño de la red neuronal artificial, para la arquitectura de esta red se definen tres variables de entrada como son peso (mg), temperatura (K) y tiempo datos que se obtienen de forma experimental en el análisis termogravimétrico que se realizó a los residuos de tallo de rosa, también se define una variable de salida en este caso la energía de activación obtenida por el modelo cinético de DAEM mediante calculos en Microsoft Excel.

Tabla 6-3: Variables de entrada y salida de la red neuronal artificial

Capa	Variables		Unidades
Entradas	Tiempo	t	s
	Temperatura	T	K
	Peso	P	mg
Salidas	Energía de activación	Ea	KJ/mol

Realizado por: Cayambe, José, 2021

3.5.2 Normalización de datos

Para el desarrollo de la red neuronal generalmente se normalizan los datos para evitar redundancia de los mismos, por ello se importa desde la base de datos tanto para variables de entrada como de salida creada en Microsoft Excel al espacio de trabajo de Matlab para mejorar el proceso de entrenamiento y predicción de la red, mediante la siguiente ecuación.

$$X_{\text{Norm}} = \frac{X - X_{\text{min}}}{X_{\text{max}} - X_{\text{min}}}$$

Donde:

X_{Norm} = valor normalizado

X = valor que se desea normalizar

X_{min} = valor mínimo

X_{max} = valor máximo

Se puede decir que la normalización es una serie de reglas que involucra análisis y transformación de las estructuras de que exhiben propiedades únicas de consistencia mínima redundancia y máxima estabilidad.

3.5.3 Red neuronal artificial (net fitting)

Luego de haber normalizado los datos tanto de entrada como de salida se emplea la aplicación net fitting de la caja de herramientas de Matlab, seleccionando la opción se mostrará una ventana de la aplicación como asistente de diseño de la red neuronal artificial

El usuario seleccionara next mostrándose el asistente de diseño de red, dentro de este se va a seleccionar las entradas y salidas normalizadas anteriormente.

3.5.4 Entrenamiento de la red neuronal artificial

Para el entrenamiento de la red neuronal artificial es importante definir el número óptimo de neuronas en la capa oculta y seleccionar el algoritmo con el que se va a llevar a cabo el entrenamiento de la misma, la selección de del número de neuronas óptimos se lo hace en función de error cuadrático medio (MSE) y la correlación lineal dos parámetros estadísticos que determinan la eficiencia de entrenamiento con las diferentes funciones de aprendizaje. Para este proceso se empezó con 12 neuronas en la capa oculta utilizando las diferentes funciones como son Levenberg-Marquardt, Bayesi-Regularization y Scaled Conjugate Gradient, revisando los valores de MSE y R, es importante señalar que mientras el valor de R es más cercano a 1 se considera a este como el mejor número de neuronas en la capa oculta para la arquitectura final de la red neuronal artificial.

Las entradas de la red neuronal serán la temperatura, el tiempo y el peso resultados de los estudios de TGA, como se muestran en el anexo

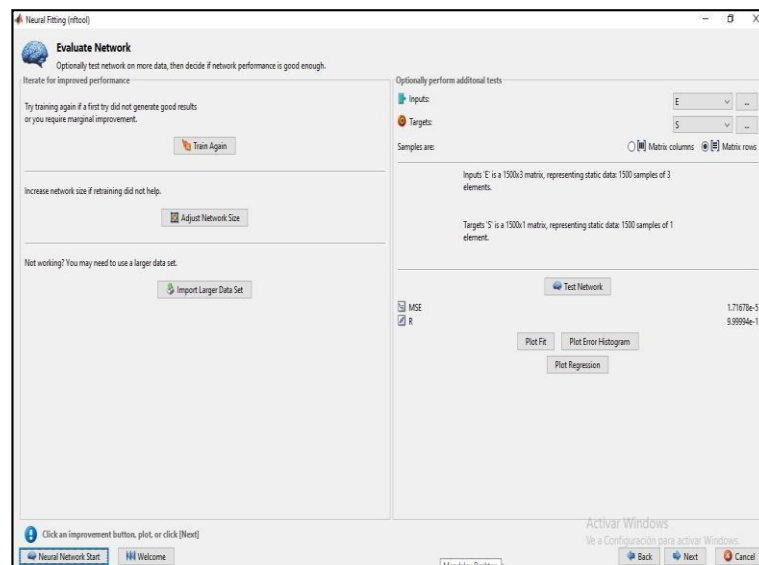


Figura 9-3: Variables de red

Realizado por: Cayambe, José, 2021

La indica un número de neuronas en la capa oculta de 30 con un valor de R de 1 y con un MSE de 0.0000171678.

La red neuronal artificial trabaja de forma predeterminada con las siguientes funciones de activación:

- Función de transferencia en la capa oculta: Hyperbolic tangent sigmoid (tansig).
- Función de transferencia para la capa de salida: Función lineal (purelin)

Para entrenar la red neuronal artificial, se opta por el algoritmo de regularización bayesiana. Este algoritmo a pesar de tomarse un largo tiempo de entrenamiento ayuda a evitar el problema de sobreajuste y logra resultados de estimación más precisos (Balam et al., 2019, p.20).

El algoritmo de Regularización Bayesiana (BR) actualiza los pesos y los valores de sesgo, minimizando el error de predicción y determinando la combinación correcta para obtener una red que generalice bien (Baghirli, 2015, p.15).

Es así que la red neuronal consta de tres neuronas de entrada 30 neuronas en la capa oculta y 1 neurona en la capa de salida. Para el entrenamiento de la red se utilizan 1540 datos de entrada, mientras que para validación 330 y para la evaluación de la red se utiliza también 330 datos.



Figura 10-3: Proceso de entrenamiento de la red

Realizado por: Cayambe, José, 2021

Finalizado el procedimiento de entrenamiento la aplicación nos permite visualizar el código de trabajo como se muestra en la.

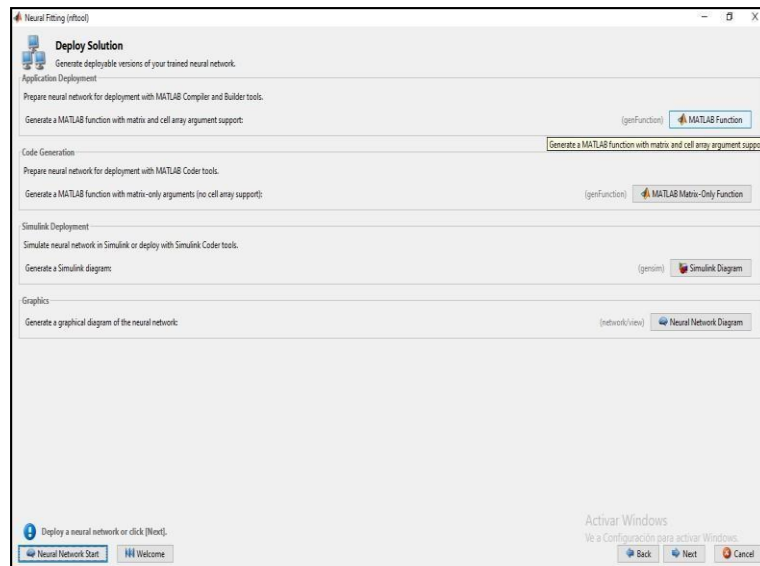


Figura 11-3: Visualización de código

Realizado por: Cayambe, José, 2021

3.5.5 *Análisis Estadístico*

El rendimiento de la red neuronal artificial se evalúa en función de parámetros estadísticos de los resultados predichos frente a los reales de la energía de activación. Las dos bases de datos se analizarán mediante comparación de muestras.

Pruebas estadísticas que se aplicaran:

Tabla ANOVA: análisis de la varianza como un componente entre distintos grupos y otro dentro de los grupos.

Tabla de medias: representa las medias de las muestras con sus respectivas desviaciones estándar.

Para fortalecer el análisis estadístico se elaborarán graficas ANOVA y de medias

CAPÍTULO IV

4 GESTIÓN DEL PROYECTO

4.1 Cronograma

Tabla 1-4: Cronograma de actividades

ACTIVIDAD	MESES																			
	Noviembre				Diciembre				Enero				Febrero				Marzo			
	SEMANAS																			
	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4
Revisión bibliográfica	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■
Elaboración del anteproyecto				■	■	■	■													
Determinación de variables						■	■	■												
Obtención de datos experimentales								■	■	■	■	■								
Determinación de variables de entrada y salida para la RNA									■	■	■	■								
Diseño de la red neuronal en Matlab									■	■	■	■	■							
Estudio técnico y económico									■	■	■	■	■	■						
Validación de la RNA mediante análisis estadístico									■	■	■	■	■	■	■					
Redacción del trabajo final				■	■	■	■	■	■	■	■	■	■	■	■	■				
Análisis de costos				■	■	■	■						■	■	■	■				
Revisión del documento final				■	■	■	■	■	■	■	■	■	■	■	■	■				
Auditoria Académica																	■	■		
Defensa de los resultados																			■	■

Realizado por: Cayambe, José, 2021

4.2 Presupuesto

Tabla 2-4: Presupuesto del proyecto

PRESUPUESTO			
ACTIVIDAD	MONTO	FUENTE DE FINANCIAMIENTO	
		INTERNA	EXTERNA
Análisis termogravimétrico	\$170	x	
Clases asistidas para Matlab	\$100	x	
Impresión del documento final	\$30	x	
Copias e Impresiones	\$50	x	
Empastados	\$50	x	
Contratiempos	\$20	x	
TOTAL	\$420		

Realizado por: Cayambe, José, 2021

4.3 Recursos materiales

4.3.1 Recursos humanos

Tabla 3-4: Recursos humanos del proyecto

Nombre	Función que desempeña
José Cayambe	Autor del Proyecto
Darío Guamán	Tutor (a) académico del proyecto

Realizado por: Cayambe, José, 2021

4.3.2 Recursos materiales

Tabla 4-4: Materiales utilizados en el proyecto

Equipo y software	Uso
Termo balanza	Análisis termogravimétrico de los residuos de café.
Computadora	Calculos cinéticos, diseño de la red neuronal.
Matlab	Diseño de la red neuronal
STATGRAPHICS CENTURION	Validación de los resultados de la red neuronal
Microsoft Excel	Calculos cinéticos

Realizado por: Cayambe, José, 2021

4.4 Resultados

4.4.1 Análisis termogravimétrico

Tabla 5-4: Condiciones para el análisis termogravimétrico

Muestra	Biomasa
Descripción	Residuos de semilla y cáscara de café
Tipo de ensayo	Termogravimetría
Equipo / máquina	Mettler Toledo TGA-1
Descripción del método	<ul style="list-style-type: none">• Rampa de calentamiento 5 y 15 °C/min• Programa de 25 a 900 °C• Atmósfera inerte (N₂) 20 ml/min• Resultados de TGA y dTGA (200puntos)

Realizado por: Cayambe, José, 2021




Figura 1-4: TGA de la rampa 5°C/min

Fuente: Laboratorio de investigación UCE




Figura 2-4:TGA de la rampa 15°C/min

Fuente: Laboratorio de investigación UCE

4.4.2 Resultados de la regresión simple de los modelos cinéticos

Se utilizó el método de regresión simple para la elección del modelo cinético para el cálculo de la energía de activación de las rampas de calentamiento 5 y 15 °C/min

Tabla 6-4: Resultado de los modelos cinéticos

Método	Modelo cinético	Coefficiente de correlación	R ² (%)	R ² ajustada (%)
Flynn-Wall-Ozawa (FWO)	$\ln\left(\frac{g}{g_0}\right) = \ln\left(\frac{g_0 - 5.331 - 1.052}{g_0 - 5.331 - 1.052}\right) - \frac{E_a}{RT}$	0.999816	99.9631	99.9628
Kissinger-Akahira-Sunose(KAS)	$\frac{d\ln(g/g_0)}{dT} = \ln\left(\frac{g_0 - 5.331 - 1.052}{g_0 - 5.331 - 1.052}\right) \left(1 - \frac{E_a}{RT}\right) - \frac{E_a}{RT^2}$	0.999816	99.9631	99.9628
Friedman	$\frac{d\ln(g/g_0)}{dT} = \ln\left[\frac{g_0 - 5.331 - 1.052}{g_0 - 5.331 - 1.052}\right] - \frac{E_a}{RT}$	0.997957	99.5919	99.5885
DAEM	$\ln\left(\frac{g}{g_0}\right) = \ln\left(\frac{g_0 - 5.331 - 1.052}{g_0 - 5.331 - 1.052}\right) + 0.6575 - \frac{E_a}{RT}$	0.999994	99.9988	99.9987
Rampa 15 °C/min				
Flynn-Wall-Ozawa (FWO)	$\ln\left(\frac{g}{g_0}\right) = \ln\left(\frac{g_0 - 5.331 - 1.052}{g_0 - 5.331 - 1.052}\right) - \frac{E_a}{RT}$	0.999787	99.9573	99.9566
Kissinger-Akahira-Sunose(KAS)	$\frac{d\ln(g/g_0)}{dT} = \ln\left(\frac{g_0 - 5.331 - 1.052}{g_0 - 5.331 - 1.052}\right) \left(1 - \frac{E_a}{RT}\right) - \frac{E_a}{RT^2}$	0.999787	99.9573	99.9566
Friedman	$\frac{d\ln(g/g_0)}{dT} = \ln\left[\frac{g_0 - 5.331 - 1.052}{g_0 - 5.331 - 1.052}\right] - \frac{E_a}{RT}$	0.996575	99.3163	99.3052
DAEM	$\ln\left(\frac{g}{g_0}\right) = \ln\left(\frac{g_0 - 5.331 - 1.052}{g_0 - 5.331 - 1.052}\right) + 0.6575 - \frac{E_a}{RT}$	0.999991	99.9982	99.9981

Realizado por: Cayambe, José, 2021

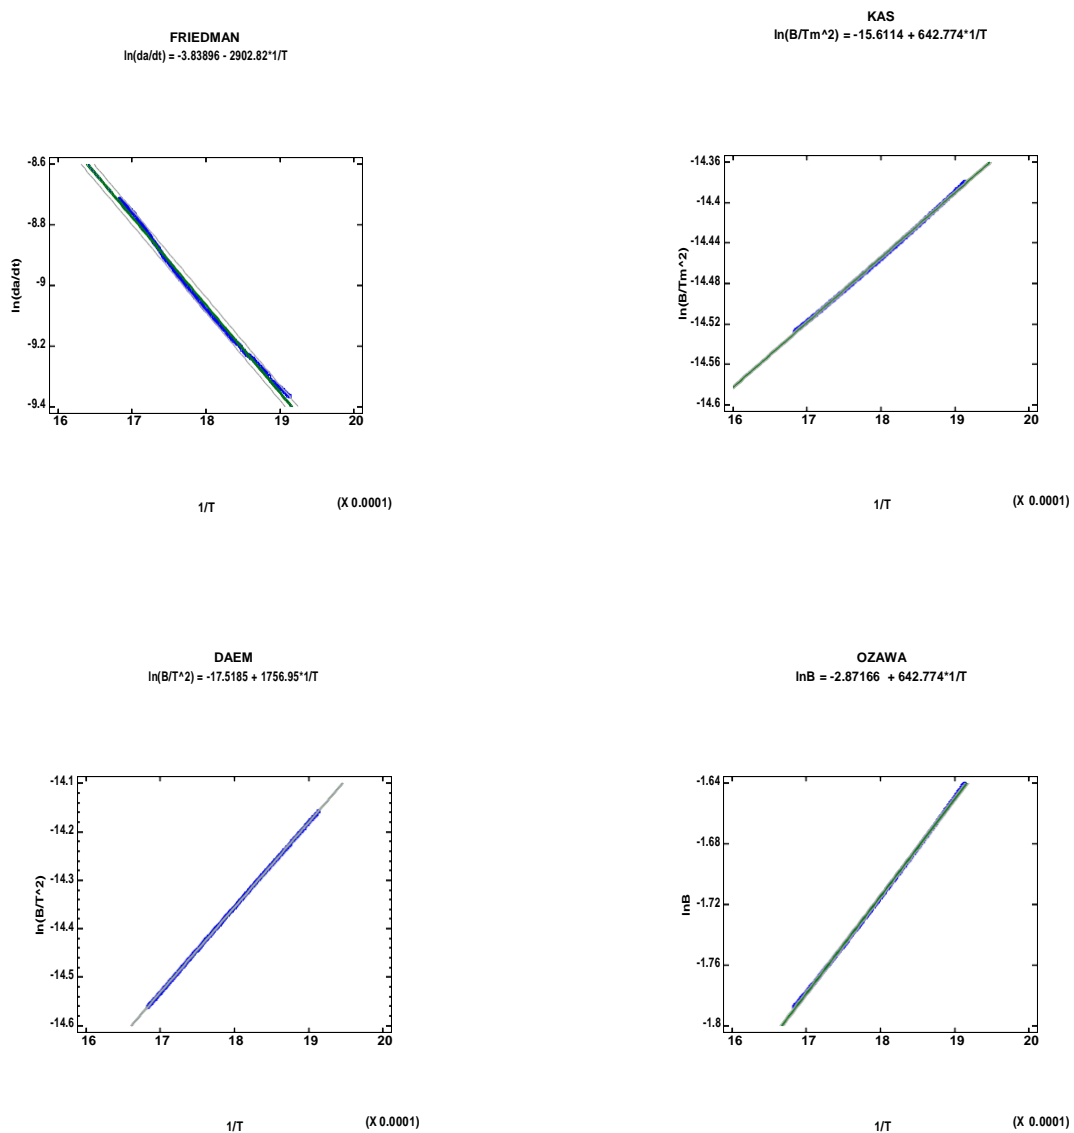


Figura 3-4: Resultados de la regresión simple para la rampa 5°C/min

Realizado por: Cayambe, José, 2021

La Figura 3-4 indica los resultados de la regresión simple de los modelos cinéticos de DAEM, Friedman, Ozawa y KAS para la rampa 5°C/min, donde es evidente que los valores del modelo de energía de activación distribuida (DAEM) se ajustan a la recta alcanzando un factor de correlación cercano a 1, por ello es importante analizar cada uno de los modelos cinéticos para tener un criterio más amplio en la investigación

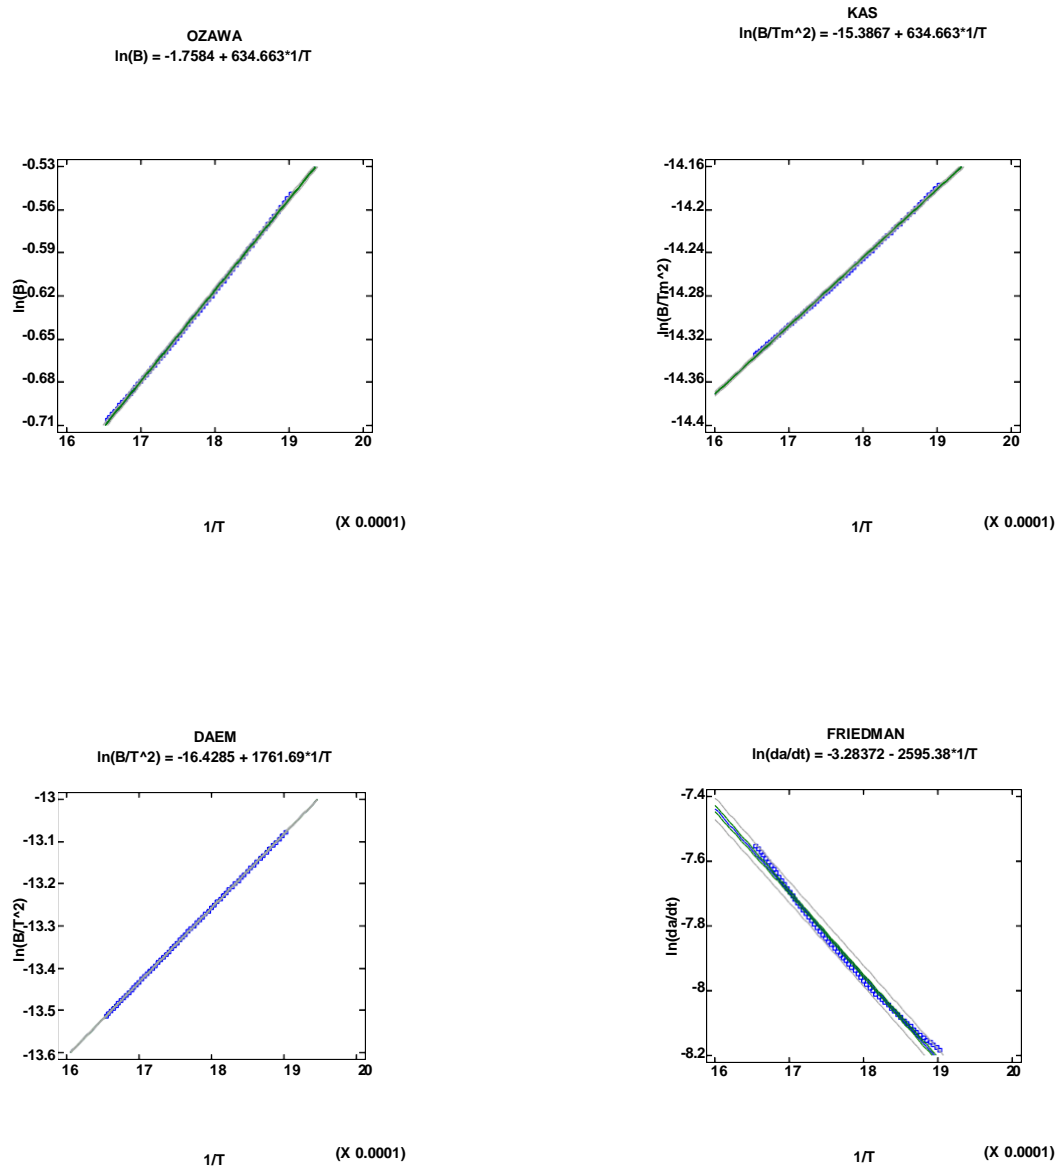


Figura 4-4: Resultados de la regresión simple para la rampa de 15 °C/min

Realizado por: Cayambe, José, 2021

Como es evidente en los dos casos Figura 3-4 y Figura 4-4 el modelo cinético para el cálculo de la energía de activación es el de DAEM o de energía de activación distribuida por su baja dispersión de datos.

4.4.3 Resultados de la energía de activación

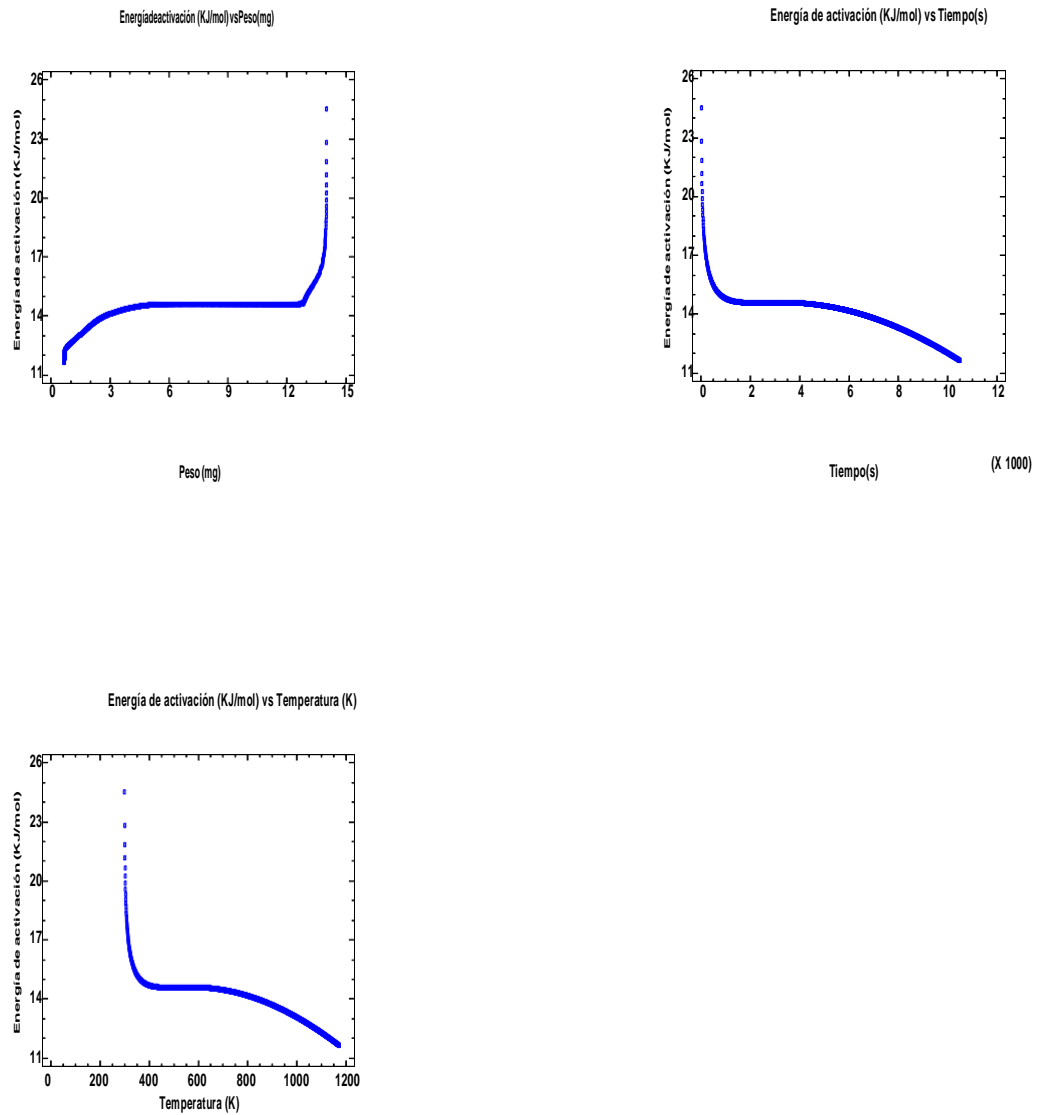


Figura 5-4: Energía de activación rampa 5 °C/min

Realizado por: Cayambe, José, 2021

La Figura 5-4 muestra la dependencia de la energía de activación en función de las variables temperatura, tiempo y peso.

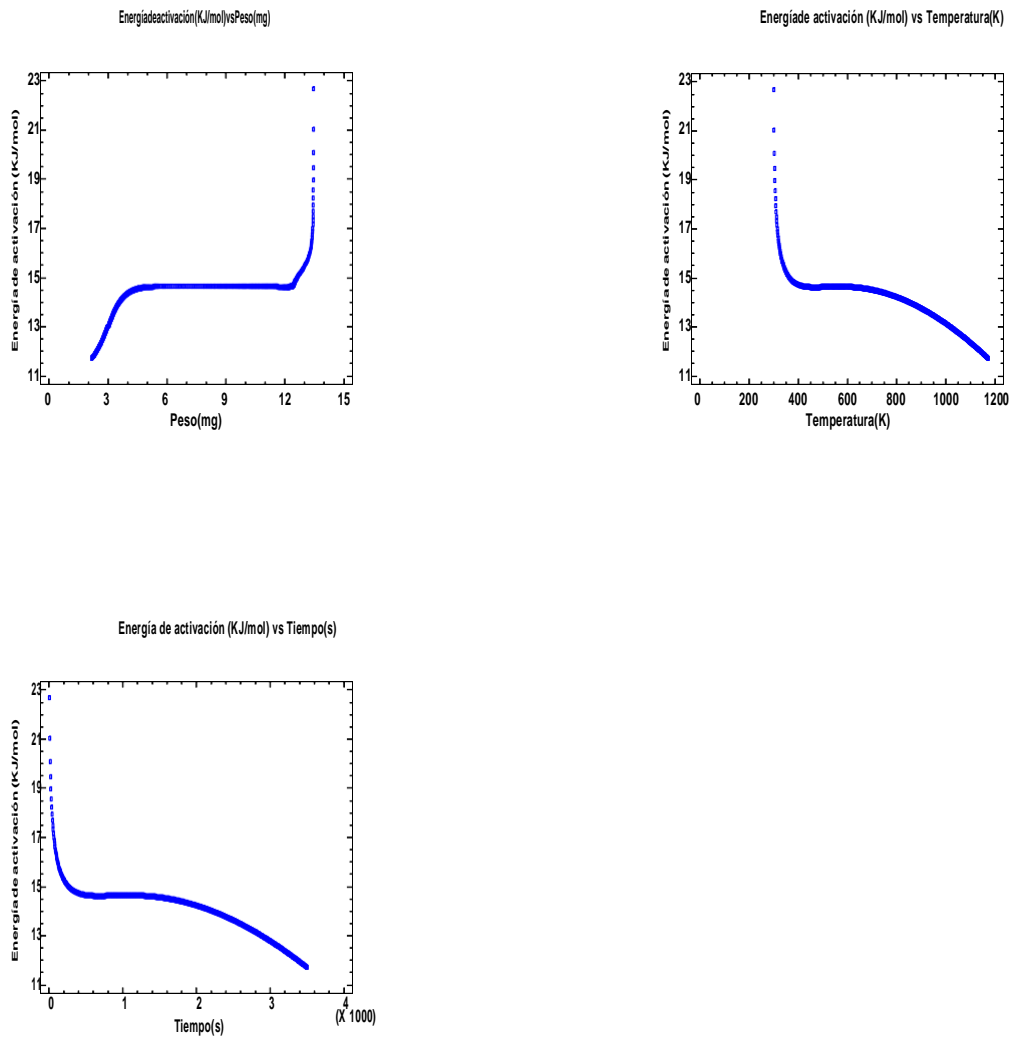


Figura 6-4: Energía de activación rampa 15 °C/min

Realizado por: Cayambe, José, 2021

La Figura 6-4 muestra la misma dependencia con la Figura 5-4 es considerable por ello la propuesta de realizar una sola red neuronal para la predicción de la energía de activación en función de las variables de entrada tiempo, temperatura y peso.

4.4.4 *Desarrollo de la red neuronal artificial*

4.4.4.1 *Normalización de datos*

Como se indica en el 3 los datos de entrada como de salida fueron normalizados para evitar incoherencias en los mismos.

Después de haber importado los datos al espacio de trabajo de Matlab se utiliza la aplicación que se encuentra en su conjunto de herramientas como es Neuronal Net Fiting.




Figura 7-4: Arquitectura de la red con 200 neuronas

Realizado por: Cayambe, José, 2021

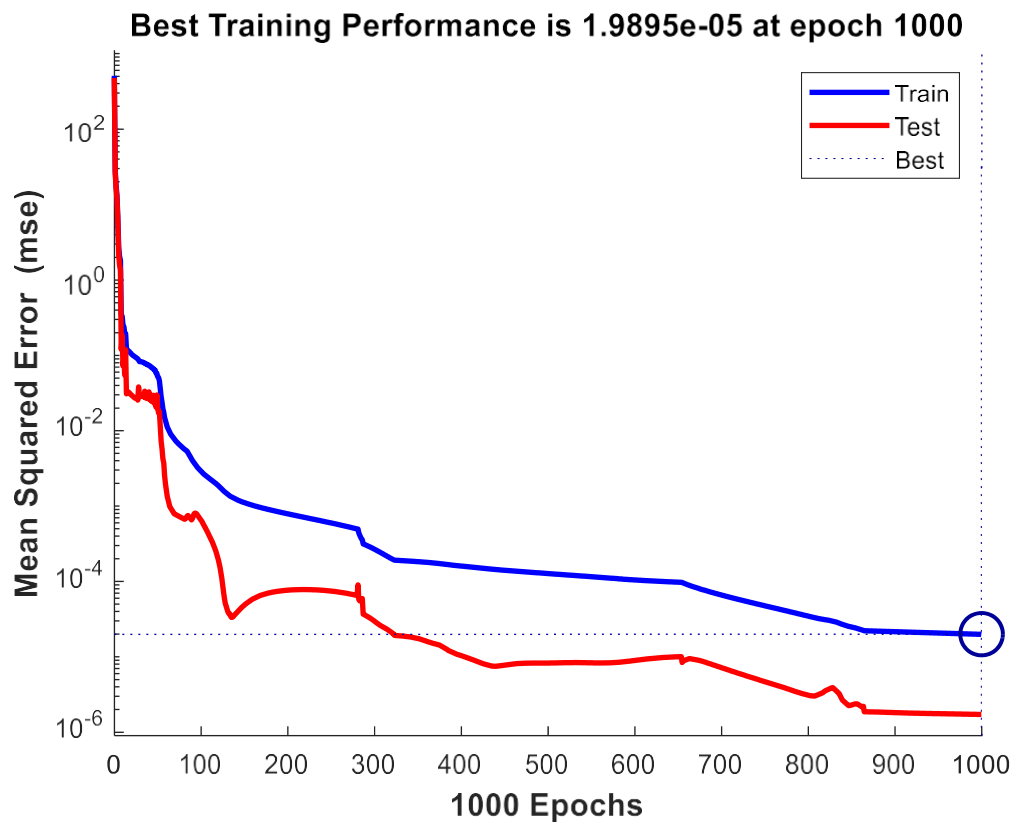


Figura 8-4: Curva de aprendizaje con 30 neuronas

Realizado por: Cayambe, José, 2021




Figura 9-4: Correlación de la red de 30 neuronas

Realizado por: Cayambe, José, 2021

Como muestra la **Figura 9-4** se alcanza un factor de correlación de 1 en el entrenamiento de la red lo que hace de esta una arquitectura idónea para la predicción de la energía de activación.

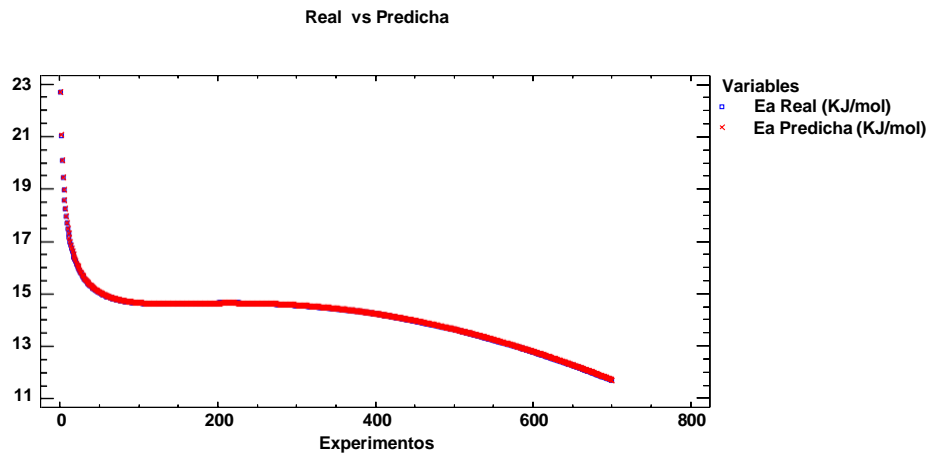


Figura 10-4: Comparación de la energía de activación real y la predicha por la red

Realizado por: Cayambe, José, 2021

La Figura 10-4 comparó los resultados de la energía de activación calculada y la energía de activación predicha donde no existe una diferencia entre valores.

4.4.5 *Análisis estadístico de la red neuronal*

Los resultados de la predicción de la red neuronal artificial se validan mediante un análisis estadístico comparativo de muestras tanto energía de activación real como energía de activación producto de la predicción.

4.4.5.1 *Análisis ANOVA*

Tabla 7-4: ANOVA

Fuente	Suma de Cuadrados	Gl	Cuadrado Medio	Razón-F	Valor-P
Entre grupos	0.000151156	1	0.000151156	0.00	0.9916
Intra grupos	1888.93	1398	1.35116		
Total (Corr.)	1888.93	1399			

Realizado por: Cayambe, José, 2021

La Tabla 7-4 descompone la varianza de los datos en dos componentes: un componente entre-grupos y un componente dentro-de-grupos. La razón-F, que en este caso es igual a 0.00011871, es el cociente entre el estimado entre-grupos y el estimado dentro-de-grupos. Puesto que el valor-P de la razón-F es mayor o igual que 0.05, no existe una diferencia estadísticamente significativa entre las medias de las 2 variables con un nivel del 95.0% de confianza.

CONCLUSIONES

- La red neuronal artificial diseñada es de aprendizaje supervisado misma que emplea datos experimentales del análisis termogravimétrico con su respectivo análisis cinéticos para el cálculo de la energía de activación de los residuos de tallos de rosas.
- Los datos del análisis termogravimétrico se obtuvieron a dos rampas de calentamiento de 5°C/min y 15 °C/min en intervalos de temperatura de 25 a 900°C con flujo de nitrógeno de 20 ml/min.
- El cálculo de la energía de activación se lo llevo a cabo en función de los modelos cinéticos propuestos para cada una de las rampas de calentamiento, donde el modelo de DAEM o energía de activación distribuida tiene un factor de correlación para la rampa 5 °C de 0.999994 y un R² de 99.9988 % producto del análisis por regresión simple del modelo, para el caso de la rampa 15 °C/min modelo que tiene un factor de correlación cercano a 1 es el de DAEM con un coeficiente de 0.999991 y un R² de 99.9982 %.
- La red neuronal artificial está diseñada en el software Matlab cuyo diseño arquitectónico consta de 3 neuronas de entrada que son temperatura (K), tiempo(s) y peso (mg) de la muestra de residuos de tallo de rosas, datos que resultaron del análisis termogravimétrico, en la capa oculta la se encuentran 30 neuronas y una neurona de salida que es la energía de activación (KJ/mol), el algoritmo de entrenamiento fue el de regularización Bayesiana con un coeficiente de correlación de 1 y un error cuadrático medio de 2.73E⁻³.
- Los resultados predichos por la red neuronal artificial fueron evaluados mediante análisis estadístico comparativo de dos muestras, energía de activación real con la predicha por la red donde el valor-P de la razón-F es mayor 0.05, no existiendo una diferencia estadísticamente significativa entre las medias de las 2 variables con un nivel del 95.0% de confianza.

RECOMENDACIONES

Realizar modelos de predicción para cada uno de las ecuaciones cinéticas propuestas en el trabajo.

Evaluar la red neuronal artificial con resultados obtenidos en otros trabajos de investigación relacionados con el tema.

Aprovechar los resultados del trabajo de integración curricular con el propósito de generar tecnología de aprovechamiento de residuos orgánicos para la generación de energía

BIBLIOGRAFÍA

AHMAD, et al., 2017. Kinetic analyses and pyrolytic behavior of Para grass (*Urochloa mutica*) for its bioenergy potential. *Bioresource Technology*, vol. 224, pp. 708-713. ISSN 18732976. DOI 10.1016/j.biortech.2016.10.090.

BAGHIRLI, O., 2015. Comparison of Lavenberg-Marquardt, Scaled Conjugate Gradient And Bayesian Regularization Backpropagation Algorithms for Multistep Ahead Wind Speed Forecasting Using Multilayer Perceptron Feedforward Neural Network. *Dissertation*, no. June, pp. Uppsala University.

BALRAM, et al., 2019. Air quality warning system based on a localized PM2.5 soft sensor using a novel approach of Bayesian regularized neural network via forward feature selection. *Ecotoxicology and Environmental Safety*, vol. 182, no. April, pp. 109386. ISSN 10902414. DOI 10.1016/j.ecoenv.2019.109386.

BARR, et al., 2020. On the suitability of thermogravimetric balances for the study of biomass pyrolysis. *Fuel* [en línea], vol. 276, no. November 2019, pp. 118069. ISSN 00162361. DOI 10.1016/j.fuel.2020.118069. Disponible en: <https://doi.org/10.1016/j.fuel.2020.118069>.

CAI, J et al., 2018. Processing thermogravimetric analysis data for isoconversional kinetic analysis of lignocellulosic biomass pyrolysis: Case study of corn stalk. *Renewable and Sustainable Energy Reviews*, vol. 82, no. April, pp. 2705-2715. ISSN 18790690. DOI 10.1016/j.rser.2017.09.113.

CASTRO, et al., 2020. Evaluation of models to predict the influence of chemical pretreatment on the peels of *Nephelium lappaceum* L. based on pyrolysis kinetic parameters obtained using a combined Fraser-Suzuki function and Friedman isoconversional method. , no. March.

CHAYAPORN, et al., 2014. Evaluation of biomass component effect on kinetic values for biomass pyrolysis using simplex lattice design. , vol. 31, no. 4, pp. 1-13. DOI 10.1007/s11814-014-0296-8.

CHEN, et al 2016. Kinetics of coffee industrial residue pyrolysis using distributed activation energy model and components separation of bio-oil by sequencing temperature-raising pyrolysis. *Bioresource Technology* [en línea], vol. 221, pp. 534-540. ISSN 18732976. DOI 10.1016/j.biortech.2016.09.062. Disponible en: <http://dx.doi.org/10.1016/j.biortech.2016.09.062>.

CONESA, et al., 2011. Biomasses pyrolysis and combustion kinetics through n-th order parallel reactions. *Thermochimica Acta* [en línea], vol. 523, no. 1-2, pp. 176-181. ISSN 00406031. DOI

10.1016/j.tca.2011.05.021. Disponible en: <http://dx.doi.org/10.1016/j.tca.2011.05.021>.

COUHERT, et al., 2009. Is it possible to predict gas yields of any biomass after rapid pyrolysis at high temperature from its composition in cellulose, hemicellulose and lignin? *Fuel* [en línea], vol. 88, no. 3, pp. 408-417. ISSN 00162361. DOI 10.1016/j.fuel.2008.09.019. Disponible en: <http://dx.doi.org/10.1016/j.fuel.2008.09.019>.

DANG, et al., 2021. Prediction and optimization of syngas production from a kinetic-based biomass gasification process model. *Fuel Processing Technology* [en línea], vol. 212, no. July 2020, pp. 106604. ISSN 03783820. DOI 10.1016/j.fuproc.2020.106604. Disponible en: <https://doi.org/10.1016/j.fuproc.2020.106604>.

DELGADO, et al., 2016. Artificial Neural Networks: Applications in Food Processing. *Reference Module in Food Science* [en línea], pp. 1-9. DOI 10.1016/b978-0-08-100596-5.03125- 5. Disponible en: <http://dx.doi.org/10.1016/B978-0-08-100596-5.03125-5>.

ESTIATI, et al., 2016. Fitting performance of artificial neural networks and empirical correlations to estimate higher heating values of biomass. *Fuel* [en línea], vol. 180, pp. 377-383. [Consulta: 4 septiembre 2020]. ISSN 00162361. DOI 10.1016/j.fuel.2016.04.051. Disponible en: <http://dx.doi.org/10.1016/j.fuel.2016.04.051>.

HAEFNER, et al., 2020. Artificial intelligence and innovation management: A review, framework and research agenda. ,

HUANG, et al., 2018. Combustion behaviors of spent mushroom substrate using TG-MS and TG-FTIR: Thermal conversion, kinetic, thermodynamic and emission analyses. *Bioresource Technology* [en línea], vol. 266, pp. 389-397. ISSN 18732976. DOI 10.1016/j.biortech.2018.06.106. Disponible en: <https://doi.org/10.1016/j.biortech.2018.06.106>.

JANUCH, M.G., 2012. Aplicación de Técnica de Inteligencia Artificial a la Predicción de Contaminantes Atmosférico. *Arabic Named Entity Recognition*, no. Madrid, España, pp. 1-225.

MATICH, D., 2001. *Redes Neuronales: Conceptos Básicos y Aplicaciones*. [en línea]. Primera ed. Rosario: s.n. Disponible en: <ftp://decsai.ugr.es/pub/usuarios/castro/Material-Redes-Neuronales/Libros/matich-redesneuronales.pdf>.

MUTHUKRISHNAN, et al., 2020. Brief History of Artificial Intelligence. *Neuroimaging Clinics of North America*, vol. 30, no. 4, pp. 393-399. ISSN 15579867. DOI 10.1016/j.nic.2020.07.004.

NEVES, et al., 2011. Characterization and prediction of biomass pyrolysis products. *Progress in Energy and Combustion Science* [en línea], vol. 37, no. 5, pp. 611-630. ISSN 03601285. DOI 10.1016/j.pecs.2011.01.001. Disponible en: <http://dx.doi.org/10.1016/j.pecs.2011.01.001>.

PDYOT, 2015. *Canton bolivar* [en línea]. Bolívar: s.n. Disponible en: http://app.sni.gob.ec/sni-link/sni/PORTAL_SNI/data_sigad_plus/sigadplusdocumentofinal/1360000390001_CANTON_BOLIVAR_PDYOT_2015_16-03-2015_16-43-46.pdf.

PIO, D.T. & TARELHO, L.A.C., 2020. Empirical and chemical equilibrium modelling for prediction of biomass gasification products in bubbling fluidized beds. *Energy* [en línea], vol. 202, pp. 117654. ISSN 03605442. DOI 10.1016/j.energy.2020.117654. Disponible en: <https://doi.org/10.1016/j.energy.2020.117654>.

SORIA-VERDUGO, et al., 2015. Effect of the number of TGA curves employed on the biomass pyrolysis kinetics results obtained using the Distributed Activation Energy Model. *Fuel Processing Technology* [en línea], vol. 134, pp. 360-371. ISSN 03783820. DOI 10.1016/j.fuproc.2015.02.018. Disponible en: <http://dx.doi.org/10.1016/j.fuproc.2015.02.018>.

SUNPHORKA, et al., 2017. Artificial neural network model for the prediction of kinetic parameters of biomass pyrolysis from its constituents. *Fuel* [en línea], vol. 193, pp. 142-158. ISSN 00162361. DOI 10.1016/j.fuel.2016.12.046. Disponible en: <http://dx.doi.org/10.1016/j.fuel.2016.12.046>.

VAN DE VELDEN, et al., 2010. Fundamentals, kinetics and endothermicity of the biomass pyrolysis reaction. *Renewable Energy* [en línea], vol. 35, no. 1, pp. 232-242. ISSN 09601481. DOI 10.1016/j.renene.2009.04.019. Disponible en: <http://dx.doi.org/10.1016/j.renene.2009.04.019>.

ANEXOS

ANEXO A. ANÁLISIS TERMOGRAVIMÉTRICO



UNIVERSIDAD CENTRAL DEL ECUADOR
FACULTAD DE INGENIERÍA QUÍMICA
ÁREA DE INVESTIGACIÓN



REPORTE DE RESULTADOS DE LABORATORIO ORDEN 090

Lugar y fecha: Quito, 22 de febrero de 2021

1. Datos del solicitante:


Nombre:	José Luis Cayambe Guamán
Dirección:	Riobamba
Cédula / Pasaporte / RUC:	0604130518
Teléfono:	0984332318
Persona de contacto:	José Cayambe Teléfono: 0984332318

2. Especificaciones del ensayo

Muestra:	Biomasa
Descripción:	Tallos de rosa molidos
Tipo de ensayo:	Termogravimetría
Equipo / máquina:	Mettler Toledo TGA-1
Analista:	Ing. Pablo Londoño
Descripción del método:	<ul style="list-style-type: none">• 2 rampas de calentamiento distintas 5 y 15 °C/min• Programa de 25 a 900 °C• Atmósfera inerte (N₂) 20 ml/min• Resultados de TGA y dTGA
Observaciones:	

3. Resultados


Rampa 5°C/min



Rampa 15°C/min



UNIVERSIDAD CENTRAL DEL ECUADOR
FACULTAD DE INGENIERIA QUIMICA
AREA DE INVESTIGACION

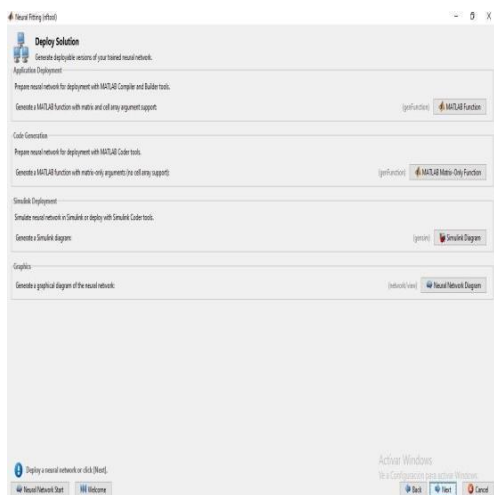
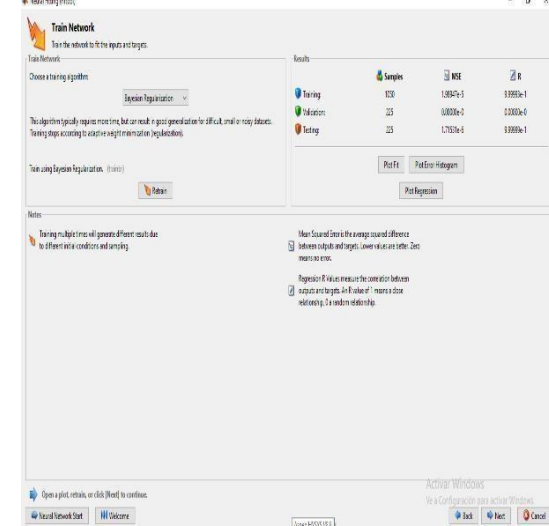
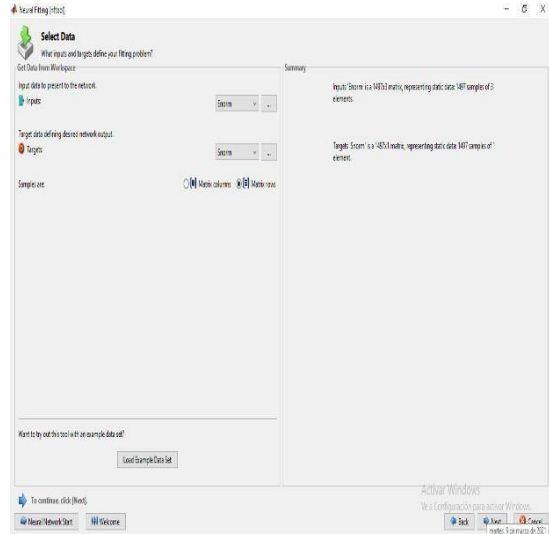
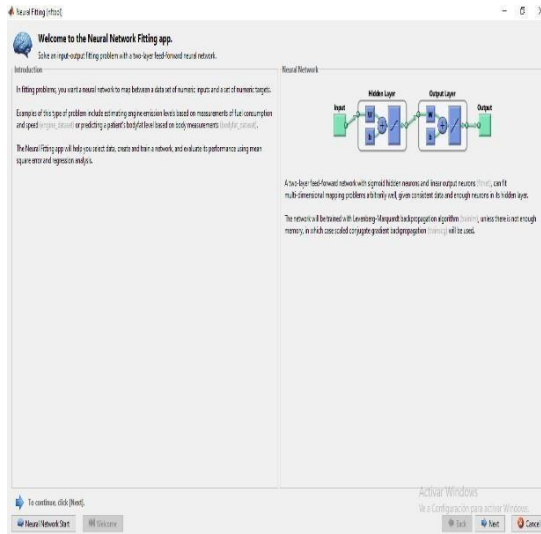


Los resultados en details han sido enviados al correo electronico del cliente

Ing. Pablo Londoño Larrea
Analista de Laboratorio Universitario 3

Dirección: Glitter sin y Bolivia Tel+fonos: 2904794 / 2544631 Coz'zeo electrónico: [rtPranatn fin@urP
erlu er CASILIA: 17-03-1673](mailto:rtPranatnfin@urP.edu.ec)
QUITO - ECUADOR

ANEXO B: TOOL BOX MATLAB DE LA RED NEURONAL





ESCUELA SUPERIOR POLITÉCNICA DE
CHIMBORAZO
DIRECCIÓN DE BIBLIOTECAS Y RECURSOS DEL
APRENDIZAJE



UNIDAD DE PROCESOS TÉCNICOS
REVISIÓN DE NORMAS TÉCNICAS, RESUMEN Y BIBLIOGRAFÍA

Fecha de entrega: 11 / 10 / 2021

INFORMACIÓN DEL AUTOR/A (S)

Nombres – Apellidos: *José Luis Cayambe Guamán*

INFORMACIÓN INSTITUCIONAL

Facultad: *Ciencias*

Carrera: *Ingeniería Química*

Título a optar: *Ingeniero Químico*

f. Analista de Biblioteca responsable: *Lic. Luis Caminos Vargas Mgs.*

LUIS
ALBERTO
CAMINOS
VARGAS

Firmado digitalmente
por LUIS ALBERTO
CAMINOS VARGAS
DN: cn=LUIS ALBERTO
CAMINOS VARGAS,
c=EC, l=RIOBAMBA
Motivo: Soy el autor de
este documento
Ubicación:
Fecha: 2021-10-11
15:08:05:00



0879-DBRAI-UTP-2021