



# UNIVERSIDAD TÉCNICA DEL NORTE

## FACULTAD DE INGENIERÍA EN CIENCIAS AGROPECUARIAS Y AMBIENTALES

### CARRERA DE AGROINDUSTRIA

#### INFORME FINAL DE TRABAJO DE INTEGRACIÓN CURRICULAR, MODALIDAD PRESENCIAL

#### TEMA:

#### “MODELACIÓN MATEMÁTICA DE LA ESTIMACIÓN DE TURBIDEZ EN VINOS ARTESANALES”

Trabajo de titulación previo a la obtención del título de Ingeniería Agroindustrial

**Línea de Investigación:** Gestión, producción, productividad, innovación y desarrollo socioeconómico.

**Autora:** De La Cruz Rojas Erika Mishell

**Director:** Ing. Juan Carlos de la Vega Quintero, MSc.

Ibarra, 2024



## UNIVERSIDAD TÉCNICA DEL NORTE BIBLIOTECA UNIVERSITARIA

### AUTORIZACIÓN DE USO Y PUBLICACIÓN A FAVOR DE LA UNIVERSIDAD TÉCNICA DEL NORTE

#### 1. IDENTIFICACIÓN DE LA OBRA

En cumplimiento del Art. 144 de la Ley de Educación Superior, hago la entrega del presente trabajo a la Universidad Técnica del Norte para que sea publicado en el Repositorio Digital Institucional, para lo cual pongo a disposición la siguiente información:

DATOS DE CONTACTO			
<b>CÉDULA DE IDENTIDAD:</b>	1726575739		
<b>APELLIDOS Y NOMBRES:</b>	De La Cruz Rojas Erika Mishell		
<b>DIRECCIÓN:</b>	Tabacundo_Panamericana Norte km 37		
<b>E-MAIL:</b>	<a href="mailto:emdelacruz@utn.edu.ec">emdelacruz@utn.edu.ec</a>		
<b>TELÉFONO FIJO:</b>		<b>TELÉFONO MÓVIL:</b>	0993088471

DATOS DE LA OBRA			
<b>TÍTULO:</b>	Modelación matemática de la estimación de turbidez en vinos artesanales		
<b>AUTORA:</b>	De La Cruz Rojas Erika Mishell		
<b>FECHA: DD/MM/AAAA</b>	14/03/2024		
SOLO PARA TRABAJOS DE GRADO			
<b>PROGRAMA:</b>	<input checked="" type="checkbox"/> PREGRADO	<input type="checkbox"/> POSGRADO	
<b>TÍTULO POR EL QUE OPTA:</b>	Ingeniera Agroindustrial		
<b>DIRECTOR:</b>	Ing. Juan Carlos de la Vega, MSc.		

#### 2. CONSTANCIAS

El autor manifiesta que la obra objeto de la presente autorización es original y se la desarrolló, sin violar derechos de autor de terceros, por lo tanto, la obra es original y que es el titular de los derechos patrimoniales, por lo que asume la responsabilidad sobre el contenido de la misma y saldrá en defensa de la Universidad en caso de reclamación por parte de terceros.

Ibarra, a los 14 días del mes de marzo de 2024

#### EL AUTOR:

  
 .....  
 Erika Mishell De La Cruz Rojas

## **CERTIFICACIÓN DIRECTOR DEL TRABAJO DE INTEGRACIÓN CURRICULAR**

Ibarra, 13 de marzo de 2024

Ing. Juan Carlos de la Vega, MSc.

### **DIRECTOR DEL TRABAJO DE INTEGRACIÓN CURRICULAR**

CERTIFICA:

Haber revisado el presente informe final del trabajo de Integración Curricular, el mismo que se ajusta a las normas vigentes de la Universidad Técnica del Norte; en consecuencia, autorizo su presentación para fines legales pertinentes.



Ing. Juan Carlos de la Vega, MSc

C.C: 1002958856

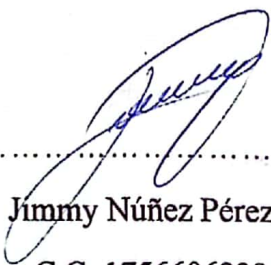
## APROBACIÓN DEL COMITÉ CALIFICADOR

El Comité Calificador del trabajo de Integración Curricular “Modelación matemática de la estimación de turbidez en vinos artesanales” elaborado por Erika Mishell De La Cruz Rojas, previo a la obtención del título de Ingeniera Agroindustrial, aprueba el presente informe de investigación en nombre de la Universidad Técnica del Norte.



Ing. Juan Carlos de la Vega. MSc

C.C: 1002958856



Ing. Jimmy Núñez Pérez. MSc

C.C: 1756606339

## DEDICATORIA

*Dedico este trabajo de investigación a mis padres Mirian Rojas y Santos De La Cruz, quienes han sido fuente de motivación para alcanzar cada uno de mis logros. Por su amor, guía, sabiduría, sacrificio y apoyo incondicional en este proceso, así como también a lo largo de mi vida.*

*También dedico este trabajo a Dayana, Gisela, Viviana y Zoe, cuyo apoyo moral ha sido fundamental en esta etapa académica, incentivándome diariamente a no rendirme frente a cualquier obstáculo presentado en mi camino.*

**Mishell De La Cruz**

## AGRADECIMIENTO

*Agradezco a Dios por brindarme salud y sabiduría durante este recorrido del aprendizaje y por permitirme estudiar esta carrera que será con lo que me desempeñe posteriormente en el campo laboral.*

*A mis padres que han sido un pilar fundamental en mi formación personal como profesional, inculcándome buenos valores y forjando mi carácter convirtiéndome en la persona que soy actualmente. Por enseñarme a valorar los pequeños momentos de la vida e impulsarme en cada error cometido a través de un consejo y enseñanza.*

*De igual manera a los diferentes docentes de la carrera por compartir sus conocimientos y experiencias que han sido muy valiosas. Especialmente mi gratitud a mi tutor, Ing. Juan Carlos De La Vega por su orientación, paciencia y consejos, por brindarme la libertad de explorar nuevas ideas y proporcionar una guía valiosa a lo largo de este proceso. Por motivarme con sus palabras a seguir adelante y realizar las actividades de manera satisfactoria.*

*Finalmente, agradezco a Cristian por brindarme su apoyo incondicional de manera física y emocional, por sus palabras de aliento en los momentos más difíciles y por celebrar cada logro conjuntamente conmigo a lo largo de este camino.*

**Mishell De La Cruz**

## RESUMEN EJECUTIVO

El vino tinto es una bebida muy consumida en el mundo debido a su sabor característico, la cual contiene sólidos suspendidos originados durante su proceso de producción provocando turbidez. Parámetro que afecta la calidad dado que produce cambios en las propiedades organolépticas. El propósito de este estudio fue modelar matemáticamente la estimación de turbidez en vinos artesanales con relación a dosificación y tipos de clarificantes, basado en estudios previos sobre clarificación que hayan presentado resultados positivos. Para ello se elaboró vino de uva de la variedad Borgoña (*Vitis lambrusca*), el cual fue clarificado con yausabara y bentonita a diferentes concentraciones (100 por cada clarificante), de esta manera se generó una base de datos significativa. Se modeló el sistema mediante métodos aproximados como regresión lineal múltiple y Machine Learning con las aplicaciones de Neural Net Fitting y Regression Learner de Matlab. Para el entrenamiento y validación se utilizaron el 70% y 30 % de los datos, respectivamente. El mejor modelo entrenado fue la red neuronal de 25 neuronas en la capa oculta con un  $R^2= 0.9876$  y  $MSE= 0.0029$  y seguidamente el modelo regresión del proceso gaussiano exponencial que presentó un  $R^2= 0.9726$  y  $MSE= 0.0030$ . En consecuencia, se infiere que los modelos mencionados resultaron ser buenos tanto en el entrenamiento como en la validación. La validación del modelo mostró que la red neuronal (RNA) es capaz de predecir la turbidez del vino artesanal con un nivel de fiabilidad alta debido a que modela procesos complejos que no presentan linealidad.

**Palabras claves:** redes neuronales, aprendizaje automático, regresión, estabilidad.

## ABSTRACT

Red wine is a widely consumed beverage in the world due to its characteristic flavor, which contains suspended solids originating during its production process causing turbidity. Parameter that affects quality since it produces changes in organoleptic properties. The purpose of this study was to mathematically model the estimation of turbidity in artisanal wines in relation to dosage and types of fining agents, based on previous studies on clarification that have presented positive results. For this, grape wine of the Burgundy variety (*Vitis lambrusca*) was produced, which was clarified with yausabara and bentonite at different concentrations (100 for each fining agent), in this way a significant database was generated. The system was modeled using approximate methods such as multiple linear regression and Machine Learning with the Neural Net Fitting and Regression Learner applications of Matlab. For training and validation, 70% and 30% of the data were used, respectively. The best trained model was the neural network of 25 neurons in the hidden layer with an  $R^2= 0.9876$  and  $MSE= 0.0029$  and then the regression model of the exponential Gaussian process that presented an  $R^2= 0.9726$  and  $MSE= 0.0030$ . Consequently, it is inferred that the mentioned models turned out to be good in both training and validation. The validation of the model showed that the neural network (ANN) is capable of predicting the turbidity of artisanal wine with a high level of reliability because it models complex processes that do not present linearity.

**Keywords:** neural networks, machine learning, regression, stability.



## ÍNDICE DE CONTENIDO

<b>INTRODUCCIÓN .....</b>	<b>14</b>
<b>Problema .....</b>	<b>14</b>
<b>Justificación .....</b>	<b>16</b>
<b>Objetivos .....</b>	<b>17</b>
Objetivo general .....	17
Objetivos específicos .....	17
<b>Hipótesis .....</b>	<b>17</b>
Hipótesis alternativa .....	17
Hipótesis nula .....	17
<b>CAPÍTULO I.....</b>	<b>18</b>
<b>MARCO TEÓRICO .....</b>	<b>18</b>
<b>1.1 Vino.....</b>	<b>18</b>
<b>1.2 Características del vino.....</b>	<b>18</b>
<b>1.3 Clasificación de vinos.....</b>	<b>19</b>
1.3.1 Según su color.....	19
1.3.2 Según el contenido de azúcar .....	19
<b>1.4 Fermentación del vino.....</b>	<b>20</b>
<b>1.5 Turbidez .....</b>	<b>20</b>
1.5.1 Medición de turbidez.....	21
1.5.2 Espectrofotómetro.....	22
1.5.3 Absorbancia .....	22
<b>1.6 Clarificación.....</b>	<b>23</b>
1.6.1 Tipos de clarificantes .....	24

<b>1.7</b>	<b>Yausabara (<i>Pavonia sepium</i>)</b> .....	<b>24</b>
1.7.1	Usos.....	25
<b>1.8</b>	<b>Bentonita</b> .....	<b>25</b>
<b>1.9</b>	<b>Modelo matemático</b> .....	<b>26</b>
1.9.1	<i>Desarrollo de modelos matemáticos</i> .....	26
<b>1.10</b>	<b>Métodos multivariables</b> .....	<b>27</b>
1.10.1	<i>Regresión lineal múltiple</i> .....	27
1.10.2	<i>Red Neuronal Artificial (RNA)</i> .....	27
1.10.3	<i>Técnica de Neural Net Fitting</i> .....	28
1.10.4	<i>Técnica de Regression Learner</i> .....	29
<b>1.11</b>	<b>Validación cruzada</b> .....	<b>29</b>
<b>1.12</b>	<b>Ajuste del modelo matemático</b> .....	<b>30</b>
1.12.1	<i>Coeficiente de determinación</i> .....	30
1.12.2	<i>Error cuadrático medio</i> .....	31
<b>CAPÍTULO II</b> .....		<b>32</b>
<b>METODOLOGÍA</b> .....		<b>32</b>
<b>2.1</b>	<b>Tipo de Investigación</b> .....	<b>32</b>
<b>2.2</b>	<b>Técnicas e instrumentos de investigación</b> .....	<b>32</b>
<b>2.3</b>	<b>Caracterización del área de estudio</b> .....	<b>33</b>
<b>2.4</b>	<b>Manejo específico del experimento</b> .....	<b>33</b>
2.4.1	<i>Elaboración del vino</i> .....	33
2.4.2	<i>Clarificación del vino</i> .....	34
2.4.3	<i>Almacenamiento durante fase de experimentación</i> .....	34

2.4.4	<i>Determinación de turbidez</i> .....	35
<b>2.5</b>	<b>Procedimiento y análisis de datos</b> .....	<b>35</b>
<b>2.6</b>	<b>Métodos</b> .....	<b>35</b>
2.6.1	<i>Análisis del modelo matemático representativo mediante métodos aproximados</i> .	36
2.6.2	<i>Análisis de modelos matemáticos representativos mediante Machine learning</i> ....	36
2.6.3	<i>Validación del modelo matemático</i> .....	38
<b>CAPÍTULO III</b> .....		<b>39</b>
<b>RESULTADOS Y DISCUSIÓN</b> .....		<b>39</b>
<b>3.1</b>	<b>Pretratamiento de datos</b> .....	<b>39</b>
<b>3.2</b>	<b>Análisis mediante métodos aproximados y Machine Learning de los modelos matemáticos representativos del sistema de estudio</b> .....	<b>40</b>
3.2.1	<i>Modelo de predicción de turbidez a través de regresión lineal múltiple</i> .....	40
3.2.2	<i>Modelo de predicción de turbidez a través de Neural Net Fitting</i> .....	41
3.2.3	<i>Modelo de predicción de turbidez a través de Regression Learner</i> .....	44
<b>3.3</b>	<b>Validación de los modelos matemáticos seleccionados mediante datos experimentales diferentes a los trabajados en el entrenamiento</b> .....	<b>47</b>
<b>CONCLUSIONES Y RECOMENDACIONES</b> .....		<b>50</b>
<b>4.2</b>	<b>Conclusiones</b> .....	<b>50</b>
<b>4.3</b>	<b>Recomendaciones</b> .....	<b>50</b>
<b>REFERENCIAS BIBLIOGRÁFICAS</b> .....		<b>52</b>
<b>ANEXOS</b> .....		<b>62</b>

## ÍNDICE DE FIGURAS

<i><b>Figura 1.</b> Esquema general de un espectrofotómetro .....</i>	22
<i><b>Figura 2.</b> Absorción de un haz atravesado por una muestra en celda de plástico. ....</i>	23
<i><b>Figura 3.</b> Planta de Yausabara (<i>Pavonia sepium</i>).....</i>	25
<i><b>Figura 4.</b> Estructura de red de aplicación Neural Net Fitting.....</i>	28
<i><b>Figura 5.</b> Diagrama de flujo para entrenar modelos de regresión.....</i>	29
<i><b>Figura 6.</b> Diagrama de cajas y bigotes de los valores de turbidez con yausabara y bentonita ..</i>	39
<i><b>Figura 7.</b> Rendimiento del modelo de red neuronal con 25 neuronas en la capa oculta .....</i>	43
<i><b>Figura 8.</b> Valores de coeficiente de determinación (A) y cuadrado medio del error (B) de los modelos entrenados con el mejor rendimiento .....</i>	44
<i><b>Figura 9.</b> Regresión de entrenamiento del modelo del proceso gaussiano exponencial para predecir la turbidez.....</i>	46
<i><b>Figura 10.</b> Rendimiento de validación de los modelos seleccionados: A) regresión lineal múltiple, B) Red neuronal y C) GRP exponencial .....</i>	48

## ÍNDICE DE TABLAS

<b>Tabla 1.</b> <i>Características de los diferentes tipos de vino basados en el umbral de turbidez.....</i>	21
<b>Tabla 2.</b> <i>Métricas de rendimiento del entrenamiento de los algoritmos de aprendizaje.....</i>	42
<b>Tabla 3.</b> <i>Métricas de validación de los modelos seleccionados en el entrenamiento.....</i>	47
<b>Tabla 4.</b> <i>Comparación entre las métricas de entrenamiento y validación de los modelos seleccionados .....</i>	49

## INTRODUCCIÓN

### Problema

El vino es una bebida obtenida mediante la fermentación del mosto de la fruta por acción de levaduras (Vernhet, 2019). Actualmente su consumo se ha popularizado en Ecuador logrando ser la tercera bebida alcohólica más demandada, siendo superada por la cerveza y licores (Arrien, 2019). Según el Instituto Nacional de Estadísticas y Censos (INEC, 2018) estima que la productividad de vinos tintos, blancos y rosados es de alrededor de 1132.70, 1430.68 y 145.21 litros, respectivamente. Su oferta se enfoca en producciones artesanales internas y mayoritariamente en exportaciones de otros países (Araujo, 2023).

El proceso de elaboración del vino requiere de varias fases, siendo la inestabilidad un parámetro que requiere de un riguroso control (Vernhet, 2019). Esta inestabilidad es provocada por la presencia de partículas suspendidas que afectan la preservación de sus propiedades y claridad, denominada turbidez (Angamarca y Morales, 2011). Dado que una eliminación exagerada de la misma puede hacer que se agoten sus nutrientes provocando vinos de baja calidad (Berrazueta y Yanchaguano, 2018). Por consiguiente, la clarificación es una etapa clave en el transcurso de vinificación para eliminar partículas floculantes (Chuma, 2018).

Para determinar la turbidez en tiempo real se realizan procesos de clarificación que requieren de un largo periodo de tiempo (Chuma, 2018). Según De la Fuente et al. (2023) una medición viable de este parámetro se lo realiza mediante muestras puntuales, lo que genera un tedioso trabajo, además de la adquisición de insumos y uso de equipos como el turbidímetro que representan un significativo capital de inversión. Esta complejidad implica que los productores artesanales resten interés a la medición de este parámetro, aun cuando es importante en el vino.

Existen investigaciones realizadas por Angamarca y Morales (2011), Carrión et al. (2018) y Chuma (2018) sobre la evaluación de dosis de diferentes clarificantes en distintos tipos de vinos para conseguir una turbidez adecuada. Sin embargo, no existe un modelo matemático que represente este sistema, mediante el cual se permita asegurar con certidumbre el valor de turbidez final sin necesidad de realizar experimentos en campo. Lo cual se debe a la limitada información y desconocimiento de nuevas herramientas tecnológicas. Es así como el vacío del modelo matemático no apoya a los productores artesanales en optimizar la calidad del producto que ofrecen, al no contar con una herramienta de fácil manejo, bajo costo y rápida accesibilidad.

## Justificación

En Ecuador, el aumento de la demanda de vinos artesanales se debe a su sabor característico tradicional (Reyes y Rojas, 2018). Razón por la cual se encuentra una extensa variedad de estos que el consumidor exige sean de calidad, lo que ha generado un mercado más competitivo (Araujo, 2023). Dado que aquellos que se presentan turbios suelen ser rechazados por el comprador (Carrión et al., 2018).

Tras el proceso fermentativo se evidencia que los vinos exhiben una falta de claridad, lo cual afecta la preservación de las propiedades sensoriales (Peyro, 2019). En la industria vinícola, la medición de turbidez es un indicador clave de la claridad y estabilidad en los vinos antes del embotellamiento (Chuma, 2018). Dado que existen partículas presentes en el vino que son de tamaño pequeño y por ende más ligeras las cuales no sedimentan naturalmente (Castro et al., 2010). Por lo cual, mediante un modelo se puede ayudar a controlar estos procesos para detectar y abordar problemas de manera oportuna (Roldán, 2019).

La ausencia de herramientas para predecir de manera rápida la turbidez final en un vino artesanal ha hecho necesaria la realización del presente trabajo de investigación. Que pretende optimizar estos procesos mediante el desarrollo de un modelo matemático predictivo que represente la relación entre dosis y tipos de clarificantes de fácil acceso y disponibilidad (yausabara y bentonita). Los cuales han sido anteriormente probados en un estudio que dieron un eficiente proceso de clarificación. De esta manera, se pretende establecer una herramienta útil y práctica para la determinación rápida e *in-situ* del valor final de turbidez en vinos artesanales. En este contexto una reducción de tiempo y costos mediante la estandarización y mejora de la calidad de este producto, conservando la confianza de los consumidores y competitividad en el mercado.



## **Objetivos**

### **Objetivo general**

- Modelar matemáticamente la estimación de turbidez en vinos artesanales con relación a dosificación y tipos de clarificantes.

### **Objetivos específicos**

- Analizar mediante métodos aproximados o machine learning modelos representativos del sistema de estudio.
- Validar el modelo matemático mediante datos experimentales diferentes a los trabajados en el entrenamiento.

## **Hipótesis**

### **Hipótesis alternativa**

**Ha:** El modelo matemático desarrollado se adapta correctamente al sistema de estudio.

### **Hipótesis nula**

**Ho:** El modelo matemático desarrollado no se adapta correctamente al sistema de estudio.

# CAPÍTULO I

## MARCO TEÓRICO

### 1.1 Vino

Consiste en una bebida producida a través la fermentación alcohólica del mosto o jugo de uvas frescas (Idígoras, 2011). Este producto debe tener una graduación alcohólica mínima de 8.5% vol., sin embargo, debido a varios factores climáticos se estima que el contenido de alcohol es inferior hasta el 7% vol. (Gadvay, 2015).

Asimismo, es una solución compuesta por un 88% de agua, un 9% de alcohol etílico y el resto de ácidos y minerales como fósforo, calcio, magnesio, hierro, sodio, potasio, yodo y zinc que le confieren al vino sus cualidades organolépticas (Berrazueta y Yanchaguano, 2018).

### 1.2 Características del vino

Esta bebida se conforma de una variedad de componentes químicos que contribuyen a su compleja composición, tales como monosacáridos, glucosa, agua, etanol, ácidos volátiles, fenoles, fructosa, sacarosa y polisacáridos (Buja, 2022). Durante la fermentación se presentan cambios de acidez que se deben a un equilibrio formado por un conjunto de ácidos orgánicos que provienen directamente de la uva. Estos ácidos incluyen el tartárico, málico, láctico y cítrico que están directamente relacionados con los atributos sensoriales del producto final (Berrazueta y Yanchaguano, 2018). Así también, los compuestos fenólicos son los responsables del amargor y astringencia, dado que afectan la concentración de taninos (Sainz et al., 2022).

Por otro lado, la cantidad de azúcares en un vino depende del índice de maduración y tipo de fruta a utilizarse, puesto que frutas con un índice de maduración alto poseen mayor contenido de azúcares y por otro lado, si es menor el índice el contenido de azúcares es bajo (Chuma, 2018). El pH esta relacionado con la acidez titulable, dado que se requiere que alcance un punto final

especifico con un pH de 7 o 8.2 durante la evaluación de la acidez, proceso que se lleva a cabo mediante pruebas de colorimetría (Sández et al., 2019).

### **1.3 Clasificación de vinos**

La clasificación del vino es muy extensa, sin embargo, existen dos tipos que son más relevantes: según su color y según el contenido de azúcares.

#### ***1.3.1 Según su color***

Con respecto a su color existen vinos: tintos, rosados y blancos. Los vinos tintos son obtenidos del prensando la uva tinta juntamente con los hollejos. Por otro lado, los vinos rosados son resultado de la trituración de uvas seleccionadas con un tiempo de macerado menor, dando un tono rosa claro o violeta. Por último, los vinos blancos se obtienen de uvas blancas y su tonalidad resulta de la ausencia de hollejos durante la fermentación (Vera, s. f.).

#### ***1.3.2 Según el contenido de azúcar***

El contenido de azúcar es un factor relevante en la clasificación de vinos, dado que representa la cantidad de azúcar que permanece en el producto al momento de ser embotellado (Angamarca y Morales, 2011).

Según Idígoras (2011), se puede encontrar los siguientes tipos:

- Vinos secos, los cuales no deben tener más de 5 gramos de azúcar por litro.
- Vinos semisecos, que presentan entre 5 y 15 gramos de azúcar residual por litro.
- Vinos abocados, se ubican en un rango de 15-30 gramos de azúcar residual por litro.
- Vinos semidulces, que presentan de 30-50 gramos de azúcar residual por litro.
- Vinos dulces, que poseen un mínimo de 50 gramos de azúcar residual por litro.

## 1.4 Fermentación del vino

La fermentación alcohólica es una fase crucial, dado que en esta se generan los atributos aromáticos de los vinos mediante compuestos volátiles producidos por la levadura, comúnmente la *Saccharomyces cerevisiae* (Berrazueta y Yanchaguano, 2018). Este proceso implica una serie de reacciones biológicas complejas que realizan las levaduras en ausencia de oxígeno ( $O_2$ ), donde los azúcares del mosto de uva son transformados en alcohol, dióxido de carbono y energía (Buja, 2022).

Una de las desviaciones más significantes en la fermentación del vino son las causadas por el deterioro bacteriano producido en el ambiente de bodega, lo cual contamina el mosto de uva (Angamarca y Morales, 2011). Por esta razón, para obtener etanol como producto final es esencial controlar variables como: temperatura y pH; además debido a las transformaciones químicas producidas en la fermentación se evidencia la presencia de turbidez en los vinos (Chuma, 2018).

## 1.5 Turbidez

Consiste en la falta de transparencia en el vino causada por la presencia de partículas suspendidas originadas durante el proceso de vinificación (Angamarca y Morales, 2011). Estos sólidos suspendidos surgen de los fragmentos de uva o de los productos enológicos empleados, provocando que el producto no quede homogeneizado, por lo cual su calidad podría verse afectada (Peyro, 2019).

Por esta razón, es de gran importancia en los vinos tintos la determinación del umbral teórico de turbidez que es utilizado como unidad auxiliar de la filtración a una longitud de onda de 620 nanómetros (Ibáñez, 2015). En la siguiente tabla 1 se clasifica los distintos tipos de vinos según su umbral teórico de turbidez ( $St$ ) y su adaptación de claridad, en donde las variables representadas son adimensionales.

**Tabla 1***Características de los diferentes tipos de vino basados en el umbral de turbidez teórico*

<b>Características visuales</b>	<b>Vino blanco</b>	<b>Vino rosado 1</b>	<b>Vino rosado 2</b>	<b>Vino tinto</b>
DO 620	0	0.007	0.038	0.056
St	1.4	1.6	2.3	2.7
Brillo	< 1.1	<1.2	< 1.7	< 2.2
Claro	1.1 a 2.2	1.2 a 2.4	1.7 a 3.4	2 a 4
Turbio	> 4.4	> 4.8	> 6.8	> 8

**Nota.** Adaptado de Ibáñez (2015).

En la tabla 1, la densidad óptica (absorbancia) está representada por DO, además se observa que los vinos tintos con una turbidez superior a 8 se denominan turbios, mientras que los que poseen una turbidez inferior a 8 se consideran estables y de calidad, aptos para el consumidor (Ibáñez, 2015).

### **1.5.1 Medición de turbidez**

Existen varios métodos para determinar el valor de la turbidez en un vino, incluidas mediciones visuales y dispositivos de medición a gran escala. Un ejemplo es el disco Secchi, una opción visual ideal para la medición en campo. Sin embargo, cabe recalcar que es un método subjetivo por lo que no es muy recomendable (HANNA instruments, 2022).


Turbidímetro, es utilizado en presencia de varias muestras para medir el grado de difusión lumínica provocada por sólidos suspendidos en unidades de turbidez nefelométrica (NTU) o en unidades de turbidez de formazina (FTU), utilizando un detector de luz y filtros (Serrano, s. f.). Por otro lado, para la medición de soluciones que presentan menor turbiedad se utiliza un instrumento de dispersión luminosa, como es el turbidímetro de Hach o un espectrofotómetro, que determina el valor de la absorbancia (Deloya, 2006).

### 1.5.2 Espectrofotómetro

Es un dispositivo que cuantifica la absorción de luz en una sustancia con relación a una longitud de onda. Donde la fuente de iluminación empleada es una lámpara de tungsteno que proporciona diversas formas de radiación (Molina, 2017), representado en la figura 1.

#### Figura 1

*Esquema general de un espectrofotómetro*



Nota. Adaptado de Molina (2017).

Este equipo impulsa una intensa luz especial que es conducida por medio de un monocromador que selecciona y separa la luz con la onda de longitud deseada. A continuación, esta luz atraviesa la muestra contenida en una celda de plástico hasta llegar al detector que analiza las señales para generar un resultado de absorbancia (Téllez et al., 2020).

### 1.5.3 Absorbancia

Es conocida también como densidad óptica y consiste en la cantidad de luz absorbida por una sustancia (Chuma, 2018). Donde la concentración del absorbente y longitud de peso determinan la intensidad de radiación, relación que se basa en la ley Beer-Lambert, mostrado en la figura 2 (Téllez et al., 2020). Esta puede ser expresada como una fracción molar cuando la sustancia utilizada es líquida en donde su valor depende del material absorbente, pues la ley suele ser inválida para concentraciones muy elevadas y cuando se utiliza un material que dispersa altamente la luz (Romero, 2021).

## Figura 2

*Absorción de un haz atravesado por una muestra en celda de plástico.*



Nota. Adaptado de Absorción de la luz; ley de Beer-Lambert (2021).

En la figura 2,  $I_0$  representa la luminosidad incidente,  $I$  es la luminosidad atravesada,  $l$  simboliza la longitud de celda,  $c$  representa la concentración de soluto y  $\alpha$  es la absorbancia molar (Absorción de la luz; ley de Beer-Lambert, 2021).

Por otro lado, según Ibáñez (2015) la absorbancia es utilizada como medida para la determinación de turbidez en vinos tintos por medio del umbral teórico de turbidez, representado por la ecuación 1.

$$St = (23.4 * A_{620}) + 1.43 \quad (1)$$

Donde:

St: umbral de turbidez teórico

$A_{620}$ : absorbancia a 620 nm para color azul

### 1.6 Clarificación

Consiste en introducir a un vino turbio agentes clarificantes que llevan todas las partículas suspendidas hacia el fondo durante su fabricación (Angamarca y Morales, 2011). Según Vernhet (2019), los clarificantes, compuestos del vino y partículas sobrantes interactúan física y

químicamente durante el proceso de clarificación. Este es realizado con el propósito de asegurar la calidad y cualidades del producto dado que un vino turbio es considerado deficiente y no apto para el consumidor.

### **1.6.1 Tipos de clarificantes**

Los agentes clarificadores son compuestos que en contacto con el vino flocculan las partículas en suspensión provocando su sedimentación de manera que mejoren su claridad y estabilidad colorante coloidal (Vernhet, 2019). Se pueden categorizar según su origen en: animal (albuminas), marino (alginato), mineral (bentonita) y de naturaleza química (anhídrido silícico), mismos que aportan cualidades diferentes a los diversos tipos de vino (Chuma, 2018). Según Quezada et al. (2016) también se pueden utilizar clarificantes naturales como los obtenidos a partir de plantas mucilaginosas, destacando a la Yausabara (*Pavonia sepium*) como la que mejores resultados de turbidez ha presentado.

### **1.7 Yausabara (*Pavonia sepium*)**

Es una planta considerada para muchos agricultores como maleza que alcanza alturas de 1 a 2 metros y se desarrolla en lugares húmedos (Angamarca y Morales, 2011) Generalmente se la encuentra entre los campos agrícolas del norte de Ecuador, específicamente en la ciudad de Ibarra y en el Carchi y debido a su gran contenido en mucílagos y gomas es aplicada en la agroindustria panelera (Quezada et al., 2016).

Como se observa en la figura 3, esta planta posee hojas simples con bordes aserrados, sus flores son de color amarillo con un diámetro de aproximadamente 3 cm. Sus frutos son pequeñas esferas que contienen ganchos lo que hace que sean adheribles a ciertos objetos, específicamente al pelaje o tela (Morejón y Toapanta, 2020).



### Figura 3

*Planta de Yausabara (Pavonia sepium)*



Nota. Adaptado de Quezada et al. (2016).

#### 1.7.1 Usos

Este arbusto es utilizado en la agroindustria como clarificante para jugos y vinos, también en la industria azucarera (Quezada y Gallardo, 2014). Además, algunos estudios han destacado su potencial como planta ornamental con propiedades farmacológicas (Morejón y Toapanta, 2020).

Según Angamarca y Morales (2011) el proceso de preparación de la yausabara como clarificante implica separar las hojas, lavar y pesar los tallos para determinar la cantidad de agua necesaria para extraer el gel; luego los tallos se trituran manualmente y se maceran en una solución que requiere de un litro de agua por cada 2 kg de tallos. La cantidad de solución a añadir es de 500 a 600 ml por cada 20 a 25 litros de vino, lo que respectivamente equivale al 1.5 al 3 % en volumen (Chuma, 2018).

#### 1.8 Bentonita

Es un clarificante de origen mineral que está compuesto por partículas de arcilla con una fuerte capacidad de absorción, lo que permite retener aflatoxinas y sustancias producidas por hongos debido a su carga negativa (Vernhet, 2019). Es muy eficaz para vinos tintos que presentan

problemas de turbidez proteica, por lo cual según estudios se emplean dosis entre 20 a 40 gramos/hl (Berrazueta y Yanchaguano, 2018).

Presenta mayor difusión debido a su bajo costo, su fácil aplicación y notable acción estabilizadora (Dıblan y Özkan, 2021). No obstante, puede afectar negativamente las propiedades sensoriales del vino debido al alto poder de eliminación de sabores y compuestos de sabor, generando de un 3 a 10% de pérdidas del volumen total (Al-Risheq et al., 2022).

## **1.9 Modelo matemático**

Roldán (2019) define a un modelo matemático como una simplificación que representa algunas situaciones u objetos reales que utilizan expresiones matemáticas como: ecuaciones, funciones y fórmulas. Se utilizan para presentar relaciones entre múltiples variables y adaptarse a una extensa diversidad de fenómenos, desde naturales hasta sociales (Orozco, 2019).

### ***1.9.1 Desarrollo de modelos matemáticos***

El desarrollo de un modelo matemático implica un proceso sistemático, riguroso y reproducible para garantizar la eficiencia de los resultados, tanto en términos cualitativos como cuantitativos permitiendo efectuar la experimentación (Maldonado, 2013). Seguidamente, se expone los pasos para la construcción de un modelo:

- Conceptualización: en donde se determina el problema a solucionar y se identifican las variables y relaciones relevantes.
- Elección de variables: se define las variables e incógnitas que representarán el sistema.
- Recopilación de datos: se debe organizar datos de una previa experimentación.
- Construcción del modelo: se expresa las relaciones entre las variables en términos matemáticos y determinar los parámetros y coeficientes de las ecuaciones.

- Validación del modelo, que consiste en comparar las predicciones propuestas del modelo con los datos obtenidos de una experimentación previa (Maldonado, 2013).

## 1.10 Métodos multivariantes

Los métodos multivariantes son técnicas estadísticas utilizadas para analizar simultáneamente la información de múltiples resultados en sujetos u objetos de investigación (Closas et al., 2013). Entre la más sencilla se encuentra la regresión lineal múltiple, pero también en los últimos años han surgido técnicas más avanzadas de inteligencia artificial como las redes neuronales y el aprendizaje mediante regresión.

### 1.10.1 Regresión lineal múltiple

La regresión lineal múltiple (MLR), consiste en un procedimiento estadístico que analiza cómo una variable dependiente está relacionada con varias variables independientes, ya sean métricas o no métricas (Rojo, 2007). Esta técnica permite pronosticar, comparar y evaluar de forma aproximada el comportamiento o estado de modelos explicativos (Closas et al., 2013) utilizando la ecuación 2.

$$Y = b + a_1x_1 + a_2x_2 + \dots + a_kx_k \quad (2)$$

Donde:

Y: corresponde a la variable predictiva o dependiente

$x_1, x_2, x_k$ : representa a las variables independientes

b,  $a_1, a_2, a_k$ : coeficientes estimados del efecto marginal

### 1.10.2 Red Neuronal Artificial (RNA)

Consiste en un conjunto de elementos tecnológicos que con frecuencia intentan simular la función del cerebro humano (MathWorks, 2020a). Estos componentes están altamente interconectados de manera que permiten procesar datos a través de su estado dinámico en reacción

a entradas externas (Chimedza, 2022). Además, tienen la capacidad de aprender, categorizar datos y prever sucesos futuros (Incio et al., 2023).

Según Baykal y Yildirim (2013), la RNA consta de tres capas para su funcionamiento: una capa de entrada, una o varias capas ocultas y una capa de salida. La capa de entrada recibe la información de un archivo y la pasa a la capa oculta que está determinada por los pesos de sus conexiones. Por último, la capa de salida que envía la información fuera de la red (Ruiz, 2021).

Por otro lado, existen dos fases en el modelado de una red neuronal:


- Fase de entrenamiento, que estima los parámetros representativos al modelo de red neuronal con el propósito de reducir el error generado entre la salida real y la predicha.
- Fase de prueba, en la que se realiza un ajuste al modelo mediante un grupo de datos distintos a los del entrenamiento, pero de la misma experimentación (San Miguel, s. f.).

### 1.10.3 Técnica de Neural Net Fitting

Es una técnica utilizada para entrenar la red neuronal modelada (MathWorks, 2020b). Permite crear, seleccionar, visualizar, dividir y relacionar los datos de entrenamiento con los valores obtenidos del error cuadrático medio (Ruiz, 2021). Consta de tres algoritmos: Levenberg-Marquardt, Bayesian Regularization y Scaled Conjugated Gradient (Chimedza, 2022). En la figura 4 se muestra la estructura de una red neuronal.

#### Figura 4

*Estructura de red de aplicación Neural Net Fitting*




Nota. Adaptado de Ruiz (2021).

### 1.10.4 Técnica de Regression Learner

Es una aplicación que sirve para entrenar modelos como: regresión lineal, árboles de regresión, modelos de regresión de procesos gaussianos, aproximación de kernel y modelos de regresión de redes neuronales para predecir datos. Además, examina la información, selecciona las características, define métodos de validación y analiza resultados (MathWorks, 2020c). Para la aplicación de la técnica de Regression Learner, se debe seguir una secuencia de pasos, tal como lo muestra la figura 5.

**Figura 5**

*Diagrama de flujo para entrenar modelos de regresión*



Nota. Tomado de (*App Regression Learner - MATLAB & Simulink - MathWorks América Latina*, s. f.).

Según MathWorks (2020c) el entrenamiento de un modelo con Regression Learner consta de dos fases. La primera un modelo válido que es visible en la aplicación y previene el sobreajuste utilizando un esquema de validación cruzada. La segunda un modelo completo, que incorpora los datos de prueba para su entrenamiento y no se encuentra visible en la aplicación.

### 1.11 Validación cruzada

La validación del modelo se utiliza para evitar el sobre entrenamiento y medir la exactitud de las predicciones permitiendo elegir el modelo más efectivo y adaptable (MathWorks, 2020c). Implica apartar un subconjunto de datos con lo cual se evalúa su capacidad de generalizar eventos futuros (Cuevas et al., 2021).

Según Pérez et al. (2015), la validación cruzada realiza varias veces la repetición del proceso de subdivisión de datos y el error es utilizado como indicador del rendimiento. Este

método divide los datos disponibles en  $k$  subconjuntos elegidos al azar, los cuales son aproximadamente del mismo tamaño (Dahal et al., 2021).

## 1.12 Ajuste del modelo matemático

El ajuste de un modelo determina la configuración óptima de los métodos para un problema (Montero, 2016). Su confiabilidad o representatividad es evaluada mediante indicadores estadísticos como el coeficiente de determinación y el error cuadrático medio (Incio et al., 2023).

### 1.12.1 Coeficiente de determinación

El coeficiente de determinación ( $R^2$ ), es considerado como una medida de la calidad de ajuste realizado (Rojo, 2007). Definido como la proporción (porcentaje si lo multiplica por 100) de la variabilidad de la variable respuesta explicada a través de las variables independientes que han sido evaluadas en el modelo (Montero, 2016), representado por la ecuación 3.

$$R^2 = 1 - \frac{SCE}{SCT} \quad (3)$$

Donde, SCE es la suma de los cuadrados de regresión y SCT representa la suma de los cuadrados total, determinados a través de la ecuación 4 y 5, respectivamente (Render et al., 2012).

$$SCE = \sum (\hat{y} - \bar{y})^2 \quad (4)$$

$$SCT = \sum (y - \bar{y})^2 \quad (5)$$

Donde:

$\hat{y}$ : valor pronosticado de  $y$

$y$ : valor real de  $y$

$\bar{y}$ : media de  $y$

El valor del  $R^2$  oscila entre 0 y 1, siendo 1 la representación del 100%, lo que indica que el modelo planteado representa el ajuste máximo de los datos en el intervalo desarrollado, por ende, se puede para cada modelo comparar los  $R^2$  e identificar cual se ajusta mejor (Montero, 2016).

Sin embargo, en el caso de la regresión lineal múltiple debido al consecuente aumento de una variable se produce una reducción de los grados de libertad, produciendo un sobre ajuste del modelo matemático (Rodríguez, 2021). Por ello, se sugiere corregir este problema mediante el coeficiente de determinación ajustado que se representa en la siguiente ecuación 6.

$$\bar{R}^2 = 1 - \frac{SCE/(n - k)}{SCT/(n - 1)} \quad (6)$$

Donde, n es el total de las observaciones, k el número de las variables utilizadas en el modelo, por otro lado (n-1) son los grados de libertad del modelo y (n-k) corresponde a los grados de libertad de los residuos (Montero, 2016).

### 1.12.2 Error cuadrático medio

Es una métrica de regresión en el aprendizaje automático, esta representa el promedio de la diferencia cuadrática entre los valores observados y los pronosticados. Por consiguiente, el mejor modelo deberá presentar un valor cercano a cero, pero este a su vez no ser negativo (González, 2018). Este indicador estadístico está representado por la ecuación 7.

$$MSE = \frac{\sum(y - \hat{y})^2}{n} \quad (7)$$

Donde:

y: valor real

$\hat{y}$ : valor pronosticado

n: número total de observaciones

## **CAPÍTULO II**

### **METODOLOGÍA**

#### **2.1 Tipo de Investigación**

En esta investigación se abordó un enfoque cuantitativo, el cual consiste en la adquisición y análisis de datos para realizar predicciones. Este enfoque permite encontrar relaciones entre variables dependientes e independientes mediante algoritmos y herramientas matemáticas (Suárez, 2023). Así pues, el dominio y deducción son superiores en comparación con otros métodos de estudio posibilitando la evaluación de hipótesis (Castillero, 2017).

Asimismo, en esta investigación cuantitativa se empleó un diseño experimental no necesariamente tradicional, el cual según Ramos (2021) se basa en la manipulación de variables cualitativas y cuantitativas para identificar su efecto dentro de un estudio. Además del procesamiento de los datos, selección de algoritmos y validación del modelo mediante técnicas específicas.

#### **2.2 Técnicas e instrumentos de investigación**

Para la presente investigación se utilizaron diversas técnicas e instrumentos de estudio. Tales como la compilación y análisis de información que permiten adquirir evidencias para plantear un juicio concreto y adecuado mediante documentos científicos, revistas, tesis, entre otros. Del mismo modo, se implementó un experimento con la finalidad de recopilar datos para su posterior análisis en el software de simulación y modelado matemático Matlab. Finalmente, se realizó una verificación del modelo mediante un enfoque de validación cruzada y retro propagación para obtener una representación adecuada de los fenómenos estudiados.



## 2.3 Caracterización del área de estudio

El componente experimental del presente trabajo se llevó a cabo en tres localizaciones. La primera fue en la provincia de Pichincha en el Cantón Pedro Moncayo en la ciudad de Tabacundo, lugar donde se realizó el vino. La segunda en los laboratorios de la Facultad de Ingeniería en Ciencias Agropecuarias y Ambientales (FICAYA) de la Universidad Técnica del Norte ubicada en la provincia de Imbabura. El proceso de clarificación se desarrolló en el laboratorio de análisis experimental e innovación, mientras que las muestras se cuantificaron en el laboratorio de análisis fisicoquímico para determinar la turbidez final del vino.

## 2.4 Manejo específico del experimento

### 2.4.1 *Elaboración del vino*

El vino fue realizado siguiendo la metodología de Chuma (2018), con uva de la variedad Borgoña (*Vitis lambrusca*) adquirida en el Mercado Mayorista ubicado en la ciudad de Ibarra. La fruta fue clasificada visualmente, lavada con abundante agua y se retiraron los racimos. Luego se realizó un macerado manual para la extracción del mosto, que inicialmente presentaba 13 °Brix. Posteriormente, fue ajustado a 22 °Brix utilizando un refractómetro portátil (Marca Boeco) con una escala de 0-50 °Brix.

La fermentación se efectuó utilizando 11 litros de agua y 4.25 kg de azúcar, tal como indica el programa de vino artesanal, con la adición de 0.2 g/hl de levadura Fermín P21 (*Saccharomyces cerevisiae*) seca activa. Este proceso tuvo lugar en un sistema que impida la entrada de oxígeno y permita la expulsión de CO<sub>2</sub>. Finalmente, el mosto fermentó durante un periodo de 15 días, presentando 9 °Brix y una graduación alcohólica de 12%.

### **2.4.2 Clarificación del vino**

Se realizó un trasiego del vino para eliminar los compuestos sólidos presentes en el fondo del recipiente. Luego se agregó 0.1 g/L de sorbato potásico para detener la fermentación. A continuación, fue transportado a granel en horario matutino hasta el lugar donde se desarrolló el proceso de clarificación para evitar que el producto se exponga a altas temperaturas y modifique sus características organolépticas.

Cada unidad experimental fue de 100 ml de vino turbio contenida en frascos ámbar de 120 ml. Se añadieron agentes clarificantes a cada unidad experimental para obtener 200 datos para modelar el sistema. Siguiendo la metodología de Chuma (2018) la cantidad permitida de gel de yausabara es del 1.5 al 3% (v/v). Por lo tanto, para obtener los primeros 100 datos se empezó a clarificar con una concentración del 1.5% (v/v) y se fue incrementando un 0.015% a cada unidad experimental hasta alcanzar la dosis máxima del 3%.

Así mismo, para la obtención de los 100 datos restantes se utilizó bentonita previamente acondicionada para maximizar su efecto, realizando una solución madre. Se recomienda colocar 1 kg en 10 L de agua a 55 °C para que se remoje e hinche durante 24 horas (Berrazueta y Yanchaguano, 2018). Después de este tiempo se añadió al vino una dosificación del 0.019% hasta 0.038% (v/v), aumentando un 0.0002% en cada unidad experimental hasta llegar al límite de dosificación permitida.

### **2.4.3 Almacenamiento durante fase de experimentación**

Una vez añadidos los clarificantes se dejó reposar las muestras durante 11 días para el vino clarificado con bentonita (Berrazueta y Yanchaguano, 2018) y según Chuma (2018) para la clarificación con yausabara el tiempo de reposo fue de 25 días. El vino fue almacenado en un lugar

fresco y obscuro a temperatura ambiente para evitar la oxidación, pues superior a una temperatura de 24 °C se produce un envejecimiento (Oliveira et al., 2024).

#### **2.4.4 Determinación de turbidez**

Para determinar la turbidez se tomó alícuotas de 2 ml de vino clarificado de cada unidad experimental utilizando una pipeta de 5 ml y luego se transfirieron a tubos de ensayo de plástico con tapón. Estos fueron trasladados al laboratorio de análisis fisicoquímico para su cuantificación. A continuación, se tomó 1 ml con una micropipeta y se colocó en una cubeta de plástico para medir la absorbancia a 620 nanómetros en el espectrofotómetro, estableciendo como blanco agua destilada (Ibáñez, 2015). Finalmente, se calculó el umbral teórico de turbidez mediante la ecuación 1 y se registró cada medición en Excel para desarrollar la base de datos.

### **2.5 Procedimiento y análisis de datos**

En esta investigación se utilizó un conjunto de datos en Excel que contenía los tipos de clarificante y dosis empleada (variables independientes o inputs) y el valor de turbidez (variable dependiente o targets). Los datos fueron analizados visualmente mediante diagramas de caja y bigotes para comprender su distribución y explicar la significancia entre los clarificantes (Dahal et al., 2021). Además, las variables categóricas fueron convertidas en variables ficticias debido al impacto potencial de dicha inconsistencia en las predicciones, como lo menciona Lin et al. (2023) y Rodríguez (2021).

### **2.6 Métodos**

Los datos recopilados fueron almacenados en el software Excel según las necesidades específicas de las diferentes técnicas evaluadas. Luego con el fin de prevenir posibles sesgos y errores se realizó una aleatorización previa a su partición y posterior modelado. Para el enfoque de regresión lineal múltiple y Regression Learner los datos fueron divididos en 70% para

entrenamiento y 30% para validación del modelo en campo incluyendo entradas y salidas (García et al., 2020).

Mientras que para la técnica de Neural Net Fitting fueron divididos en 70% para entrenamiento, 15% para validación y 15% para la prueba realizada por la aplicación (Atecnea, 2020; Jana et al., 2023). La eficacia del modelo desarrollado fue evaluada mediante indicadores estadísticos como el coeficiente de determinación ( $R^2$ ) cercano a uno y el error cuadrático medio (MSE) cercano a cero entre las distintas técnicas objeto de estudio (Lin et al., 2023; MathWorks, 2020c).

### ***2.6.1 Análisis del modelo matemático representativo mediante métodos aproximados***

El desarrollo del modelo matemático mediante métodos aproximados se realizó utilizando el análisis de regresión lineal múltiple (MRL) que está representado por la ecuación 2, descrita en el capítulo anterior. Consiste en una herramienta eficaz para obtener información relevante con un número significativo de datos superior a 100 objetos observados (Closas et al., 2013).

Tras el análisis de datos se obtuvo una tabla generada con el valor de los coeficientes estimados del efecto marginal y el término del intercepto, los cuales fueron reemplazados en la ecuación general de regresión lineal múltiple (Rodríguez, 2021). Además, según lo mencionado por Montero (2016) como consecuencia de la aparición de sobreajuste en el modelo matemático, se evaluó su rendimiento mediante el coeficiente de determinación ajustado.

### ***2.6.2 Análisis de modelos matemáticos representativos mediante Machine learning***

Denominado también aprendizaje automático, es un entorno ideal del ámbito de la inteligencia artificial que desarrolla sistemas para el análisis de datos (Ruiz, 2021). Este enfoque permite producir modelos de manera eficaz y automática, los cuales ofrecen resultados precisos

(Chimedza, 2022). Las técnicas que se utilizaron en esta investigación son: Neural Net Fitting y Regression Learner, las cuales fueron ejecutadas en el software de Matlab

### **Neural Net Fitting**

Esta técnica es diseñada con el software de Matlab con la aplicación Neural Net Fitting que utiliza el mecanismo de Backpropagation (Baykal y Yildirim, 2013). Para su desarrollo se trabajó con los mismos datos experimentales utilizados en la regresión lineal múltiple, pero organizados de diferente manera. Tomando en cuenta que los valores de prueba no presentan ningún efecto durante el entrenamiento del modelo (Orozco, 2019).

Se estableció la arquitectura de la red neuronal tomando como indicio la configuración predeterminada del número de capas ocultas con 10 neuronas. Finalmente, se entrenó la red neuronal con los algoritmos de Levenberg-Marquardt, Bayesian Regularization y Scaled Conjugated Gradient (Chimedza, 2022; Incio et al., 2023). En el entrenamiento de cada uno de estos algoritmos se modificó el número de neuronas aumentando 5 unidades para cada iteración (Ahamad et al., 2019) hasta alcanzar 100 neuronas con lo cual se ha alcanzado un buen porcentaje de error (Bazalar et al., 2013).

### **Regression Learner**

La técnica de Regression Learner entrena varios modelos de regresión para predecir datos futuros permitiendo una exploración simple con la especificación de esquemas de validación y evaluación de modelos representativos (MathWorks, 2020c). Es un aprendiz de regresión que se encuentra dentro de la aplicación de Machine Learning en el software de Matlab (De Porcento et al., 2023). Para evitar el sobreajuste del modelo se utilizó el método de validación cruzada generalmente con 5 pliegues (Dahal et al., 2021; Pérez et al., 2015). El entrenamiento

automatizado se realizó mediante: regresión lineal, árboles de regresión, máquinas de vectores de soporte, modelos de regresión del proceso gaussiano y redes neuronales (García et al., 2020).

### **2.6.3 Validación del modelo matemático**

En el caso de la técnica de MRL y Regression Learner, se determinó el error cuadrático medio (MSE) y el coeficiente de determinación ( $R^2$ ) del modelo exportado con el 30 % de los datos reservados para la validación real. Para dicho procedimiento se utilizó las ecuaciones 7 y 3 respectivamente, como medida de comparación con los datos medidos en campo. Estas métricas fueron calculadas en el software de Excel. Para la validación del modelo seleccionado en la técnica Neural Net Fitting, no se procedió como lo mencionado anteriormente. Dado que tiene la posibilidad de entrenar y validar al mismo tiempo. Por ello, los valores del coeficiente de determinación y error cuadrático medio fueron tomados de la prueba realizada por el programa.

Finalmente, se realizó un análisis de acuerdo con las métricas de entrenamiento y validación presentadas por los modelos seleccionados. Con lo cual se escogió entre todos al que presentó menor valor de MSE y un  $R^2$  lo más cercano a uno (De Porcento et al., 2023). Pues el modelo que se adaptó con esta relación es el que mejor eficacia presenta para la estimación de turbidez en vinos artesanales en la presente investigación.

## CAPÍTULO III

### RESULTADOS Y DISCUSIÓN

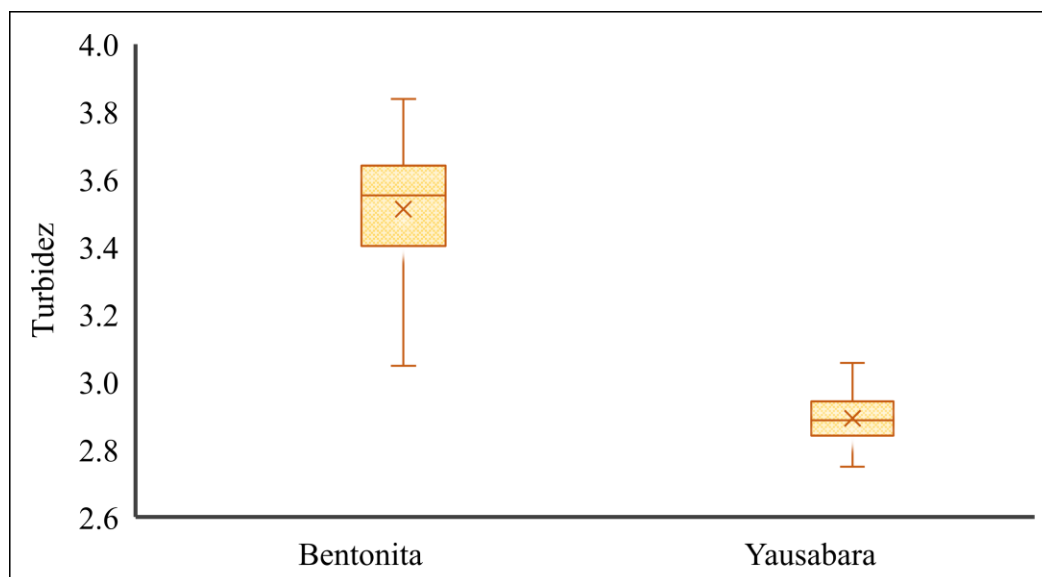
En el presente capítulo se da a conocer de forma detallada los resultados de esta investigación para dar cumplimiento a cada uno de los objetivos planteados.

#### 3.1 Pretratamiento de datos

Los valores de turbidez calculados previamente con la ecuación (1) se encontraron dentro del rango 2.75 hasta 3.84. Además, mediante el análisis de variabilidad se encontró que existe diferencia significativa entre los clarificantes, dado que la bentonita presentó valores de turbidez más altos que la yausabara a pesar de que la gráfica muestra un cruce entre los bigotes (Figura 6). Sin embargo, todos los valores se encontraron dentro de lo reportado por Ibáñez (2015) con respecto al umbral de turbidez teórica, en donde un valor de este parámetro inferior a 8 indica que el vino es estable y claro, por ende, apto para el consumidor.

#### Figura 6

*Diagrama de cajas y bigotes de los valores de turbidez con yausabara y bentonita*



La diferencia de los valores de turbidez obtenidos entre los clarificantes se debe a sus interacciones fisicoquímicas. Dado que la bentonita con una consistencia menos viscosa y con mayor diversidad de minerales, exhibe variadas cargas y puntos isoeléctricos que atraen a las proteínas del vino mediante fuerzas electroestáticas (Dıblan y Özkan, 2021). Mientras que la yausabara presenta una consistencia más viscosa que al entrar en contacto con el vino perturba las fuerzas de atracción entre las partículas, produciendo una sedimentación más efectiva y mejor rendimiento (Quezada y Gallardo, 2014).

### **3.2 Análisis mediante métodos aproximados y Machine Learning de los modelos matemáticos representativos del sistema de estudio**

#### ***3.2.1 Modelo de predicción de turbidez a través de regresión lineal múltiple***

El entrenamiento mediante regresión lineal múltiple permitió la obtención de coeficientes estimados del efecto marginal y el término de intercepto. De esta forma se obtuvo un modelo matemático que predice los datos de turbidez final ( $Y$ ), a través de la ecuación 8. En donde  $X_1$  puede ser remplazado por 1 y 0, correspondiente a yausabara y bentonita, respectivamente. Mientras que la variable  $X_2$  puede ser sustituida por las diferentes dosis de los clarificantes: yausabara (1.5 - 3%) y bentonita (0.0019 - 0.0038%).

$$Y = 3.46 - 0.66 * X_1 + 3.76 * X_2 \quad (8)$$

En la ecuación la variable tipo de clarificante presentó un coeficiente de -0.66 considerado significativo ( $p < 0.01$ ), indicando que en promedio por el tipo de clarificante (yausabara) se espera disminuya un 0.66 el valor de turbidez. Por otro lado, la variable dosis presentó un coeficiente de 3.76 considerado no significativo ( $p = 0.40$ ), el cual muestra un impacto positivo en cuanto al aumento de la variable turbidez y su relación directa con la variable dosis. Asimismo, el término



constante fue de 3.46, valor que toma la variable turbidez cuando todas las variables corresponden a cero (0).

Para este modelo de regresión se alcanzó un p-valor significativo ( $p < 0.01$ ) con un  $\bar{R}^2 = 0.761$  y  $MSE = 0.027$ , indicando que el modelo es capaz de explicar una cantidad sustancial de la variación en la turbidez con respecto a las variables dosis y tipos de clarificantes. Dado que según lo mencionado por Rojo (2007) los valores de  $R^2$  en un rango de 0.5 a 0.85 son considerados bastante buenos para un modelado con regresión lineal. Por lo cual ese podría interpretar que el modelo obtenido es lo suficientemente robusto a pesar del uso de únicamente dos variables de regresión (Sahin et al., 2023).

### ***3.2.2 Modelo de predicción de turbidez a través de Neural Net Fitting***

En el entrenamiento del modelo con la técnica de Neural Net Fitting para pronosticar turbidez en vinos, las lecturas arrojadas de cada corrida por el programa del  $R^2$  y MSE fueron registrados en la Tabla 2. Mostrando que los algoritmos de aprendizaje Levenberg-Marquardt (LM) y Bayesian Regularization (SC) presentaron mejor rendimiento en un promedio de representatividad del 0.96 a diferencia del algoritmo Scaled Conjugated Gradient (SC) que en promedio presentó una representatividad del 0.85 para el sistema de estudio.

Además, tomando en cuenta la maximización del  $R^2$  y el MSE cercano a cero, se seleccionó el mejor modelo. Como se muestra en la tabla 2, es la red neuronal entrenada con el algoritmo Levenberg-Marquardt con 25 neuronas en la capa oculta.

**Tabla 2***Métricas de rendimiento del entrenamiento de los algoritmos de aprendizaje*

Nº neuronas	Levenberg-Marquardt		Bayesian Regularization		Scaled Conjugated Gradient	
	R <sup>2</sup>	MSE	R <sup>2</sup>	MSE	R <sup>2</sup>	MSE
10	0.978	0.005	0.853	0.032	0.876	0.027
15	0.974	0.006	0.866	0.029	0.856	0.031
20	0.984	0.003	0.862	0.031	0.893	0.026
<b>25</b>	<b>0.988</b>	<b>0.003</b>	0.979	0.005	0.834	0.034
30	0.982	0.004	0.980	0.004	0.867	0.035
35	0.949	0.014	0.978	0.005	0.773	0.047
40	0.979	0.006	0.981	0.003	0.856	0.031
45	0.973	0.006	0.971	0.006	0.867	0.031
50	0.982	0.005	0.975	0.006	0.850	0.031
55	0.968	0.007	0.978	0.006	0.886	0.033
60	0.976	0.005	0.978	0.004	0.852	0.036
65	0.897	0.019	0.979	0.003	0.841	0.032
70	0.979	0.007	0.979	0.002	0.867	0.031
75	0.975	0.006	0.983	0.004	0.830	0.038
80	0.957	0.008	0.984	0.003	0.886	0.018
85	0.982	0.004	0.982	0.004	0.789	0.057
90	0.969	0.008	0.982	0.005	0.818	0.048
95	0.941	0.015	0.984	0.003	0.839	0.031
100	0.978	0.006	0.982	0.004	0.835	0.036

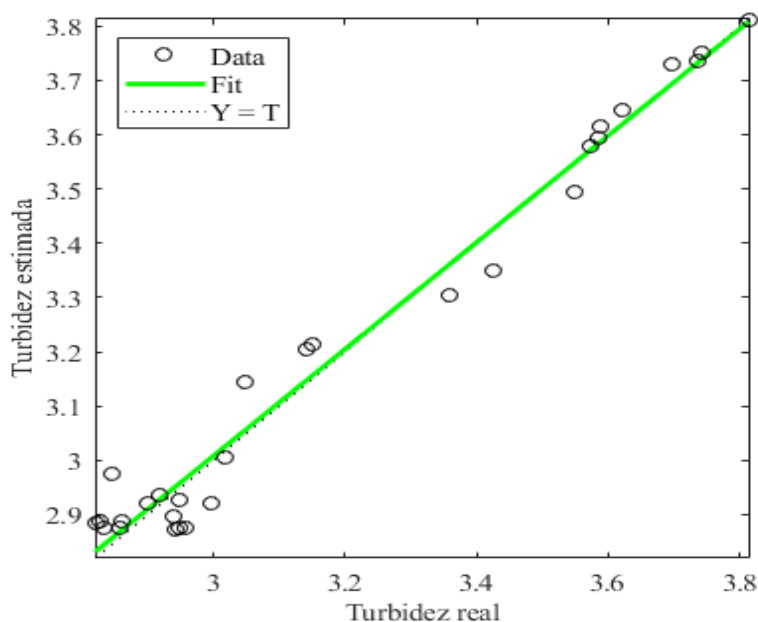
El modelo seleccionado mostró un R<sup>2</sup> de 0.988, valor similar a otras investigaciones que han entrenado redes neuronales con el mismo algoritmo (Ahamad et al., 2019; Bazalar et al., 2013; Hosu et al., 2014), pero en distintas disciplinas. Además, el MSE del modelo es de 0.003, lo que demuestra la viabilidad del proceso de aprendizaje supervisado para estimar la turbidez. Las

métricas presentadas y el algoritmo seleccionado indican que el modelo es bastante robusto, tal como lo afirma Incio et al (2023) y Orozco (2019).

Por otro lado, el algoritmo entrenado Levenberg-Marquardt haya sido el mejor resultado se debe a que este actualiza los valores de peso y sesgo al culminar cada época (MathWorks, 2020b). Además, como combina el método de descenso gradiente y el método de Gauss-Newton se convierte en una herramienta de optimización eficaz con lo cual se reduce la suma de errores al cuadrado (Gavin, 2022). En la figura 7 se muestra la gráfica de rendimiento de regresión lineal de la RNA seleccionada (LM con 25 neuronas), en donde se representan los valores de turbidez predichos por la red con respecto a las respuestas de turbidez reales.

### Figura 7

*Rendimiento del modelo de red neuronal con 25 neuronas en la capa oculta*



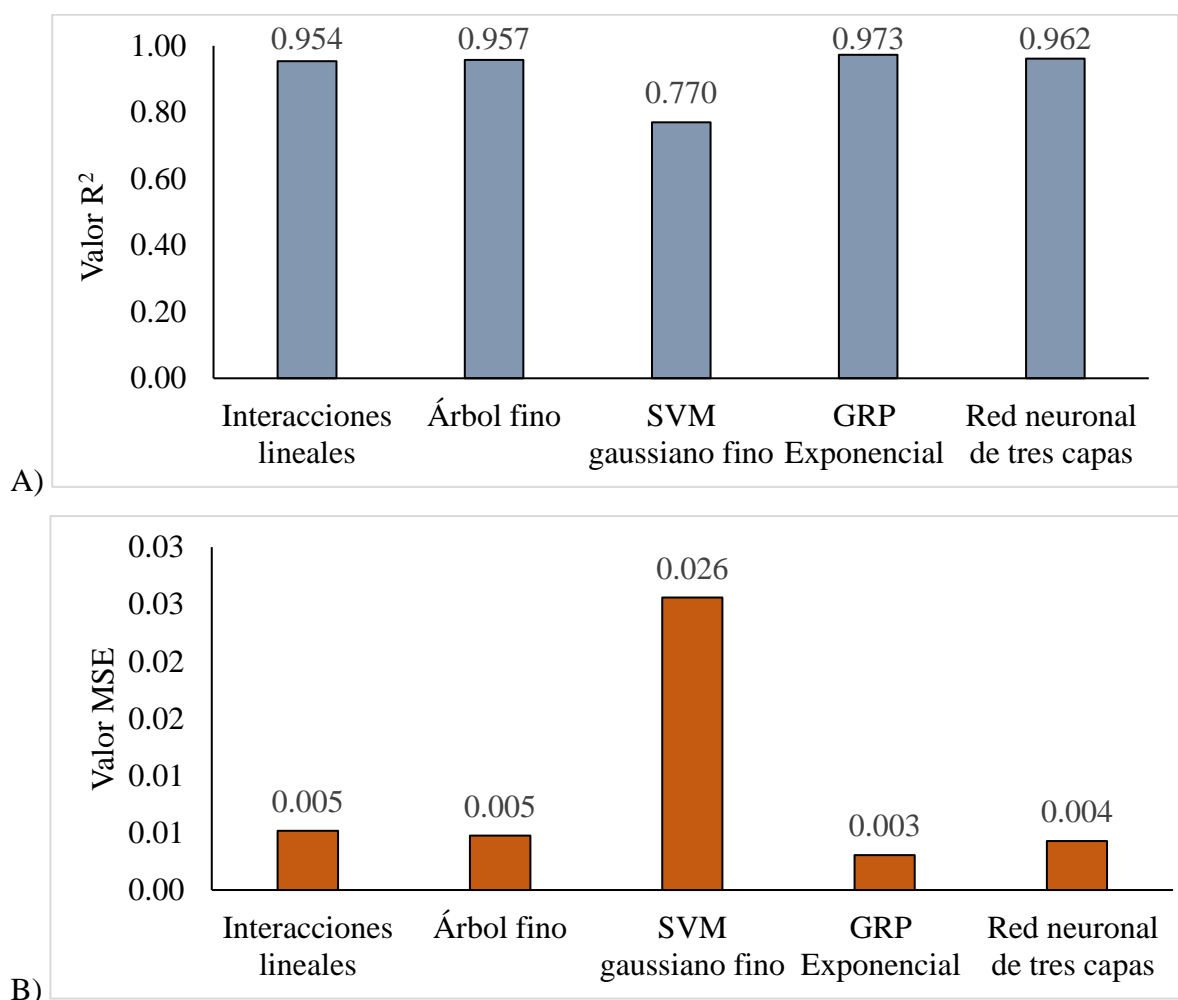
Los valores están dispuestos cerca de la línea de 45 grados. Asimismo, la línea de color se encuentra casi sobre la línea punteada que representa a los valores de salida en una perfecta predicción. Observando un buen ajuste entre los valores predichos y experimentales, según lo mencionado por Ahamad et al. (2019) y Sahin et al. (2023).

### 3.2.3 Modelo de predicción de turbidez a través de Regression Learner

Mediante el enfoque de Regression Learner se entrenaron diferentes modelos de aprendizaje automático para regresión. El desempeño de los modelos con mejor rendimiento (Figura 8) presentaron un  $R^2$  que se encuentra dentro del rango de 0.5 a 1 de representatividad alta (Hernández et al., 2018) para estimar la turbidez del vino antes del embotellamiento.

#### Figura 8

Valores de coeficiente de determinación (A) y cuadrado medio del error (B) de los modelos entrenados con el mejor rendimiento



**Nota:**  $R^2$  (Coeficiente de determinación), MSE (Error cuadrático medio), SVM (Máquinas de vectores de soporte) y GRP (Regresión del proceso gaussiano).

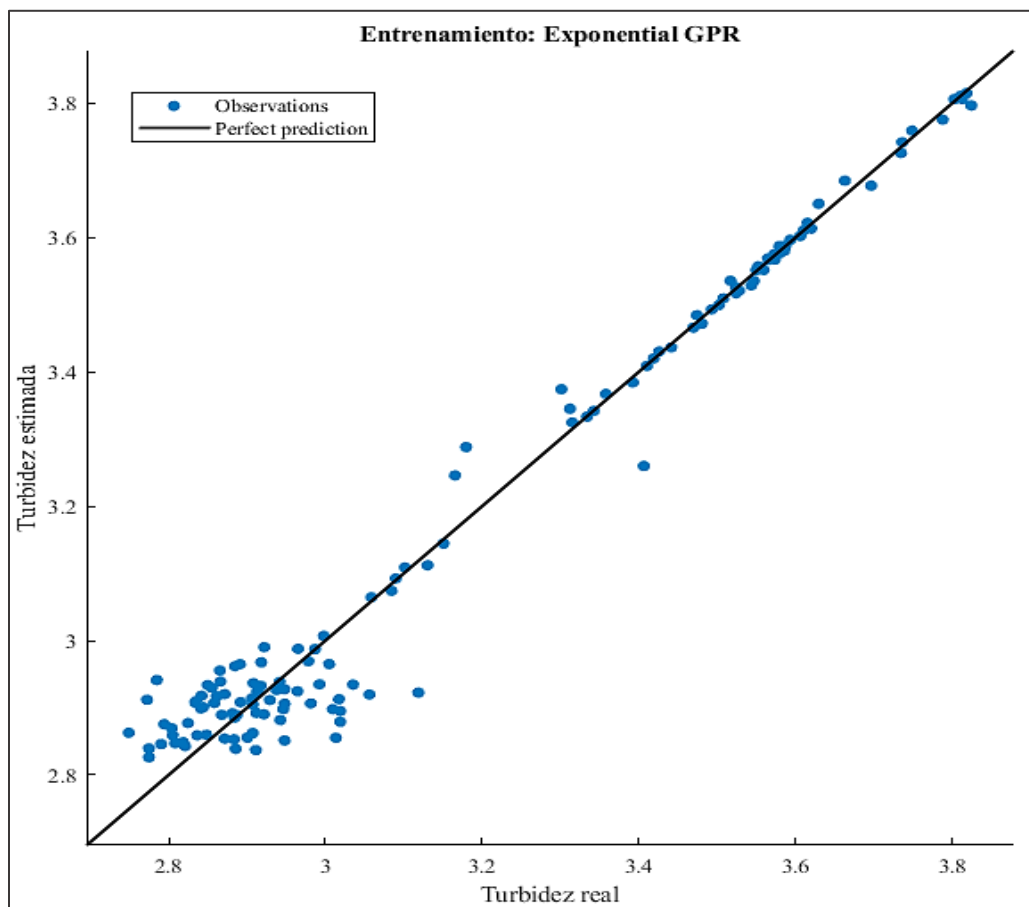
Como resultado se muestra que el modelo de regresión del proceso gaussiano exponencial (GRP) presentó mejores métricas de rendimiento en comparación con los otros modelos, con un  $R^2= 0.973$  y un  $MSE= 0.003$ . Estos valores se asemejan a los encontrados por Cerna et al (2022) que en su investigación entrenaron modelos de procesos gaussianos para predecir residuos sólidos encontrando valores de  $R^2=0.982$  y  $MSE=0.007$ . Los resultados obtenidos se deben a que estos establecen relaciones no lineales entre los datos utilizados en el entrenamiento (dosis y tipo de clarificante) mediante una distribución de probabilidad en un espacio de funciones (MathWorks, 2020c).

Por el contrario, el modelo de máquina de vectores de soporte gaussiano fino (SVM) presentó menor rendimiento con un  $R^2= 0.770$  y un  $MSE= 0.026$  en comparación con los otros modelos. Obteniendo con este modelo valores similares a los encontrados por Dahal et al. (2021) que revelaron un  $R^2= 0.77$  y  $MSE= 0.276$  para predecir la calidad del vino. El rendimiento obtenido en este estudio se debe a que este tipo de modelo no es flexible a cambios bruscos de los datos de turbidez obtenidos asignando los valores no lineales en un espacio superior utilizando la función kernel ( Dahal et al., 2021).

En consecuencia, se corrobora que el modelo de procesos gaussianos representa una buena dispersión de datos (García et al., 2020). Relacionando los valores de turbidez predichos y reales, lo cual se observa de mejor manera en la figura 9.

**Figura 9**

*Regresión de entrenamiento del modelo del proceso gaussiano exponencial para predecir la turbidez*



Se observa que los valores de turbidez predichos están distribuidos simétricamente casi sobre la línea diagonal. Lo que significa que el modelo de aprendizaje automático seleccionado es fiable para hacer estimaciones. Así mismo, la distancia vertical desde cada punto hasta la línea negra muestra su error de predicción (MathWorks, 2020c). Verificando que estos no son tan grandes debido a que el error al estimar la variable turbidez es pequeño.

### 3.3 Validación de los modelos matemáticos seleccionados mediante datos experimentales diferentes a los trabajados en el entrenamiento

Debido a que en el entrenamiento se puede producir un sobreajuste de los modelos exportados, se realizó la validación que determina una confiabilidad óptima. En la validación de los diferentes modelos seleccionados los valores de  $R^2$  y MSE fueron registrados en la tabla 3.

El modelo de regresión lineal múltiple resultó ser menos robusto para este sistema de estudio con un  $R^2= 0.671$ , en comparación con los modelos de red neuronal y GRP exponencial que presentan un  $R^2= 0.985$  y  $R^2= 0.943$ , respectivamente. Sin embargo, muestra una confiabilidad alta (Hernández et al., 2018) para predecir valores de turbidez. Por otro lado, tomando en cuenta al modelo con mejores métricas de validación es el de red neuronal con un coeficiente de determinación superior, además de un error de 0.004 valor inferior en comparación con los otros

**Tabla 3**


*Métricas de validación de los modelos seleccionados en el entrenamiento*

<b>Modelos</b>	<b><math>R^2</math></b>	<b>MSE</b>
Regresión lineal múltiple	0.671	0.042
Red Neuronal	<b>0.985</b>	<b>0.004</b>
GRP exponencial	0.943	0.008

Con el MSE bajo y un  $R^2$  más próximo a uno (1), se puede inferir que la RNA representa un desempeño de pronóstico con alta precisión (Chimedza, 2022). Esto se puede justificar debido a que modela procesos complejos y no lineales basada en un conjunto de datos, usando un elevado aprendizaje auto adaptativo sin requerir de una distribución normal como los métodos convencionales (Tu et al., 2019). Para una mejor evaluación de la validación se muestra la figura 10, en donde están representados las predicciones de turbidez en relación con los valores observados por cada modelo.

**Figura 10**

*Rendimiento de validación de los modelos seleccionados: A) regresión lineal múltiple, B) Red neuronal y C) GRP exponencial*



Una buena confiabilidad del modelo se observa cuando los valores estimados se encuentran sobre la línea diagonal de la gráfica de rendimiento (Tchakala et al., 2023). En la gráfica de la red neuronal todos los datos están dispersos cerca a línea sólida. La red muestra que la línea punteada se alinea casi perfectamente con la línea de color (valor de salida). En la gráfica GRP exponencial los datos dispersos no son tan nítidos como en la red neuronal, debido a que existen puntos alejados



de la línea diagonal. Por último, en la gráfica de regresión lineal múltiple los datos están bastante alejados de la línea diagonal, mostrando que entre la salida y el objetivo no existe ninguna relación cercana. En este sentido el modelo analizado con redes neuronales representa mejores métricas de validación, por lo cual es considerado fiable para el sistema en estudio.

Los resultados presentados llevaron a realizar un análisis comparativo entre las métricas de rendimiento de entrenamiento y validación de los modelos más representativos, mostrados en la tabla 4.

**Tabla 4**

*Comparación entre las métricas de entrenamiento y validación de los modelos seleccionados*

Modelos	Entrenamiento		Validación	
	R <sup>2</sup>	MSE	R <sup>2</sup>	MSE
Regresión lineal múltiple	0.761	0.027	0.671	0.042
Red Neuronal	<b>0.988</b>	<b>0.003</b>	<b>0.985</b>	<b>0.004</b>
GRP exponencial	0.973	0.003	0.943	0.008

En donde el modelo que se adapta a estas condiciones es la red neuronal, presentando el coeficiente de determinación más alto para entrenamiento y validación de los evaluados en la investigación. En cuanto al MSE, de la misma manera el modelo de red neuronal presentó los valores más bajos entre todos los evaluados en esta investigación, lo que indica la bondad del ajuste entre al análisis experimental y los datos predichos por el modelo. Por lo tanto, se puede evidenciar que el modelo entrenado con Neural Net Fitting (Anexo 1) representa de manera eficiente la estimación de turbidez en vinos artesanales.

## CAPÍTULO IV

### CONCLUSIONES Y RECOMENDACIONES

#### 4.2 Conclusiones

- Las diferentes metodologías permitieron la obtención de modelos altamente significativos en el entrenamiento como regresión lineal múltiple ( $R^2=0.761$ ;  $MSE=0.027$ ), red neuronal ( $R^2=0.988$ ;  $MSE=0.003$ ) y regresión del proceso gaussiano exponencial ( $R^2=0.973$ ;  $MSE=0.003$ ), mostrando que con aprendizaje automático se obtienen mejores métricas de rendimiento.
- Una vez realizada la validación de los modelos se verificó que la red neuronal entrenada mediante la técnica de Neural Net Fitting representa el sistema de estudio a través de la prueba con un conjunto de datos reservados, mostrando el mayor coeficiente de determinación y el menor error cuadrático medio.
- Se acepta la hipótesis alternativa, dado que el modelo matemático por red neuronal (RNA) con arquitectura de 2-25-1, entrenada con el algoritmo de Levenberg-Marquart presentó la mayor representatividad en entrenamiento y validación, indicando una alta semejanza entre el modelo y la realidad.

#### 4.3 Recomendaciones

- Desarrollar un modelo que no solo estime la turbidez, sino también para predecir la intensidad de color (IC) en vinos artesanales. Para una evaluación de la influencia de los agentes clarificantes en la cantidad de taninos presentes que desempeñan un papel en la tonalidad del vino durante el proceso de clarificación.

- Realizar estudios similares donde se tome en cuenta otros tipos de vino con diferentes variedades de uva, para ampliar la capacidad de predicción y uso del modelo generado en la industria vinícola artesanal logrando mejorar la calidad del vino.

## REFERENCIAS BIBLIOGRÁFICAS

- Ahamad, M. y Muhammad, F. y Fairul, J. y Muhamad, A. (2019). Optimal Number of Hidden Neuron Identification for Sustainable Manufacturing Application. *International Journal of Recent Technology and Engineering (IJRTE)*, 8(2).  
<https://doi.org/10.35940/ijrte.B2013.078219>
- Al-Risheq, D. I. M. y Shaikh, S. M. R. y Nasser, M. S. y Almomani, F. y Hussein, I. A. y Hassan, M. K. (2022). Enhancing the flocculation of stable bentonite suspension using hybrid system of polyelectrolytes and NADES. *Colloids and Surfaces A: Physicochemical and Engineering Aspects*, 638, 128305. <https://doi.org/10.1016/J.COLSURFA.2022.128305>
- Angamarca, F. H. y Morales, E. (2011). *DETERMINACIÓN DEL MEJOR TIEMPO DE CLARIFICACIÓN UTILIZANDO YAUSABARA (Pavonia sepium) Y SÁBILA (Aloe vera) EN EL VINO ARTESANAL DE UVILLA (Physalis peruviana. L.)* [UNIVERSIDAD TÉCNICA DEL NORTE]. <http://repositorio.utn.edu.ec/handle/123456789/2105>
- App Regression Learner - MATLAB & Simulink - MathWorks América Latina.* (s. f.). Recuperado 15 de agosto de 2022, de <https://la.mathworks.com/help/stats/regression-learner-app.html>
- Araujo, A. (2023). *Análisis de la percepción del consumidor ecuatoriano, sobre el consumo moderado del vino y su incidencia en la salud.*  
<http://repositorio.espe.edu.ec/handle/21000/36503>
- Arrien, I. (2019). *El mercado de vino en Ecuador 2019.*
- Atecnea. (2020). *Tutorial de Machine Learning con Matlab: Regresión (Predecir valor de un Sensor)* . <https://www.youtube.com/watch?v=2eo1Rfk9TAK>

- Baykal, H. y Yildirim, H. K. (2013). Application of Artificial Neural Networks (ANNs) in Wine Technology. *Reviews in Food Science and Nutrition*, 53(5), 415-421. <https://doi.org/10.1080/10408398.2010.540359>
- Bazalar, M. y Tejerina, M. y Paganini, J. y Gonzalez, S. (2013). *Selección de una Arquitectura de Red Neuronal Artificial eficiente para predecir el coeficiente de difusividad másica del aguaymanto (Physalis peruviana L.) deshidratado osmoconvectivamente*. Universidad Nacional de Trujillo.
- Berrazueta, P. J. y Yanchaguano, J. M. (2018). *APLICACIÓN DE TRES AGENTES CLARIFICANTES YAUSA (Abutiloninsigne P.) GELATINA Y BENTONITA PARA CLARIFICAR EL VINO DEUVILLA (Physalis peruviana L.) EN EL EMPRENDIMIENTO DE LAPARROQUIA DE CANCHAGUA” [UNIVERSIDAD TÉCNICA DE COTOPAXI ]*. <http://repositorio.utc.edu.ec/bitstream/27000/8449/1/PC-000461.pdf>
- Buja, L. M. (2022). The history, science, and art of wine and the case for health benefits: perspectives of an oenophilic cardiovascular pathologist. *Cardiovascular Pathology*, 60, 107446. <https://doi.org/10.1016/J.CARPATH.2022.107446>
- Carrión, C. y Barrazueta, S. y Mendoza, G. y Lara, M. (2018). MEJORAMIENTO DE LAS PROPIEDADES FÍSICOQUÍMICAS DEL VINO USANDO DISTINTOS NIVELES DE BENTONITA. *Ciencia Digital*, 2(4.2.), 67-87. <https://doi.org/10.33262/cienciadigital.v2i4.2..202>
- Castillero, O. (2017). *Los 15 tipos de investigación (y características)*. Portal Psicología y Mente. <https://psicologiaymente.com/miscelanea/tipos-de-investigacion>
- Castro, M. R. y Echeagaray, M. E. y Rodríguez, R. A. y Udaquiola, S. M. (2010). Modelado

- estadístico de la producción de vinos tintos finos. *Ingeniería e Investigación*, 30(1), 146-150.  
<https://www.redalyc.org/articulo.oa?id=64312498026>
- Cerna, A. y Rosas, C. y Perales, R. y Ataucusi, P. (2022). Predicción de la generación de residuos sólidos domiciliarios con machine learning en una zona rural de Puno. *TECNIA*, 32(1), 44-52. <https://doi.org/10.21754/tecnia.v32i1.1378>
- Chimedza, K. (2022). *A Neural Network and Regression Analysis Approach for the Analysis of Shock Absorber Spring Deformation*. Universidad de Johannesburg.
- Chuma, W. (2018). “*EVALUACIÓN DEL PROCESO DE CLARIFICACIÓN DE VINO DE UVA, ARTESANAL E INDUSTRIAL, UTILIZANDO LÁTEX DE PAPAYA Papaína Y GELDE YAUSABARA Pavonia sepium*”. Universidad Técnica del Norte.
- Closas, A. H. y Arriola, E. A. y Kuc Zening, C. I. y Amarilla, M. R. y Jovanovich, E. C. (2013). Análisis multivariante, conceptos y aplicaciones en Psicología Educativa y Psicometría. *Enfoques*, 25(1), 65-92. [http://www.scielo.org.ar/scielo.php?script=sci\\_arttext&pid=S1669-27212013000100005&lng=es&nrm=iso&tlng=es](http://www.scielo.org.ar/scielo.php?script=sci_arttext&pid=S1669-27212013000100005&lng=es&nrm=iso&tlng=es)
- Cuevas, E. y Avalos, O. y Díaz, P. y Valdivia, A. y Pérez, M. (2021). *Introducción al Machine Learning con MATLAB*.
- Dahal, K. R. y Dahal, J. N. y Banjade, H. y Gaire, S. (2021). Prediction of Wine Quality Using Machine Learning Algorithms. *Open Journal of Statistics*, 11(02), 278-289. <https://doi.org/10.4236/ojs.2021.112015>
- De Porcento, J. y Mendaros, Y. y Moral, R. M. y Cortes, E. P. (2023). Enhanced Power Demand Forecasting Accuracy in Heavy Industries Using Regression Learner-based Approched

- Machine Learning Model. *ARTICLE*, 1(2), 4-12. <https://doi.org/10.5281/zenodo.8164764>
- Deloya, A. (2006). Métodos de análisis físicos y espectrofométricos para el análisis de aguas residuales | Revista Tecnología en Marcha. *Revista Tecnología En Marcha*, 19(2), 31. [https://revistas.tec.ac.cr/index.php/tec\\_marcha/article/view/30](https://revistas.tec.ac.cr/index.php/tec_marcha/article/view/30)
- Dıblan, S. y Özkan, M. (2021). Effects of various clarification treatments on anthocyanins, color, phenolics and antioxidant activity of red grape juice. *Food Chemistry*, 352(129321). <https://doi.org/10.1016/j.foodchem.2021.129321>
- Gadvay, E. (2015). *ELABORACIÓN Y CARACTERIZACIÓN DE VINO DE ARAZA (Eugenia stipitata) UTILIZANDO ENZIMAS PROTEOLITICAS (PAPAINA) COMO AGENTE CLARIFICANTE* [Universidad Técnica de Machala]. <http://repositorio.utmachala.edu.ec/bitstream/48000/4227/1/CD000030-TRABAJO COMPLETO-pdf>
- García, J. J. y Zambrano, J. J. y Alcivar, R. y Zambrano, W. D. (2020). Predicción del rendimiento de cultivos agrícolas usando aprendizaje automático. *Revista Arbitrada Interdisciplinaria Koinonía*, 5(2), 144. <https://doi.org/10.35381/r.k.v5i2.1013>
- Gavin, H. P. (2022). *The Levenberg-Marquardt algorithm for nonlinear least squares curve-fitting problems*.
- Gonzáles, L. (2018). *Evaluando el error en los modelos de regresión. Aprende IA*. <https://aprendeia.com/evaluando-el-error-en-los-modelos-de-regresion/>
- HANNA instruments. (2022). *La guía completa para la medición de turbidez en el agua*. <https://hannainst.com.mx/blog/la-guia-completa-para-la-medicion-de-turbidez-en-el->

agua

- Hernández, D. y Espinosa, J. y Peñaloza, M. y Rodríguez, J. y Chacón, J. y Toloza, C. y Arenas, M. y Carrillo, S. y Bermúdez, V. (2018). Sobre el uso adecuado del coeficiente de correlación de Pearson: definición, propiedades y suposiciones. *Revista Archivos Venezolanos de Farmacología y Terapéutica*, 37(5). <https://orcid.org/0000-0003->
- Hosu, A. y Cristea, V. M. y Cimpoi, C. (2014). Analysis of total phenolic, flavonoids, anthocyanins and tannins content in Romanian red wines: Prediction of antioxidant activities and classification of wines using artificial neural networks. *Food Chemistry*, 150, 113-118. <https://doi.org/10.1016/j.foodchem.2013.10.153>
- Ibáñez, J. (2015). *La medida de turbidez como elemento auxiliar de la filtración - Dialnet*. 36-41.
- Idígoras, J. (2011). *CURSO SOBRE VINO*. <https://frutales.files.wordpress.com/2011/01/vi-07-curso-sobre-vino.pdf>
- Incio, F. y Capuñay, D. y Estela, R. (2023). Artificial Neural Network Model to Predict Academic Results in Mathematics II. *Revista Electronica Educare*, 27(1). <https://doi.org/10.15359/ree.27-1.14516>
- INEC. (2018). *Encuesta Estructural Empresarial 2018*. <https://www.ecuadorencifras.gob.ec/encuesta-estructural-empresarial-2018/>
- Jana, D. y Bhunia, P. y Adhikary, S. Das y Mishra, A. (2023). Analyzing of salient features and classification of wine type based on quality through various neural network and support vector machine classifiers. *Results in Control and Optimization*, 11, 100219. <https://doi.org/10.1016/J.RICO.2023.100219>



Lin, S. y Kim, J. y Hua, C. y Kang, S. y Park, M. H. (2023). Comparing artificial and deep neural network models for prediction of coagulant amount and settled water turbidity: Lessons learned from big data in water treatment operations. *Journal of Water Process Engineering*, 54. <https://doi.org/10.1016/j.jwpe.2023.103949>

Maldonado, L. (2013). *El modelamiento matemático en la formación del ingeniero* (Grupos de Investigación (Ed.)).

MathWorks. (2020a). *¿Qué es una red neuronal? - MATLAB & Simulink*. <https://la.mathworks.com/discovery/neural-network.html>

MathWorks. (2020b). *Ajustar datos con la app Neural Net Fitting - MATLAB & Simulink - MathWorks América Latina*.

MathWorks. (2020c). *Entrene modelos de regresión en la aplicación Regression Learner - MATLAB & Simulink - MathWorks América Latina*. <https://la.mathworks.com/help/stats/train-regression-models-in-regression-learner-app.html>

Molina, D. (2017). *Diseño y construcción de un prototipo de un Espectrofotómetro*. Universidad Central del Ecuador.

Montero, R. (2016). *Modelos de regresión lineal múltiple*. [https://www.ugr.es/~montero/maticas/regresion\\_lineal.pdf](https://www.ugr.es/~montero/maticas/regresion_lineal.pdf)

Morejón, J. y Toapanta, D. (2020). *DETERMINACIÓN DEL PERFIL FITOQUÍMICO Y REOLÓGICO DE PLANTAS MUCILAGINOSAS DE LOS ANDES ANDINOS: YAUSABARA (*Pavonia sepium*) y CUCARDA (*Hibiscus rosa sinensis*)* [Universidad Técnica de Cotopaxi]. <http://repositorio.utc.edu.ec/bitstream/27000/6695/1/PC-000874.pdf>

- Oliveira, J. B. de y Fialho, F. B. y Laureano, O. y de Castro, R. y Pereira, G. E. y Ricardo-da-Silva, J. M. (2024). Impact of aging on the physical-chemical and phenolic stability of tropical red wines from Brazil produced with grapes harvested in the summer season. *Journal of Food Composition and Analysis*, 125. <https://doi.org/10.1016/j.jfca.2023.105794>
- Orozco, B. (2019). *MODELADO Y SIMULACIÓN DE UN SISTEMA DE DESTILACIÓN BINARIA BENCENO-TOLUENO PARA LA PREDICCIÓN DE LA COMPOSICIÓN DE LOS PRODUCTOS MEDIANTE REDES NEURONALES ARTIFICIALES*. Escuela Superior Politécnica de Chimborazo.
- Pérez, P. y Delegido, J. y Rivera, J. y Verrelst, J. (2015). Análisis de métodos de validación cruzada para la obtención robusta de parámetros biofísicos . *Revista de Teledetección* , 44, 55-65. <https://doi.org/10.4995/raet.2015.4153>
- Peyro, G. (2019). *Estabilidad proteica y clarificación del vino*. <https://www.verema.com/blog/verema/1504305-estabilidad-proteica-clarificacion-vino>
- Quezada, W. y Gallardo, I. (2014). Obtención de extractos de plantas mucilaginosas para la clarificación de jugos de caña Obtainment of Mucilaginous Plant Extrax for Clarification of Cane Juice. *Tecnología Química*, 34(2), 91-98. <http://www.redalyc.org/articulo.oa?id=445543782001>
- Quezada, W. y Gallardo, I. y Quezada, D. (2016). Plantas mucilaginosas en la clarificación del jugo de la caña de azúcar. *Centro Azúcar*, 42(2). [http://scielo.sld.cu/scielo.php?script=sci\\_arttext&pid=S2223-48612016000200001](http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S2223-48612016000200001)
- Ramos, C. (2021). Diseños de investigación experimental. *CienciAmérica*, 10(1), 1-7. <https://doi.org/10.33210/ca.v10i1.356>

- Render, B. y Stair, R. y Hanna, M. (2012). *Métodos cuantitativos para los negocios* (Undécima edición). <https://ucreeanop.com/wp-content/uploads/2020/08/Métodos-Render.pdf>
- Reyes, D. y Rojas, K. (2018). *PLAN DE NEGOCIO PARA LA PRODUCCIÓN Y COMERCIALIZACIÓN DEL VINO DE CARAMBOLA* [Universidad de Guayaquil]. <http://repositorio.ug.edu.ec/bitstream/redug/34511/1/BINGQ-ISCE-18P04.pdf>
- Rodríguez, D. (2021). *REGRESIÓN LINEAL MÚLTIPLE* - *YouTube*. <https://www.youtube.com/watch?v=MMhQS9-tMLg>
- Rojo, J. (2007). *Regresión lineal múltiple*. [http://humanidades.cchs.csic.es/cchs/web\\_UAE/tutoriales/PDF/Regresion\\_lineal\\_multiple\\_3.pdf](http://humanidades.cchs.csic.es/cchs/web_UAE/tutoriales/PDF/Regresion_lineal_multiple_3.pdf)
- Roldán, P. (2019). *Modelo matemático*. <https://economipedia.com/definiciones/modelo-matematico.html>
- Romero, I. (2021). *Ley de Lambert-Beer*. <https://www.studocu.com/es-mx/document/tecnologico-de-estudios-superiores-de-ecatepec/microbiologia-general/ley-de-lambert-beer/46582695>
- Ruiz, C. (2021). *Eficiencia del Deep Learning para el modelado de la fuerza de reacción durante la marcha* [Universidad de Sevilla]. <https://idus.us.es/bitstream/handle/11441/126353/TFG-3587-RUIZ MAYO.pdf?sequence=1&isAllowed=y>
- Sahin, G. y Isik, G. y van Sark, W. G. J. H. M. (2023). Predictive modeling of PV solar power plant efficiency considering weather conditions: A comparative analysis of artificial neural networks and multiple linear regression. *Energy Reports*, 10, 2837-2849. <https://doi.org/10.1016/J.EGYR.2023.09.097>

- Sainz, F. y Pardo, J. y Ruiz, A. y Expósito, D. y Armero, R. y Querol, A. y Guillamón, J. M. (2022). Use of non-conventional yeasts to increase total acidity in the Cava base wines. *LWT*, 158, 113183. <https://doi.org/10.1016/J.LWT.2022.113183>
- San Miguel, J. (s. f.). *DESARROLLO CON MATLAB DE UNA RED NEURONAL PARA ESTIMAR LA DEMANDA DE ENERGÍA ELÉCTRICA*. Universidad de Valladolid.
- Sández, N. y Calvo-López, A. y Vidigal, S. S. M. P. y Rangel, A. O. S. S. y Alonso-Chamarro, J. (2019). Automated analytical microsystem for the spectrophotometric monitoring of titratable acidity in white, rosé and red wines. *Analytica Chimica Acta*, 1091, 50-58. <https://doi.org/10.1016/J.ACA.2019.09.052>
- Serrano, J. (s. f.). *Medición de turbidez en vinos para el embotellado*. HANNA Instruments Bolivia. Recuperado 4 de agosto de 2022, de <https://www.hannabolivia.com/blog/post/473/medicion-turbidez-en-vinos-para-el-embotellado>
- Suárez, E. (2023). *Tipos de investigación y su clasificación*. Experto Universitario. <https://expertouniversitario.es/blog/tipos-de-investigacion/>
- Tchakala, M. y Tafticht, T. y Rahman, M. J. (2023). *An Efficient Approach for Short-Term Load Forecasting Using the Regression Learner Application*. 31-34. <https://doi.org/10.1109/CGEE59468.2023.10351847>
- Téllez, M. O. y Domínguez, R. D. y González Ch Rev Aidee Vega Ramiro Domínguez, E. (2020). *Práctica 7 CONOCIMIENTO DE TÉCNICAS ANALÍTICAS PARTE I: FUNDAMENTOS DE ESPECTROFOTOMETRÍA*.

Tu, J. y Wei, X. y Huang, B. y Fan, H. y Jian, M. y Li, W. (2019). Improvement of sap flow estimation by including phenological index and time-lag effect in back-propagation neural network models. *Agricultural and Forest Meteorology*, 276-277. <https://doi.org/10.1016/j.agrformet.2019.06.007>

Vera, S. (s. f.). *Guía sobre tipos de vino: características y variaciones* / Aprende Institute. Recuperado 9 de agosto de 2022, de <https://aprende.com/blog/gastronomia/vinos/tipos-de-vino/>

Vernhet, A. (2019). Red Wine Clarification and Stabilization. *Red Wine Technology*, 237-251. <https://doi.org/10.1016/B978-0-12-814399-5.00016-5>

# ANEXOS

## Anexo 1

### *Modelo de red neuronal*

```

function [y1] = redneuronaltesis(x1)
%REDNEURONALTESIS neural network simulation function.
%
% Auto-generated by MATLAB, 03-Nov-2023 15:35:43.
%
% [y1] = redneuronaltesis(x1) takes these arguments:
%   x = Qx2 matrix, input #1
% and returns:
%   y = Qx1 matrix, output #1
% where Q is the number of samples.

%#ok<*RPMT0>

% ===== NEURAL NETWORK CONSTANTS =====

% Input 1
x1_step1.xoffset = [0;0.000191];
x1_step1.gain = [2;67.0938307222651];
x1_step1.ymin = -1;

% Layer 1
b1 = [-7.3686939706552347928;-6.8806368619490054783;-
5.6304918873328944073;5.3354136500197286708;-4.3491527140902110915;-
7.4411918719721672488;3.5257995656586329503;2.9161002297002824868;1.648264571
4484254196;-1.7499966802241704311;-1.6568173182412699873;-
0.74775551971856457634;0.2516192229019130755;-
0.56356233451804371715;1.166700547669971666;-2.0324641245763892528;-
2.2753506804442369393;1.6319058687141509978;-
3.5003147384491337668;3.9739897054203425775;4.6668513910647142495;-
2.9612801233444634441;-4.3353351585981174665;-6.4051493603888509654;-
6.697323239089285174];
IW1_1 = [6.0131603279879115576 3.0993283450753961183;4.501667562094369579
5.0001434854742923264;7.1749175050285147748 -0.68184690712486883957;-
4.6943019482215007088 -6.0358589364394381604;7.1605881179782180368 -
1.0485299908938425784;5.0541904579805505549 -4.0866462118491506672;-
5.0678487762684767404 -4.8082563530775637162;-6.4601483747759340659 -
2.6970571493911932315;-1.7107047898152174525
7.3338532401956344486;6.9217959371960882109
1.0434523097964376603;4.9619605020975132703 -
6.9289809489566565048;0.6770253435302667766
7.388864657938826852;3.1172287278614794204 -
6.9791924035454950825;6.6935692112701410394
2.0873323722596945906;5.1473393725003226962 4.7439564590902678631;-
2.3708549813842672016 6.5663831691285610148;-4.4572858839684990073
5.4246206925291415857;6.7880722918590601367 -5.3266434105709272728;-
4.3700433602303094816 -5.467806199182907001;3.7433967259495313229 -
5.9639882507793728905;4.5255555959096529506 -5.3400356380555979996;-
8.5795634927950921167 5.8878183932502334841;-8.429632667480047914
4.0242000469791525674;-6.1892722320924553614 3.2820677440119152557;-
2.9767505463404431154 -6.7448988512269894002];

```

```

% Layer 2
b2 = -0.04349277276376293383;
LW2_1 = [1.232832242786523258 1.5870981966973090049 -1.3937343130937260849
1.8415167124997995352 -0.47322454919599549195 5.419756611659493295
0.56626850657801608424 0.84367177018499839303 1.0072722044675692654 -
0.63820797563552755793 4.96618343726464051 1.0977357261614273387 -
3.2952230040871972605 2.1332737273850792548 -1.960208977428516075 -
0.59718761163797817737 0.49417926968304110025 4.3100895882731737885
1.5458278626087498253 -0.86336750277990426117 0.13806329303025649535 -
6.1928351033378721269 -4.5292248122053511139 0.092899435221801621165
0.5042350036238657518];

% Output 1
y1_step1.ymin = -1;
y1_step1.gain = 1.83674968775255;
y1_step1.xoffset = 2.74898;

% ===== SIMULATION =====

% Dimensions
Q = size(x1,1); % samples

% Input 1
x1 = x1';
xp1 = mapminmax_apply(x1,x1_step1);

% Layer 1
a1 = tansig_apply(repmat(b1,1,Q) + IW1_1*xp1);

% Layer 2
a2 = repmat(b2,1,Q) + LW2_1*a1;

% Output 1
y1 = mapminmax_reverse(a2,y1_step1);
y1 = y1';
end

% ===== MODULE FUNCTIONS =====
% Map Minimum and Maximum Input Processing Function
function y = mapminmax_apply(x,settings)
y = bsxfun(@minus,x,settings.xoffset);
y = bsxfun(@times,y,settings.gain);
y = bsxfun(@plus,y,settings.ymin);
end

% Sigmoid Symmetric Transfer Function
function a = tansig_apply(n,~)
a = 2 ./ (1 + exp(-2*n)) - 1;
end

% Map Minimum and Maximum Output Reverse-Processing Function
function x = mapminmax_reverse(y,settings)
x = bsxfun(@minus,y,settings.ymin);
x = bsxfun(@rdivide,x,settings.gain);
x = bsxfun(@plus,x,settings.xoffset);
end

```