



ESCUELA SUPERIOR POLITÉCNICA DE CHIMBORAZO
FACULTAD DE CIENCIAS
CARRERA INGENIERÍA QUÍMICA

**APLICACIÓN DE UN MODELO DE REDES NEURONALES
ARTIFICIALES (RNA) PARA LA DOSIFICACIÓN ADECUADA DE
LOS COLORES EN TEXTILES DE LA EMPRESA PROLAVTEX**

Trabajo de Integración Curricular

Tipo: Proyecto Técnico

Presentado para optar al grado académico de:

INGENIERA QUÍMICA

AUTORA:

LISBETH PAMELA OCAÑA GUERRA

Riobamba – Ecuador

2024



ESCUELA SUPERIOR POLITÉCNICA DE CHIMBORAZO
FACULTAD DE CIENCIAS
CARRERA INGENIERÍA QUÍMICA

**APLICACIÓN DE UN MODELO DE REDES NEURONALES
ARTIFICIALES (RNA) PARA LA DOSIFICACIÓN ADECUADA DE
LOS COLORES EN TEXTILES DE LA EMPRESA PROLAVTEX**

Trabajo de Integración Curricular

Tipo: Proyecto Técnico

Presentado para optar al grado académico de:

INGENIERA QUÍMICA

AUTORA: LISBETH PAMELA OCAÑA GUERRA

DIRECTOR: Ing. DARÍO FERNANDO GUAMÁN LOZADA

Riobamba – Ecuador

2024

© 2024, **Lisbeth Pamela Ocaña Guerra**

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

Yo, Lisbeth Pamela Ocaña Guerra, declaro que el presente Trabajo de Integración Curricular 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 autora asumo la responsabilidad legal y académica de los contenidos de este Trabajo de Integración Curricular; el patrimonio intelectual pertenece a la Escuela Superior Politécnica de Chimborazo.

Riobamba, 11 de junio de 2024.

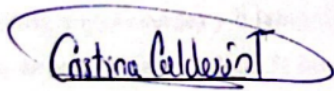

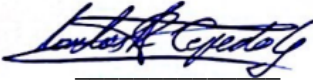


Lisbeth Pamela Ocaña Guerra

0504851718

ESCUELA SUPERIOR POLITÉCNICA DE CHIMBORAZO
FACULTAD DE CIENCIAS
CARRERA INGENIERÍA QUÍMICA

El Tribunal del Trabajo de Integración Curricular certifica que: El Trabajo de Integración Curricular; tipo: Proyecto Técnico, **APLICACIÓN DE UN MODELO DE REDES NEURONALES ARTIFICIALES (RNA) PARA LA DOSIFICACIÓN ADECUADA DE LOS COLORES EN TEXTILES DE LA EMPRESA PROLAVTEX**, realizado por la señorita: **OCAÑA GUERRA LISBETH PAMELA**, ha sido minuciosamente revisado por los Miembros del Tribunal del Trabajo de Integración Curricular, el mismo que cumple con los requisitos científicos, técnicos, legales, en tal virtud el Tribunal Autoriza su presentación.

	FIRMA	FECHA
Ing. Cristina Gabriela Calderón Tapia PRESIDENTE DEL TRIBUNAL		2024-06-11
Ing. Darío Fernando Guamán Lozada DIRECTOR DEL TRABAJO DE INTEGRACIÓN CURRICULAR		2024-06-11
Ing. Carlos Ramiro Cepeda Godoy ASESOR DEL TRABAJO DE INTEGRACIÓN CURRICULAR		2024-06-11

DEDICATORIA

El amor y las constantes noches de desvelo para cumplir este gran sueño se los dedico al amor de mi vida, a mi amado Luis Adrián. Su constante compañía, paciencia y comprensión me han dado la fuerza para superar cada desafío. Gracias por estar siempre a mi lado, por soñar conmigo y por construir nuestro futuro junto a mí. A mi pequeña y adorada Lizy Pamela, mi mascota, cuya alegría y cariño incondicional han llenado mis días de mucha felicidad y paz. Este logro es solo el comienzo de todo lo que construiremos juntos.

Lisbeth Pamela

AGRADECIMIENTO

Quiero expresar mi total gratitud por acompañarme durante todo este proceso a las personas más importantes en mi vida: a mis padres, Lizandra Pamela y Joselito Orlando, fuente de inspiración para convertirme en una mujer con principios y valores. A mi madre, por enseñarme a luchar por lo que realmente me apasiona. A mi padre, por guiarme por el camino de la responsabilidad y el respeto. Y, sobre todo, a mi hermano por cuidarme y ser el motor que me impulsa a seguir día a día luchando por mis sueños.

Lisbeth Pamela

ÍNDICE DE CONTENIDO

ÍNDICE DE TABLAS.....	X
ÍNDICE DE ILUSTRACIONES.....	XI
ÍNDICE DE ANEXOS.....	XII
RESUMEN.....	XIII
ABSTRACT.....	XIV
INTRODUCCIÓN.....	1

CAPÍTULO I

1. DIAGNÓSTICO DEL PROBLEMA.....	2
1.1. Planteamiento del problema.....	2
1.2. Justificación.....	3
1.3. Objetivos.....	3
1.3.1. <i>Objetivo general</i>	4
1.3.2. <i>Objetivos específicos</i>	4

CAPÍTULO II

2. MARCO TEÓRICO.....	5
2.1. Antecedentes de la investigación.....	5
2.1.1. <i>Técnicas de coloración de textiles</i>	5
2.1.2. <i>Uso de RNA como herramienta de optimización de procesos</i>	6
2.1.3. <i>Modelos de RNA aplicados en la industria textil</i>	7
2.2. Referencias teóricas.....	9
2.2.1. <i>Coloración de textiles</i>	9
2.2.1.1. <i>Colorantes reactivos</i>	9
2.2.1.2. <i>Proceso de tintura</i>	12
2.2.1.3. <i>Parámetros de control del proceso de tintura</i>	13
2.2.1.4. <i>Formulación de la receta de tintura</i>	14
2.2.1.5. <i>Control de calidad</i>	15
2.2.2. <i>Redes neuronales artificiales</i>	16
2.2.2.1. <i>Introducción</i>	16
2.2.2.2. <i>Arquitectura de una RNA</i>	17

2.2.2.3.	<i>Clasificación de RNA</i>	18
2.2.2.4.	<i>Proceso de aprendizaje</i>	18
2.2.2.5.	<i>Modelo matemático</i>	20
2.2.2.6.	<i>MATLAB®</i>	21

CAPÍTULO III

3.	MARCO METODOLÓGICO	24
3.1.	Metodología del proyecto	24
3.2.	Obtención de datos experimentales	25
3.2.1.	<i>Descripción del proceso</i>	28
3.2.1.1.	<i>Descrude</i>	29
3.2.1.2.	<i>Tintura</i>	30
3.2.1.3.	<i>Enjabonado</i>	31
3.2.1.4.	<i>Suavizado</i>	32
3.2.2.	<i>Medición del color</i>	33
3.3.	Procesamiento de datos	34
3.4.	Diseño de la RNA en MATLAB	44
3.5.	Entrenamiento de datos	45
3.6.	Validación de resultados de la RNA	48
3.7.	Análisis estadístico	49

CAPÍTULO IV

4.	RESULTADOS	51
4.1.	Informe de resultados del proceso de tintura	51
4.1.1.	<i>Variables del proceso</i>	51
4.1.2.	<i>Muestras experimentales</i>	52
4.2.	Resultados de la red neuronal artificial (RNA)	53
4.2.1.	<i>Arquitectura de la RNA</i>	53
4.2.2.	<i>Comportamiento de la RNA</i>	54
4.2.3.	<i>Código de programación de la RNA</i>	57
4.2.4.	<i>Comparación entre los datos de la RNA y los datos experimentales</i>	57
4.2.4.1.	<i>RNA vs valores de entrenamiento</i>	58
4.2.4.2.	<i>RNA vs datos externos</i>	67
4.2.5.	<i>Análisis estadístico</i>	71

CONCLUSIONES
RECOMENDACIONES
BIBLIOGRAFÍA
ANEXOS

ÍNDICE DE TABLAS

Tabla 3-1: Parámetros de funcionamiento del proceso de tintura.....	26
Tabla 3-2: Clasificación de tintura de acuerdo a su uso.....	28
Tabla 3-3: Formulaciones de color utilizadas para las pruebas	28
Tabla 3-4: Parámetros de entrada de la RNA.....	35
Tabla 3-5: Parámetros de salida de la RNA.....	35
Tabla 3-6: Base de datos generados para la RNA.....	35
Tabla 3-7: Tabla ANOVA para el análisis de la varianza.....	49
Tabla 4-1: Ensayos de entrenamientos seleccionados	51
Tabla 4-2: Ensayos de entrenamientos seleccionados	53
Tabla 4-3: MSE para cada etapa del diseño de la RNA.....	56
Tabla 4-4: Valores reales comparados con los predichos por la RNA.....	58
Tabla 4-5: Base de datos para la validación vs predicciones de la RNA.....	67
Tabla 4-6: Análisis ANOVA para todas las variables	71
Tabla 4-7: Tabla de medias.....	72

ÍNDICE DE ILUSTRACIONES

Ilustración 2-1: Estructura molecular de los colorantes sustitutivos	10
Ilustración 2-2: Reacción de colorantes de diclorotriazinilo con celulosa y agua.....	11
Ilustración 2-3: Reacción de colorantes de monoclorotriazinil y ramazol con celulosa y agua 11	
Ilustración 2-4: Diagrama esquemático de una red neuronal artificial.....	17
Ilustración 2-5: Aprendizaje supervisado de una RNA.....	19
Ilustración 2-6: Modelo básico de una neurona	20
Ilustración 3-1: Metodología del trabajo de titulación	24
Ilustración 3-2: Flujograma de procesos de PROLAVTEX.....	26
Ilustración 3-3: Curva general de teñido reactivo.	27
Ilustración 3-4: Incorporación de los reactivos	29
Ilustración 3-5: Adición de los colorantes en el proceso de tintura.....	30
Ilustración 3-6: Incorporación del auxiliar de jabonado.....	31
Ilustración 3-7: Ajuste de la temperatura de suavizado.....	32
Ilustración 3-8: Interfaz principal del programa <i>ColorMania</i>	33
Ilustración 3-9: Representación del espacio de color CIELAB.....	34
Ilustración 3-10: Selección de los parámetros de entrada y salida.....	44
Ilustración 3-11: Datos normalizados dispuestos en forma de matriz en Excel.....	45
Ilustración 3-12: Herramienta Neural Net Fitting (nftool)	46
Ilustración 3-13: Datos destinados a cada etapa de la creación de la RNA.....	46
Ilustración 3-14: Algoritmos de entrenamiento disponibles en MATLAB®	48
Ilustración 4-1: Muestra tinturada con la formulación 1	52
Ilustración 4-2: Convertidor online de coordenadas de color	53
Ilustración 4-3: Resumen de la RNA diseñada en Matlab	54
Ilustración 4-4: Valores de MSE y R obtenidos de MATLAB®	55
Ilustración 4-5: Gráficas de regresión obtenidas en MATLAB®	55
Ilustración 4-6: Rendimiento del entrenamiento de la red	56
Ilustración 4-7: Código de programación del entrenamiento de la RNA.....	57
Ilustración 4-8: Datos experimentales de L vs predichos.....	65
Ilustración 4-9: Datos experimentales de a* vs predichos	66
Ilustración 4-10: Datos experimentales de b* vs predichos	66
Ilustración 4-11: Datos experimentales de luminosidad vs RNA en la validación	69
Ilustración 4-12: Datos experimentales de a* vs RNA en la validación	69
Ilustración 4-13: Datos experimentales de b* vs RNA en la validación	70

ÍNDICE DE ANEXOS

- ANEXO A:** MUESTRAS GENERADAS PARA EL ANÁLISIS (FORMULACIÓN 1)
- ANEXO B:** MUESTRAS GENERADAS PARA EL ANÁLISIS (FORMULACIÓN 2)
- ANEXO C:** MUESTRAS GENERADAS PARA EL ANÁLISIS (FORMULACIÓN 3)
- ANEXO D:** MUESTRAS GENERADAS PARA EL ANÁLISIS (FORMULACIÓN 4)
- ANEXO E:** MUESTRAS GENERADAS PARA EL ANÁLISIS (FORMULACIÓN 5)
- ANEXO F:** VARIABLES UTILIZADAS EN EL DISEÑO Y ENTRENAMIENTO DE LA RNA
- ANEXO G:** VARIABLES UTILIZADAS EN LA VALIDACIÓN DE LA RNA
- ANEXO H:** CÓDIGO DE MATLAB® PARA EL ENTRENAMIENTO DE LA RNA
- ANEXO I:** CÓDIGO DE MATLAB® PARA LA VALIDACIÓN DE LA RNA

RESUMEN

En la industria de las lavanderías textiles, entre más cercano se encuentre el color conseguido al solicitado por el cliente, mayor será el grado de aceptación y, con ello, la satisfacción del usuario. Dado lo crucial de la precisión en la coloración de las prendas en esta industria, se vuelve fundamental garantizar una consistencia adecuada en las características del producto final. Debido a la variabilidad que se suele presentar en el color y que la relación entre los parámetros operativos no se puede predecir mediante modelos estadísticos, las herramientas informáticas de modelado y simulación se constituyen como una opción interesante para la mejora constante de estos procesos, ya que evitan la necesidad de repetición de pruebas experimentales, ahorrando tiempo y dinero. En el presente trabajo se desarrollará un enfoque de redes neuronales artificiales con base en las variables operativas más importantes del proceso de teñido de prendas textiles que se realiza en la empresa de lavandería textil PROLAVTEX. La RNA que se propone consiste en 3 variables de entrada, representadas por los 3 colorantes correspondientes a los colores primarios (rojo, amarillo y azul), que se determinaron mediante pruebas experimentales como los parámetros más influyentes en el color resultante en la prenda. Además, se establecieron 3 variables de salida que determinaron de forma objetiva el color mediante el espacio de color CIELAB y sus tres coordenadas: L (luminosidad), a (rojo/verde) y b (amarillo/azul). Un punto importante al plantear una RNA como modelo de predicción es validar la precisión de los datos arrojados por la red. Por esto, se realizan análisis gráficos, estadísticos y comparaciones con el fin de probar la capacidad de predicción del modelo. De esta forma, se puede afirmar que la RNA propuesta puede ser utilizada para la dosificación adecuada de los colores en el teñido de los textiles.

Palabras clave: <RNA>, <DOSIFICACIÓN DE COLOR>, <CIELAB>, <DOSIFICACIÓN>, <MODELO DE PREDICCIÓN>



0896-DBRA-UPT-

2024

ABSTRACT

In the textile laundry industry, the closer the color achieved is to the color requested by the customer, the higher the degree of acceptance and, thus, user satisfaction. Given the crucial importance of precision in the coloring of garments in this industry, it becomes essential to ensure adequate consistency in the characteristics of the final product. Due to the variability that is usually present in the color and the fact that the relationship between the operating parameters cannot be predicted by statistical models, computer modeling and simulation tools are an interesting option for the constant improvement of these processes, since they avoid the need to repeat experimental tests, saving time and money. In the present work, an artificial neural network approach will be developed based on the most important operational variables of the textile garment dyeing process carried out in the textile laundry company PROLAVTEX. The proposed ANN consists of 3 input variables, represented by the 3 dyes corresponding to the primary colors (red, yellow and blue), which were determined by experimental tests as the most influential parameters in the resulting color in the garment. In addition, 3 output variables were established that objectively determined the color by means of the CIELAB color space and its three coordinates: L (luminosity), a (red/green) and b (yellow/blue). An important point when considering an ANN as a prediction model is to validate the accuracy of the data provided by the network. For this reason, graphical and statistical analyses and comparisons are carried out in order to test the predictive capacity of the model. In this way, it can be affirmed that the proposed ANN can be used for the adequate dosage of colors in textile dyeing.

Key words: <RNA>, <COLOR DOSING>, <CIELAB>, <DOSING>, <PREDICTION MODEL >



Abg. Ana Gabriela Reinoso Mgs.

Ced: 1103696132

INTRODUCCIÓN

En el dinámico mundo de la industria textil, la precisión en la dosificación de colores es un factor determinante para garantizar la calidad y competitividad de los productos. En este contexto, el presente proyecto se centra en la implementación de un modelo de Redes Neuronales Artificiales (RNA) para optimizar la dosificación de colores en los textiles de la reconocida empresa PROLAVTEX.

El objetivo fundamental de esta investigación es aplicar eficazmente la tecnología de RNA para lograr una dosificación precisa y consistente de los colores utilizados en la producción textil. Para alcanzar este propósito, se plantean objetivos específicos que incluyen la identificación de las variables críticas del proceso y la definición de las entradas y salidas del modelo de RNA. Asimismo, se busca determinar la arquitectura más adecuada de la red neuronal artificial que permita prever con precisión la dosificación de los tintes.

Finalmente, se realizarán ensayos experimentales para validar la eficacia y confiabilidad de las predicciones generadas por el modelo de RNA. Este proyecto no solo tiene como objetivo mejorar la eficiencia y calidad en el proceso de producción textil de PROLAVTEX, sino también contribuir al avance y aplicación de tecnologías innovadoras en el sector industrial.

CAPÍTULO I

1. DIAGNÓSTICO DEL PROBLEMA

1.1. Planteamiento del problema

En la actualidad, el color de diferentes artículos industriales es un importante estándar de calidad en la evaluación del producto final; para poder lograr una apropiada coloración es necesario determinar la correcta proporción de colorantes requeridos para lograr una exacta coincidencia del color, a este proceso se le denomina predicción o formulación de la receta de color. En el sistema de producción de la industria textil, el desarrollo de una apropiada coloración en sus productos es un estándar de calidad indispensable, ya que éste genera un impacto directo en el nivel de agrado o rechazo de un producto (Zavala Ortiz et al., 2018, pág. 78-96).

Las diferentes variables operativas afectan el proceso, como el tiempo de lavado, pH del agua, temperatura, relación de baño, entre otros. Por esta razón, la aplicación de modelos estadísticos se vuelve difícil, considerando que la relación entre las variables a menudo no es lineal. El modelado y la simulación pueden evitar muchas ejecuciones experimentales del proceso que pueden llevar mucho tiempo, gastar reactivos y análisis de retraso. Una de las herramientas más poderosas para predecir el proceso es la red neuronal artificial (RNA). El principio de trabajo de una RNA es similar a la estructura neuronal biológica de los organismos inteligentes, que obtienen conocimiento a través de los procesos de aprendizaje. En general, la red neuronal artificial es un sistema computacional que modela las búsquedas en el funcionamiento del cerebro para realizar actividades específicas. Los valores de entrada se suministran a la red y se manipulan a través de operaciones matemáticas internas para generar un valor de salida (Leon et al., 2020, pág. 1-2).

La empresa PROLAVTEX presenta este problema de coloración muy común en la industria textil, la variación de coloración en sus lotes de productos. Este problema se acentúa, dado el nivel artesanal en el que se maneja la empresa y la falta de una estandarización total en los procesos y la formulación o receta de color, dado que esta varía en dependencia del tipo de tela, composición, proveedor, entre otros factores. Con la finalidad de lograr un estándar de calidad en la coloración de sus prendas, se busca aumentar el porcentaje de precisión en los colores deseados en las prendas para garantizar mayor exactitud al cliente.

Para esto, este trabajo plantea el uso de un modelo de redes neuronales artificiales (RNA) aplicado al proceso de coloración de los productos textiles de la empresa PROLAVTEX, con el fin de

aumentar la exactitud en la formulación de los colores en las prendas y así obtener una mejor aceptación por parte de los clientes gracias a la utilización de una herramienta informática de predicción muy poderosa.

1.2. Justificación

La evaluación del color es un estándar de calidad de suma importancia, el cual incide en el nivel de aceptación o rechazo de diversos productos en el sector industrial. En la industria textil uno de los más importantes procesos es el desarrollo de una coloración apropiada para teñir cierto tipo de tejido por medio de la generación de recetas de color adecuadas. La valoración del color en la industria textil depende en mayor medida de la evaluación visual del producto, la cual es altamente subjetiva, debido a que la percepción del color se ve afectada por diversos factores ambientales así como el entrenamiento del evaluador. Actualmente se han desarrollado diversos métodos para el análisis de la percepción del color. En éstos se han empleado técnicas y herramientas de inteligencia artificial, como son las RNA (Zavala Ortiz, 2019, pág. 4-5).

Li et al., (2015, pág. 311-317), determinaron que el color es un indicador indispensable de la evaluación de la calidad del producto. Entonces, para detectar la diferencia de color de los textiles, adoptaron el algoritmo de retropropagación optimizada de Levenberg-Marquardt (RP) para extraer los valores de las características de color de las imágenes de tela. Primero, los valores de RGB son tres entradas de la red neuronal, y los valores $L^*a^*b^*$ medidos por el espectrofotómetro son tres salidas de la red. La red entrenada pudo obtener los valores $L^*a^*b^*$ correspondientes convenientemente. Con esto, la diferencia de color se pudo calcular a través de la fórmula de diferencia de color y los valores característicos obtenidos anteriormente. Los resultados experimentales mostraron que la diferencia de color de las telas se puede detectar con una alta precisión y eficiencia con este método.

Por los motivos dados, la aplicación de un modelo de redes neuronales artificiales (RNA) para la dosificación adecuada de los colores en los textiles de la empresa PROLAVTEX se justifica con base en la falta de exactitud y variación en la coloración de los productos textiles que trata la empresa, lo que termina afectando el estándar de calidad de estos y, con ello, su nivel de aceptación por parte de los clientes. Este proyecto de titulación es contemplado en la línea de investigación de Procesos, Tecnológico e Industrial de la carrera de Ingeniería Química.

1.3. Objetivos

1.3.1. Objetivo general

- Aplicar un modelo de redes neuronales artificiales (RNA) para la dosificación adecuada de los colores en textiles de la empresa PROLAVTEX.

1.3.2. Objetivos específicos

- Identificar las variables del proceso y definir las entradas y salidas de la RNA.
- Determinar la arquitectura de la red neuronal artificial para la predicción de la dosificación de tintes.
- Validar la dosificación predicha por la RNA mediante ensayos experimentales.

CAPÍTULO II

2. MARCO TEÓRICO

2.1. Antecedentes de la investigación

2.1.1. *Técnicas de coloración de textiles*

El color en la industria textil hace que los textiles sean más llamativos y atractivos. El color es una de las características más importantes de los textiles, y las técnicas de visión artificial se han utilizado ampliamente para medirlos y evaluarlos (Shams-Nateri y Hasanlou, 2018, pág. 189). Fang et al., (2021, pág. 1-5) propusieron un enfoque novedoso para fabricar una coloración ecológica de textiles a partir de nanopelículas de color estructural de polidopamina (PDA) con alta solidez del color. Obtuvieron cuatro colores brillantes diferentes mediante la polimerización de nanopelículas de PDA con diferentes tiempos de reacción en tela de algodón. Además, obtuvieron una nanopelícula de color estructural PDA libre de grietas con alta solidez del color en la superficie de la tela de algodón. Este enfoque sencillo proporciona una idea novedosa para el teñido ecológico de diferentes tipos de textiles con color estructural que impulsa el teñido más limpio en el campo industrial textil.

Los colores estructurales biomiméticos han demostrado ser una promesa práctica significativa en la coloración ecológica. Li et al., (2022, pág. 1-4) prepararon recubrimientos de color estructural con dependencia brillante, a todo color y de ángulo bajo sobre sustratos textiles flexibles a través del autoensamblaje de filtración asistida por vacío simple. La regulación precisa de diferentes tonalidades de colores estructurales se puede lograr cambiando el tamaño de las microesferas o mezclando microesferas con diferentes tamaños, lo que demuestra la simplicidad, bajo costo y gran compatibilidad. Mientras tanto, este método también se puede aplicar a la preparación de recubrimientos de color estructural sobre sustratos con poros, ampliando la aplicación de colores estructurales en varios campos.

Liu et al., (2021, pág. 1-6) estudiaron el color estructural que se origina a partir del recubrimiento de nanopelículas biomiméticas de polidopamina similar a la melanina (PDA) sobre tela de seda flexible y su rendimiento de color. Obtuvieron cinco colores estructurales brillantes diferentes a través de los diferentes tiempos de reacción de polimerización del recubrimiento de nanopelícula de PDA. Sin embargo, el recubrimiento de nanopelículas de colores estructurales preparado

presentó grietas y poca solidez del color debido a la tensión capilar durante la formación de la película de PDA y la interacción débil con el sustrato de la tela.

Garcia et al., (2020, pág. 1-5) evaluaron la eficiencia de un tratamiento con haz de electrones aplicado a la toxicidad y reducción de color de un efluente textil que contiene el colorante reactivo Red 239. También evaluaron la DQO y el TOC de los efluentes. Los efluentes evaluados fueron sometidos a tratamiento EBI en dosis que oscilaron entre 0,5 y 15 kGy. La irradiación con EB redujo con éxito la toxicidad y el color de los efluentes. Se obtuvo una reducción de la toxicidad de aproximadamente el 70%, mientras que la reducción del color del 95% se obtuvo aplicando 5 kGy.

2.1.2. Uso de RNA como herramienta de optimización de procesos

Las incertidumbres del proceso han sido un gran desafío para la operación y el control estables de los procesos que se desarrollan en la industria (Samad et al., 2023, pág. 1403). Kothari et al., (2022, pág. 1-8) aplicaron un enfoque de red neuronal artificial (RNA) con la técnica de metodología de superficie de respuesta (MSR) para modelar y optimizar el proceso de eliminación del colorante verde brillante mediante el proceso de electrocoagulación por lotes. Entrenaron un modelo de RNA perceptrón multicapa (PMC) con cuatro neuronas de entrada que representan el tiempo de reacción, la densidad de corriente, el pH, la concentración de NaCl y dos neuronas de salida que representan la eficiencia de eliminación del colorante (%) y el consumo de energía eléctrica (kWh/kg). Las neuronas de capa oculta optimizadas se obtuvieron con base en un error cuadrático medio mínimo. En condiciones optimizadas (tiempo de electrólisis 10 min, densidad de corriente 80 A/m², pH inicial 5 y concentración de electrolito NaCl 0,5 g/L), la MSR proyectó una decoloración del 98,83 % y un consumo de energía eléctrica de 14,99 kWh/kg. Este estudio muestra que la eliminación del tinte verde brillante puede llevarse a cabo con éxito mediante un proceso de electrocoagulación por lotes. Por lo tanto, la RNA entrena con éxito el proceso y la MRS lo optimiza para aplicaciones similares.

He et al., (2021, pág. 1-4) propusieron un sistema de apoyo a la decisión que combina los modelos inteligentes basados en datos de Random Forest (RF) y una estructura multicriterio basada en el conocimiento humano del proceso analítico jerárquico (AHP) de acuerdo con el objetivo y los factores subjetivos del proceso de fabricación textil. La eficacia de este sistema se validó en un estudio de caso de optimización de un proceso de ozonización textil, lo que demuestra que puede dominar mejor las tareas de toma de decisiones desafiantes en los procesos de fabricación de productos químicos textiles. He et al., (2022, pág. 939-949) propusieron un marco novedoso que

transformó el problema de optimización del proceso textil en un juego estocástico e introdujo un algoritmo de redes Q profundas en lugar de los métodos actuales para abordarlo en un sistema multiagente. El sistema de aprendizaje desarrollado aplicó un mecanismo de selección utilitario para evitar la interrupción de equilibrios múltiples y lograr las soluciones óptimas de equilibrio correlacionadas del proceso textil. El resultado del estudio de caso refleja que el sistema propuesto puede lograr las soluciones óptimas para el proceso de ozonización textil y funciona mejor que los enfoques tradicionales.

Khiam et al., (2022, pág. 1-4) sintetizaron compuestos de óxido de grafeno/quitosano y los aplicaron en la eliminación del colorante azul de metileno (AM). Los estudios de adsorción se realizaron para verificar el efecto del pH, la dosis de adsorbente y el tiempo de contacto. Los efectos interactivos de las variables del proceso se verificaron utilizando la metodología de superficie de respuesta (MSR), y las condiciones óptimas para una mayor eficiencia de adsorción se evalúan mediante la red neuronal artificial (RNA) la optimización por enjambre de partículas (PSO). Las predicciones de la RNA-PSO concuerdan bien con los valores experimentales y, por lo tanto, dieron como resultado un R^2 más alto (0,998) en comparación con las predicciones de la MSR ($R^2=0,981$). La máxima eficiencia de eliminación de AM (90,34%) y cantidad de adsorción (7,53 mg/g) se puede obtener con una concentración de colorante inicial de 10 mg/L y valores óptimos de pH (5), dosificación de adsorbente (0,143 g/L) y tiempo de contacto (125 minutos). Estos resultados confirman además que el enfoque basado en RNA-PSO puede capturar los mecanismos inherentes del proceso de adsorción de AM y puede usarse como un buen enfoque de modelado.

Dodangeh et al., (2014, pág. 30-38) utilizaron cuatro factores (temperatura, pH, tiempo y cantidad de dendrímero), diseño compuesto central de cinco niveles, métodos de inteligencia artificial llamados método de grupo de red neuronal de manejo de datos y algoritmo competitivo imperialista para optimizar la condición de modificación de la superficie de una tela de nylon. La modificación se realizó en la condición optimizada y las telas modificadas se tiñeron con CI Acid orange 2. Los datos mostraron una mejora en la capacidad de teñido del nailon modificado que podría atribuirse a la unión de grupos amino funcionales en la superficie. El agotamiento y la adsorción del tinte por los tejidos modificados podría estar relacionado con los grupos terminales amino protonados.

2.1.3. Modelos de RNA aplicados en la industria textil

La manufactura textil es una industria tradicional que involucra alta complejidad en procesos interconectados con capacidad limitada en la aplicación de tecnologías modernas. La toma de

decisiones en este dominio generalmente toma en consideración múltiples criterios, lo que suele generar mayor complejidad (He et al., 2021, pág 1-2). Por esto, Ierace et al., (2007, pág. 147-152) describieron un nuevo sistema de mantenimiento predictivo para sistemas de máquinas textiles basado en un enfoque de red neuronal. Este enfoque evita la necesidad de una costosa medición de los parámetros del sistema. Los resultados obtenidos llevan a la conclusión de que las redes neuronales representan una herramienta eficaz para apoyar las políticas de mantenimiento basado en condiciones de las empresas textiles.

Bahlmann et al., (1999, pág. 1049-1060) presentaron un método para un control de calidad automatizado de costuras textiles, que tiene como objetivo establecer una medida de calidad estandarizada y reducir los costos en la fabricación. El sistema consta de una configuración de adquisición de imágenes adecuada, un algoritmo para ubicar la costura, una etapa de extracción de características y una red neuronal del tipo de mapa autoorganizado para la clasificación de características. Se describe un procedimiento para seleccionar un conjunto de características optimizado que lleva la información relevante para la clasificación y se obtienen resultados satisfactorios. Además, Amelio et al., (2022, pág. 1-6) propusieron un nuevo modelo basado en una red neuronal convolucional (CNN) para identificar los colores de las telas. Finalmente, a través de una serie de experimentos, demostraron que el conjunto es capaz de mejorar la identificación de colores de telas.

Elemen et al., (2012, pág. 102-111) desarrollaron un modelo de red neuronal artificial para predecir la decoloración de la solución Reactive Red 141. Se concluyó que la red neuronal artificial proporcionó un rendimiento predictivo razonable. Las simulaciones basadas en el modelo de red neuronal artificial desarrollado pueden estimar el comportamiento del proceso de decoloración en diferentes condiciones. Leon et al., (2020, pág 2-4) estudiaron el proceso de biosorción de eliminación de color de efluentes textiles utilizando bagazo de caña de azúcar modificado químicamente (SBM) como material biosorbente y la predicción del proceso mediante el modelado y simulación de una red neuronal artificial (RNA). La red neuronal feed-forward multicapa, con cinco entradas y una salida, se entrenó con ocho neuronas en la capa oculta. Una comparación entre los datos experimentales y los predichos mostró que los resultados de eliminación de color se ajustaban muy bien al modelo con un R^2 de 0,928 y un error cuadrático medio de 0,013. En general, el proceso de adsorción con SBM demostró ser un método prometedor para el tratamiento de efluentes textiles y el modelo de RNA desarrollado se puede utilizar con éxito para hacer predicciones sobre el color final del efluente.

Shootov et al., (2017, pág. 548-555) propusieron un método para estudiar la señal proveniente de los sensores del tejido inteligente. Presentan los resultados experimentales de la aplicación del

método para detectar los puntos de control utilizando redes neuronales artificiales (RNA). Llevan a cabo una conversión de datos dinámicos en estáticos mediante la fragmentación de la señal de tejido inteligente en patrones de entrenamiento, que luego alimentan a la RNA. Finalmente, la RNA entrenada es capaz de clasificar los patrones de entrenamiento, lo que permite identificar los puntos de control en el modo de operación. Los métodos y resultados desarrollados también se pueden utilizar para estudiar otras señales, por ejemplo, las recibidas de sensores de tejido médico inteligente durante el período de rehabilitación del paciente.

2.2. Referencias teóricas

2.2.1. Coloración de textiles

2.2.1.1. Colorantes reactivos

Los colorantes reactivos pueden definirse vagamente como cromóforos que contienen grupos colgantes capaces de formar enlaces covalentes con sitios nucleófilos en sustratos fibrosos. Siempre que estos enlaces covalentes sean estables a las condiciones encontradas en el lavado, las propiedades de solidez al lavado de las coloraciones serán sobresalientes. A diferencia de otras clases de colorantes que se utilizan en sustratos celulósicos, los colorantes reactivos cubren una gama de tonos muy amplia, desde el negro hasta los tonos brillantes y vibrantes, lo que explica su temprano éxito comercial en esta área (Lewis, 2011, pág. 303).

Los colorantes reactivos también se han usado más ampliamente en materiales de poliamida como un medio para producir tintes y estampados de excelente solidez al lavado; adicionalmente en el caso de la lana exhiben un efecto protector de la fibra que disminuye el daño en el teñido y también son vistas como alternativas a los tintes al cromo (Lewis, 2011, pág. 303).

Clasificación de los colorantes reactivos

Los colorantes reactivos se clasifican en dos tipos: 1) sustitutivos y 2) aditivos. Los colorantes sustitutivos incluyen mono y diclorotriazinas; 2,4,5 trihalogenopirimidinas, 2-metilsulfonil-4-metil-5-cloropirimidina y 2,3 dicloroquinoxalina; fuera de estos, los colorantes mono y diclorotriazina (ilustración 2.1) son los que más comparten. Los de tipo aditivo incluyen ésteres de ácido sulfúrico de β -hidroxietilsulfonas, β -aminoetilsulfonas, ésteres de ácido sulfúrico de β -hidroxipropionamidas y β -cloropropionamidas; los tintes de ramazol son los más importantes de este tipo (Chakraborty, 2010a, pág. 58-59).




Ilustración 2-1: Estructura molecular de los colorantes sustitutivos

Fuente: Chakraborty, 2010a.

Los tintes de diclorotriazina poseen dos átomos de cloro reactivos y se aplican a temperatura ambiente, llamados tintes de marca fría o M, mientras que las monoclorotriazinas, que poseen solo un átomo de cloro, se aplican bajo aplicación de calor y se conoce como marca caliente o colorantes H (Chakraborty, 2010a, pág. 58-59).

El de tipo aditivo incluye principalmente colorantes de sulfona de vinilo (colorantes de ramazol) que poseen una fórmula general $\text{DSO}_2\text{CH}=\text{CH}_2$. Estos tintes no dan ningún subproducto durante la reacción con el algodón o el agua, siguen un mecanismo de adición nucleófilo y se aplican mediante la aplicación de calor. La unión química se da en pH alcalino (Chakraborty 2010a, p. 59).

Propiedades de los colorantes reactivos

Los colorantes reactivos, en general, son solubles en agua; la solubilidad aumenta al agregar poca urea. La afinidad general por el algodón es pobre, lo que requiere un teñido prolongado junto con un exceso de sal. Los teñidos muestran una excelente solidez al lavado excepto con marcas en frío que carecen de la solidez al lavado requerida debido a las posibilidades de reacción simultánea con el algodón y el agua. La gama completa de sombras está disponible; los tintes son ecológicos, lo que da como resultado la autodecoloración del licor descargado a través de la hidrólisis en condiciones naturales; la reacción es la misma que ocurre en el baño de tintura. Los tintes de diclorotriazina se aplican a temperatura ambiente o un poco más allá de lo que requiere la instalación de calderas (Chakraborty, 2014, p. 177-178).

Los colorantes de marcas en frío poseen una mejor afinidad por el algodón y son adecuados solo para el teñido por agotamiento; el valor de color de los teñidos puede perderse parcialmente si se tiñen con el método pad-batch. Estos no son adecuados para el teñido localizado (tie and dye, batik y otros estampados, etc.) ya que la hidrólisis del tinte durante el teñido y el posterior lavado

doméstico pueden manchar las prendas adyacentes y estropear el aspecto y la estética (Ilustración 2.2) (Chakraborty, 2014, pág. 178).




Ilustración 2-2: Reacción de colorantes de diclorotriazinilo con celulosa y agua

Fuente: Chakraborty, 2010a.

Al ser altamente reactivo debido a la presencia de dos átomos de cloro, los colorantes fríos son más susceptibles a la hidrólisis y la tasa de fijación también es alta; las moléculas de tinte involucran un átomo de cloro para reaccionar con el algodón mientras que otro con agua provoca una pobre solidez al lavado ya que el tinte parcialmente hidrolizado no se puede sacar del algodón teñido de manera efectiva (Chakraborty, 2014, pág. 178).

Por el contrario, los tipos de marca caliente y ramazol son adecuados para acolchado o estampado solo debido a su poca afinidad con el algodón. Debido a la presencia de un solo átomo de cloro o sitio reactivo, estos se hidrolizan o reaccionan con el algodón, pero no manchan el suelo o las prendas adyacentes durante el lavado y se usan ampliamente en acolchados y estampados (Ilustración 2.3) (Chakraborty, 2014, pág. 179).




Ilustración 2-3: Reacción de colorantes de monochlorotriazinil y ramazol con celulosa y agua

Fuente: Chakraborty, 2010a.

2.2.1.2. *Proceso de tintura*

En general, la tintura se puede describir como un proceso en el que una fibra textil absorbe las moléculas de tinte de su solución, de modo que el material teñido retiene el tinte y resiste la liberación del tinte de vuelta a la solución de la que se absorbió. Los procesos de tintura que tienen lugar en soluciones acuosas de colorantes son siempre procesos de distribución entre dos fases, es decir, solución de colorante y sustrato sólido, y se basan en interacciones fisicoquímicas entre las moléculas de colorante y el sustrato. Estos procesos pueden ir acompañados de reacciones químicas entre las moléculas del colorante y el sustrato, por ejemplo, en el caso de los colorantes tina, reactivos y de cromo. En el caso de los colorantes dispersos, en el proceso interviene la segunda fase sólida, es decir, las partículas dispersas del colorante. Estas partículas se disuelven en el agua y así el transporte del colorante al sustrato sólido se realiza de manera similar a la de los colorantes solubles en agua (Grishanov, 2011, pág. 43).

El proceso de tintura en soluciones de agua se puede dividir en cuatro etapas de la siguiente manera:

- **Difusión por convección del tinte en el baño de tinte durante el cual las moléculas individuales del tinte se mueven dentro de la fase líquida hacia la fibra.** Este es un proceso relativamente rápido que puede acelerarse por el movimiento relativo de la solución de tinte y la fibra (Grishanov, 2011, pág. 43).

- **Absorción del tinte en la superficie de la fibra donde las moléculas del tinte pasan de la fase líquida (solución de tinte) a la fase sólida (fibra).** La superficie de la fibra se entiende aquí no solo como la superficie exterior visible de la fibra, que se define por el diámetro y la longitud de la fibra, sino también como la superficie de los poros que pueden penetrar profundamente en el interior de la fibra. Esta etapa define en gran medida la uniformidad del color del producto final (Grishanov, 2011, pág. 43).

- **Difusión molecular del colorante desde la superficie de la fibra hacia el interior de la fibra.** Este es un proceso lento cuya velocidad se puede aumentar elevando la temperatura de la solución de tinte. Una temperatura más alta también ayuda a aumentar la hinchazón de la fibra (Grishanov, 2011, pág. 43).

• **Fijación de las moléculas de colorante sobre las moléculas de fibra mediante la formación de enlaces entre las moléculas de colorante y la fibra.** La estabilidad de la fijación depende del tipo de unión que se haya formado (Grishanov, 2011, pág. 43).

2.2.1.3. Parámetros de control del proceso de tintura

Propiedades del colorante reactivo

En general, los tintes con una sustentividad alta y una difusión lenta son más apropiados para el teñido por agotamiento en el método por lotes. A diferencia del teñido por agotamiento, los tintes con baja sustentividad y rápida difusión son más adecuados para el método de teñido continuo. En general, hay dos tipos de proceso de teñido continuo, el más simple de una sola almohadilla en el que los tintes y el álcali se tamponan en un baño de tinte, y el versátil doble tampón en el que los tintes y el álcali se tamponan por separado y secuencialmente (Shang, 2013, pág. 302-304).

Temperatura

La temperatura tiene efectos profundos tanto en la tintura como en el algodón en solución acuosa. El aumento de la temperatura puede provocar una mejor penetración del tinte, una difusión más rápida, una mejor uniformidad, pero puede reducir la sustentividad del tinte y aumentar el riesgo de hidrólisis del tinte. Además, la temperatura elevada conduce a la apertura de la estructura de la celulosa, lo que activa la interacción colorante-fibra. Por lo tanto, la temperatura de teñido está determinada tanto por la sustentividad y reactividad del tinte como por la estructura de la fibra (Dickinson, 2011, pág. 171).

pH

El pH influye principalmente en la concentración del anión celusato (celulosa-O-) en la fibra, así como en la concentración del ion hidroxilo (-OH) en el baño de tintura y en la fibra. Los tintes reactivos consumen algo de álcali tanto para la fijación como para la hidrólisis del tinte. La alcalinidad interna de la fibra también absorbe álcali. Esto hace que el pH del baño de tintura al final de la tintura sea siempre inferior a su valor inicial. Por lo general, aumentar el pH del teñido en la etapa de fijación puede acelerar la velocidad de reacción entre el tinte y la fibra. Incluso con los tintes de baja reactividad, un pH superior a 11 aún no es apropiado, ya que un pH indebidamente alto mejorará la hidrólisis del tinte y reducirá la eficiencia del teñido en términos de profundidad y fijación (Ibrahim, 2011, pág. 156-157).

Electrolito

Cuando la fibra de algodón está en una solución acuosa, la superficie de la fibra presenta carga negativa, principalmente debido a la disociación de los grupos hidroxilo de celulosa accesibles y al reordenamiento de los grupos de carga en la interfaz entre la fibra y el agua. Los tintes reactivos, así como otros tintes solubles para el algodón, tienen cargas negativas debido a los grupos de sulfato en sus moléculas para la solubilidad. Por lo tanto, la fuerza de repulsión electrostática entre la superficie de la fibra y los colorantes debe superarse para difundir los colorantes a través de la interfaz fibra-agua. El método más común para superar la repulsión electrónica en el teñido por agotamiento es agregar una gran cantidad de electrolito (la llamada sal), cloruro de sodio o sulfato de sodio, en el baño de teñido. La presencia de electrolito reduce la extensión de la carga superficial, lo que conduce a una reducción de la repulsión entre los colorantes ionizados y la fibra, lo que aumenta la sustentividad de los colorantes (Shang, 2013, pág. 306).

Relación de baño

El agua es un medio esencial para un proceso de teñido en la mayoría de los métodos de teñido. La relación de baño es la relación entre el peso del material seco que se tiñe y el peso de agua del baño de tintura. Por ejemplo, una proporción de baño de 1:10 implica que se tiñe 1 kg de fibra en 10 L de agua. Una relación de baño grande beneficia la uniformidad del teñido, pero tiene un impacto negativo en los costos de producción y el medio ambiente, y genera más emisiones de carbono. Por lo tanto, una máquina de teñir con una relación de baño baja, como 1:5 para algodón, se está aplicando de manera más amplia (Shang, 2013, pág. 307).

2.2.1.4. Formulación de la receta de tintura

La formulación de la receta de teñido instrumental y el mantenimiento de condiciones óptimas de teñido son la clave para producir tonos nivelados. La receta debe permanecer sin cambios para reproducir un matiz y una tonalidad específicos. La receta de teñido se formula principalmente con un sistema de combinación de colores por computadora que funciona sobre la base de datos almacenados de tintes en varias concentraciones en una clase determinada de fibra. Los datos almacenados también ayudan al tintorero a conocer el costo, la solidez, etc., para cada receta. Para mantener la calidad, las existencias de tintes utilizados, así como los productos químicos requeridos, deben almacenarse adecuadamente antes de comenzar el programa de teñido y el tintorero debe permanecer adherido a la receta y las condiciones establecidas; agregar cualquier color sustituto puede estropear la sombra (Chakraborty, 2010b, pág. 2-3).

2.2.1.5. *Control de calidad*

Visualización del color

La reflexión especular (luz dirigida en un ángulo que es exactamente opuesto a la luz incidente o cuando el ángulo de incidencia es igual al ángulo de reflexión) es generalmente menos del 4-5% del total y un observador la percibe como el 'brillo' o 'lustrosidad' de la muestra. Sin embargo, para ver el color aparente de la muestra, el observador debe alejar su ojo del especular y concentrarse en examinar la reflectancia difusa (dispersa) de la muestra. Estas condiciones de visualización necesarias han dado lugar a métodos de prueba estandarizados como la norma ASTM D 1729 'Práctica estándar para la evaluación de diferencias de color de materiales opacos', donde la geometría 0°/45° (o 45°/0°) (iluminación/visualización), que evita lo especular, se recomienda (Gangakhedkar, 2010, pág. 221-223).

El papel de un espectrofotómetro de medición de color es crítico y uno debe analizar las características de diseño y seleccionar un instrumento adecuado para la aplicación textil. Muchos materiales utilizados como estándares para la igualación de tonos aparecen brillantes cuando se ven desde un ángulo particular. Estos materiales incluyen fragmentos de pintura brillante, paneles de plástico y páginas de revistas, entre otros. Cuando estos tipos de materiales se miden para la formulación de nuevos tonos o cuando las muestras se miden detrás de una placa de vidrio, es importante excluir la reflectancia brillante de la medición de la muestra (Best, 2012, pág. 292-293).

Apariencia del tejido

Este tipo de control visual se realiza en la prenda textil para comprobar la uniformidad de la tintura. En esta etapa de control se utilizan tres niveles de calificación, los cuales se describen a continuación:

- **Calificación de “mala igualación”**: indica que el textil presenta una distribución desigual del tinte, mostrando diversos tonos que parecen manchas (Binjie y Hu, 2008, pág. 149-150).
- **Calificación de “igualación media”**: se refiere a que el textil tiene partes con una distribución desigual del tinte, pero estas imperfecciones no son perceptibles en la prenda final o pueden ser corregidas durante el proceso de corte y confección (Binjie y Hu, 2008, pág. 149-150).

- **Calificación de “igualación trabajable”:** indica que el textil no presenta desigualdades significativas en la tintura y se encuentra apto para su utilización en la posterior etapa de producción (Binjie y Hu, 2008, pág. 149-150).

Solidez al lavado

La solidez del color significa la resistencia del color de los textiles a los diferentes agentes a los que estos materiales pueden estar expuestos durante la fabricación (por ejemplo, mercerizado) y su posterior uso (por ejemplo, lavado doméstico). Hoy en día, la evaluación del cambio de color se puede realizar visualmente mediante el uso de escalas de grises o una evaluación instrumental. La evaluación visual de un cambio de color se realiza comparando el contraste de color entre la muestra de prueba y la muestra original, utilizando la escala de grises conocida para el cambio de color. La escala de grises para el cambio de color consta de cinco pares de chips grises neutros que representan una diferencia de color visual que corresponde a clasificaciones de solidez de 5, 4, 3, 2 y 1. Una clasificación de 1 ilustra un gran contraste entre el original y la muestra de prueba, mientras que una calificación de 5 ilustra que no hay contraste entre ellos (máxima solidez). Por lo general, se acepta una tolerancia de $\pm 0,5$ entre diferentes observadores, por lo que es posible asignar clasificaciones de solidez intermedias (Nimkar y Bhajekar, 2012, pág. 84-85).

Como alternativa a la evaluación visual, se puede realizar una evaluación instrumental colorimétrica midiendo las coordenadas CIELAB, calculando las diferencias de color entre las muestras originales y de prueba, y convirtiendo estas diferencias en una calificación de escala de grises usando una ecuación como la propuesta en el estándar ISO 105-A05 (Bide, 2010, pág. 212-213).

2.2.2. Redes neuronales artificiales

2.2.2.1. Introducción

Una red neuronal artificial (RNA) es un paradigma de procesamiento de información que se inspira en la forma en que los sistemas nerviosos biológicos, como el cerebro, procesan la información. El elemento clave de este paradigma es la nueva estructura del sistema de procesamiento de información. Está compuesto por una gran cantidad de elementos de procesamiento altamente interconectados (neuronas) que trabajan al unísono para resolver problemas específicos. Las RNA, como las personas, aprenden con el ejemplo. Una RNA se configura para una aplicación específica, como el reconocimiento de patrones o la clasificación

de datos, a través de un proceso de aprendizaje. El aprendizaje en los sistemas biológicos implica ajustes en las conexiones sinápticas que existen entre las neuronas (Senthilkumar, 2010, pág. 125-126).

2.2.2.2. *Arquitectura de una RNA*

Las RNA suelen estar compuestas por "unidades" interconectadas que sirven como neuronas modelo. El diagrama esquemático de una ANN típica se muestra en la Ilustración 2.4.




Ilustración 2-4: Diagrama esquemático de una red neuronal artificial

Fuente: Senthilkumar, 2010.

Neurona artificial

Las RNA consisten en una gran cantidad de neuronas o unidades de procesamiento simples, también conocidas como nodos, y una neurona artificial imita las características de la neurona biológica. Aquí, se aplica un conjunto de entradas, cada una de las cuales representa una salida de otra neurona. Cada entrada se multiplica por un peso correspondiente, de forma análoga a las fuerzas sinápticas y las entradas ponderadas se suman para determinar el nivel de activación de la neurona. Las fuerzas de conexión o el peso representan el conocimiento en el sistema. El procesamiento de la información tiene lugar a través de la interacción entre estas unidades (Mukhopadhyay, 2011, pág. 330-331).

Capas de la RNA

El tipo más común de red neuronal artificial consta de tres grupos, o capas, de unidades: una capa de unidades de "entrada" está conectada a una capa de unidades "ocultas", que está conectada a

una capa de unidades de "salida" (Ilustración 2.4). La actividad de las unidades de entrada representa la información sin procesar que se alimenta a la red. Considerando que, la actividad de cada unidad oculta está determinada por las actividades de las unidades de entrada y los pesos en las conexiones entre la entrada y las unidades ocultas. De manera similar, el comportamiento de las unidades de salida depende de la actividad de las unidades ocultas y los pesos entre las unidades ocultas y las de salida (Mukhopadhyay, 2011, pág. 329-330).

2.2.2.3. *Clasificación de RNA*

Redes feed-forward

En la ilustración 2.4 se ilustra una red feed-forward general. Se trata de una red jerárquica de alimentación hacia adelante, totalmente conectada, que consta de una capa de entrada, una o más capas intermedias u ocultas y una capa de salida. Las capas internas se denominan "ocultas" porque solo reciben entradas internas y producen salidas internas. Esta red permite que las señales viajen solo de entrada a salida. No hay retroalimentación (bucles), es decir, la salida de cualquier capa no afecta a esa misma capa. Las RNA feed-forward tienden a ser redes sencillas que asocian entradas con salidas (Fávero et al., 2023, pág. 445).

Redes feedback

Las redes feedback pueden tener señales que viajan en ambas direcciones al introducir bucles en la red. Las redes de este tipo funcionan al permitir que las neuronas vecinas ajusten otras neuronas cercanas en una dirección positiva o negativa. Las redes de retroalimentación cambian continuamente hasta que alcanzan un punto de equilibrio, donde permanecen hasta que cambia la entrada y se necesita encontrar un nuevo equilibrio. Las arquitecturas de retroalimentación también se conocen como redes neuronales interactivas o recurrentes (Fávero et al., 2023, pág. 445).

2.2.2.4. *Proceso de aprendizaje*

El verdadero aprendizaje similar al humano está más allá de todas las técnicas de inteligencia artificial, aunque se han desarrollado algunas técnicas de aprendizaje que permiten que las máquinas imiten la inteligencia humana (Shehab et al., 2022, pág. 196).

Estas técnicas que permiten a las computadoras adquirir información con cierto grado de autonomía se conocen colectivamente como aprendizaje automático. Las redes neuronales

exhiben la capacidad de aprender de manera similar al aprendizaje animal: tienen una estructura dada (topología y método de aprendizaje), se les presentan estímulos (entradas) y se adaptan a ese estímulo. Cuando la red neuronal produce una decisión incorrecta, las conexiones en la red se debilitan, por lo que no volverá a producir esa respuesta. De manera similar, cuando la red produce una decisión correcta, las conexiones en la red se fortalecen, por lo que será más probable que produzca esa respuesta nuevamente. A través de muchas iteraciones de este proceso, dando a la red cientos o miles de ejemplos, la red eventualmente aprenderá a clasificar todos los personajes que ha visto. Este proceso se denomina aprendizaje supervisado y es fundamental que los datos proporcionados a la red se seleccionen con mucho cuidado para representar la información que la red debe aprender (Mukhopadhyay, 2011, pág. 329-330).

En general, hay tres formas diferentes de abordar el aprendizaje de redes neuronales:

Aprendizaje supervisado

El aprendizaje supervisado requiere que el programa proporcione a la red ejemplos de entradas y salidas correctas para cada entrada dada. De esta forma, la red puede comparar lo que ha generado con lo que debería generar y puede corregirse a sí misma (Ilustración 2.5). La propagación inversa es el método más utilizado para el entrenamiento de redes neuronales porque es el más fácil de implementar y comprender y funciona razonablemente bien para la mayoría de los problemas lineales y no lineales (Senthilkumar, 2010, pág. 129).

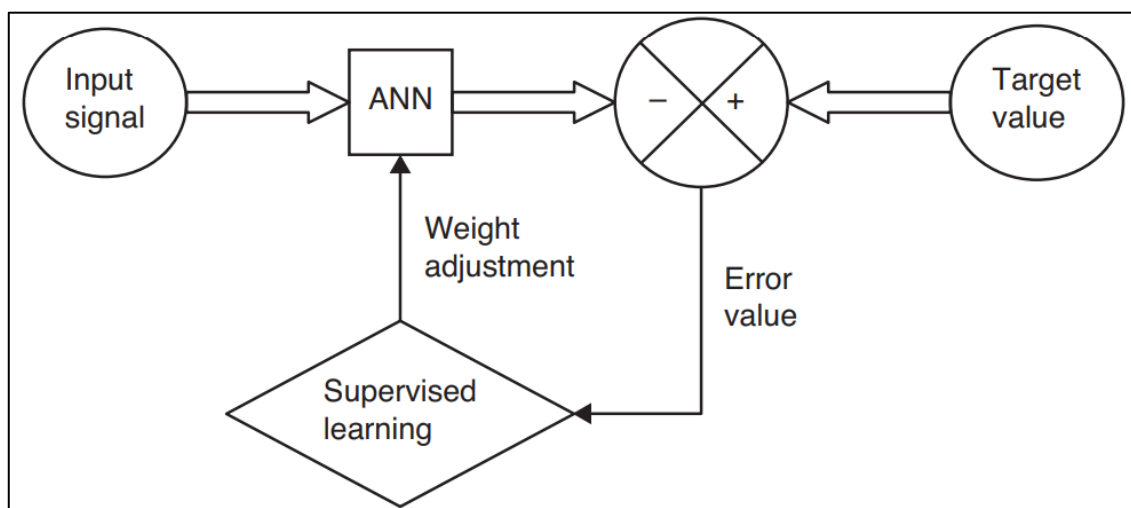


Ilustración 2-5: Aprendizaje supervisado de una RNA

Fuente: Senthilkumar, 2010.

Aprendizaje no supervisado

El aprendizaje no supervisado proporciona una entrada pero no una salida correcta. Una red que usa este tipo de aprendizaje solo recibe entradas y la red debe organizar sus conexiones y salidas sin retroalimentación directa (Zhang y Su, 2021, pág. 520).

Aprendizaje por refuerzo

El aprendizaje por refuerzo es un caso especial de aprendizaje supervisado. En lugar de usar un maestro para dar resultados objetivo, un algoritmo de aprendizaje por refuerzo emplea un crítico solo para evaluar la bondad de la salida de la red neuronal correspondiente a una entrada dada (Ibrahim et al., 2022, pág. 4).

2.2.2.5. Modelo matemático

La neurona artificial (también llamada elemento de procesamiento o nodo) imita las características de una neurona biológica. Un elemento de procesamiento posee una memoria local y lleva a cabo operaciones de procesamiento de información localizada (Paulraj y Sivanandam, 2003, pág. 2-3).

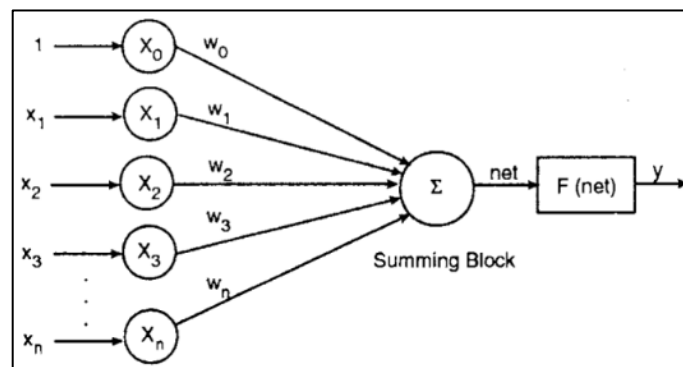


Ilustración 2-6: Modelo básico de una neurona

Fuente: Paulraj & Sivanandam, 2003.

La neurona artificial tiene un conjunto de 'n' entradas x_i , cada una de las cuales representa la salida de otra neurona (el subíndice i toma valores entre 1 y n e indica la fuente de la señal de entrada del vector). Las entradas se denominan colectivamente como X . Cada entrada se pondera antes de que llegue al cuerpo principal del elemento de procesamiento por la fuerza de conexión o el factor de peso (o simplemente peso) análogo a la fuerza sináptica. La cantidad de información sobre la entrada que se requiere para resolver un problema se almacena en forma de pesos. Cada

señal se multiplica con un peso asociado $w_1, w_2, w_3, \dots, w_n$ antes de aplicarla al bloque de suma. Además, la neurona artificial tiene un término de sesgo w_0 , un valor de umbral ' θ ' que debe alcanzarse o extenderse para que la neurona produzca una señal, una función no lineal 'F' que actúa sobre la señal producida 'red' y una salida 'y' después de la función de no linealidad. El modelo básico de una neurona se muestra en la Ilustración 2.6. Cabe señalar que se supone que la entrada a la neurona de sesgo es 1 (Paulraj y Sivanandam 2003, p. 3).

La siguiente relación (Ec. 1) describe la función de transferencia del modelo básico de neurona:

$$y = F(\text{red}) \quad (1)$$

donde

$$\text{red} = w_0 + x_1 w_1 + x_2 w_2 + x_3 w_3 + \dots + x_n w_n \quad (2)$$

o

$$\text{red} = w_0 + \sum_{i=0}^n x_i w_i \quad (3)$$

y la condición de activación de la neurona es:

$$\sum_{i=0}^n x_i w_i \geq \theta [\text{para la función de activación lineal}], x_0 = 1$$

o

$$F(\text{red}) \geq \theta [\text{para la función de activación no lineal}]$$

2.2.2.6. *MATLAB*[®]

MATLAB es un paquete de software comercial para realizar una variedad de operaciones matemáticas. Fue desarrollado por primera vez en 1984 e incluía principalmente operaciones de álgebra lineal (de ahí el nombre, *MATrix LABoratory*). Desde entonces, se ha ampliado para incluir una amplia gama de funcionalidades que incluyen visualización, estadísticas y desarrollo de algoritmos utilizando programación informática. Tiene aproximadamente 1 millón de usuarios actuales en la academia, la investigación y la industria, y ha encontrado una aplicación particular en los campos de la ingeniería, la ciencia y la economía. Además de su funcionalidad principal,

hay una serie de cajas de herramientas específicas disponibles para ampliar las capacidades de MATLAB (King y Aljabar, 2017, pág. 3).

Neural Network Toolbox

La Neural Network Toolbox es una herramienta de MATLAB que proporciona funciones y aplicaciones para modelar sistemas no lineales complejos que no se modelan fácilmente con una ecuación de forma cerrada (Lindfield y Penny, 2019, pág. 1-2).

Neural Network Toolbox admite el aprendizaje supervisado con feed-forward, base radial y redes dinámicas. También admite el aprendizaje no supervisado con mapas autoorganizados y capas competitivas. Con Neural Network Toolbox, se puede diseñar, entrenar, visualizar y simular redes neuronales. La caja de herramientas de redes neuronales se puede utilizar para resolver muchos tipos de aplicaciones, como el ajuste de datos, el reconocimiento de patrones, la agrupación, la predicción de series temporales y el modelado y control de sistemas dinámicos (Ploskas y Samaras 2016, p. 109-110).

Para acelerar el entrenamiento y manejar grandes conjuntos de datos, Neural Network Toolbox puede distribuir cálculos y datos a través de CPU, GPU y clústeres de computadoras multinúcleo y multiprocesador utilizando Parallel Computing Toolbox (Valentine y Hahn, 2023, pág. 30-31).

Para entrenar y simular una red neuronal en MATLAB, debe seguir los siguientes pasos:

- Preparar los datos de entrada y de destino.
- Cree una red neuronal utilizando la función de red de avance.
- Configure la red neuronal con los datos de entrada y de destino utilizando la función de configuración.
- Entrenar la red neuronal utilizando la función de tren.
- Simular la red neuronal usando la llamada implícita a la función sim (donde la red 'net' se llama como función).

La ventana de entrenamiento aparecerá durante el entrenamiento. Tenga en cuenta que si no desea que se muestre esta ventana durante el entrenamiento, puede establecer el parámetro `net.trainParam.showWindow` en falso. Si desea que la información de capacitación se muestre en la línea de comando, puede establecer el parámetro `net.trainParam.showCommandLine` en verdadero (Ploskas y Samaras 2016, p. 109-110).

La ventana de entrenamiento muestra toda la información disponible del entrenamiento y simulación de una red neuronal. Más específicamente, muestra:

- la estructura de su red neuronal.
- el método con el que se dividen los datos.
- el método de entrenamiento.
- la función de rendimiento.
- el modo de cálculo de entrenamiento.
- el número de épocas.
- el tiempo de entrenamiento.
- el rendimiento.
- la magnitud del gradiente de rendimiento.
- el factor μ .
- el número de comprobaciones de validación.
- el gráfico de rendimiento.
- la gráfica de estado de entrenamiento.
- el histograma de error.
- la gráfica de regresión.

CAPÍTULO III

3. MARCO METODOLÓGICO

3.1. Metodología del proyecto

El presente apartado expone el diseño metodológico que se siguió para la “Aplicación de un modelo de redes neuronales artificiales (RNA) para la dosificación adecuada de los colores en textiles de la empresa PROLAVTEX”. La propuesta se detalla en la Ilustración 3-1.

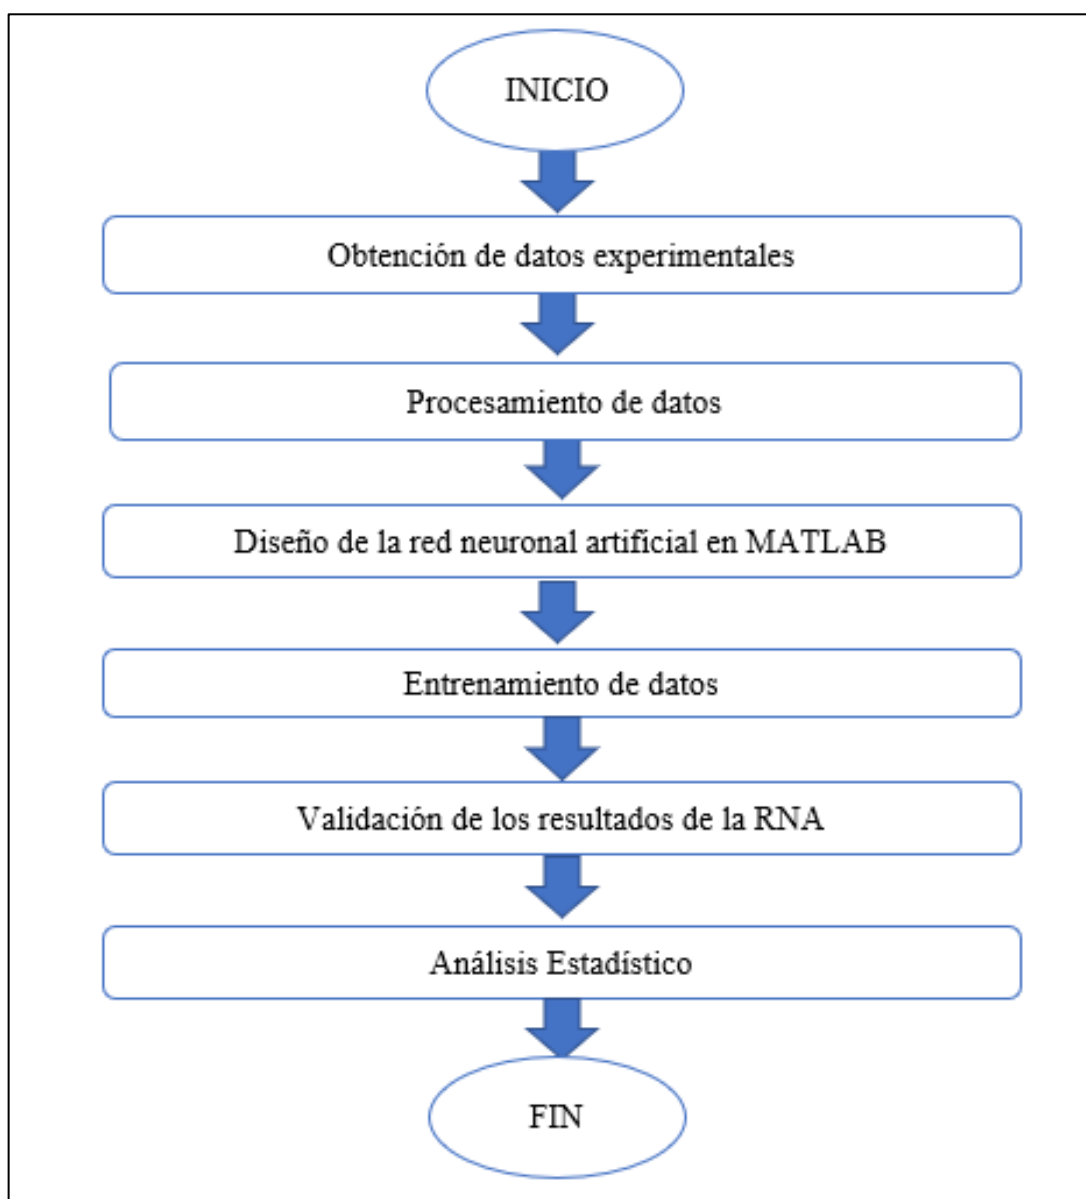


Ilustración 3-1: Metodología del trabajo de titulación

Realizado por: Ocaña, L., 2024.

Para el desarrollo de este trabajo de integración curricular primero se realizará una recopilación exhaustiva de datos experimentales mediante pruebas a textiles de la empresa PROLAVTEX. Posteriormente, se procederá a la preparación y preprocesamiento de estos datos para su alimentación al modelo de RNA.

Se determinará el número de capas ocultas y la arquitectura óptima para la red, de manera que sea capaz de predecir con precisión los resultados deseados. La red se entrenará con los datos obtenidos experimentalmente y se compararán con los resultados predichos para la validación. Por último, se llevará a cabo el análisis estadístico del modelo de RNA planteado, determinando la confiabilidad del mismo para la predicción.

La información recabada y utilizada para la redacción y aplicación del trabajo de integración curricular procede de fuentes:

Primarias: Conocimientos y datos experimentales recabados mediante pruebas realizadas en la empresa PROLAVTEX y procesamiento de datos utilizando herramientas informáticas como Microsoft Excel y Matlab.

Secundarias: Artículos científicos de alto impacto publicados en revistas Q1 y Q2, libros con temas relacionados a la investigación, tesis de grado y posgrado y páginas web oficiales de los softwares empleados.

3.2. Obtención de datos experimentales

La parte central del desarrollo de una red neuronal artificial es obtener un conjunto de datos de entrenamiento fiable y reproducible con el fin de que la red sea capaz de realizar predicciones precisas en datos no vistos. La calidad y cantidad de datos utilizados es un factor crítico en el éxito del entrenamiento de una red neuronal.

Por esto, para la obtención de datos reales se realizarán ensayos experimentales de tintura en textiles de la empresa PROLAVTEX mediante el proceso reactivo de teñido de colores claros que se realiza en la empresa. La tabla 3-1 detalla los parámetros de funcionamiento del proceso que se llevará a cabo. Los valores que se muestran se establecen para un peso de prendas de 0.5 kg.

Tabla 3-1: Parámetros de funcionamiento del proceso de tintura

Procesamiento	Artículo	Relación de baño	Temperatura	Tiempo	Cantidad
Descrude	Antiquiebre	40:1	60°C	12 min	40 g
Descrude	Humectante	40:1	60°C	12 min	10 g
Descrude	Detergente	40:1	60°C	12 min	40 g
Descrude	Alfamilasa	40:1	60°C	12 min	30 g
Tintura	Secuestrante	12:1	25°C	55 min	10 g
Tintura	Igualante	12:1	25°C	55 min	10 g
Tintura	Humectante	12:1	25°C	55 min	10 g
Tintura	Sal industrial	12:1	40°C	40 min	75 g
Tintura	Na ₂ CO ₃	12:1	50°C	30 min	30 g
Enjabonado	Asugal	20:1	50°C	10 min	10 g
Suavizado	Suavizante	12:1	40°C	10 min	40 g

Realizado por: Ocaña, L., 2024.

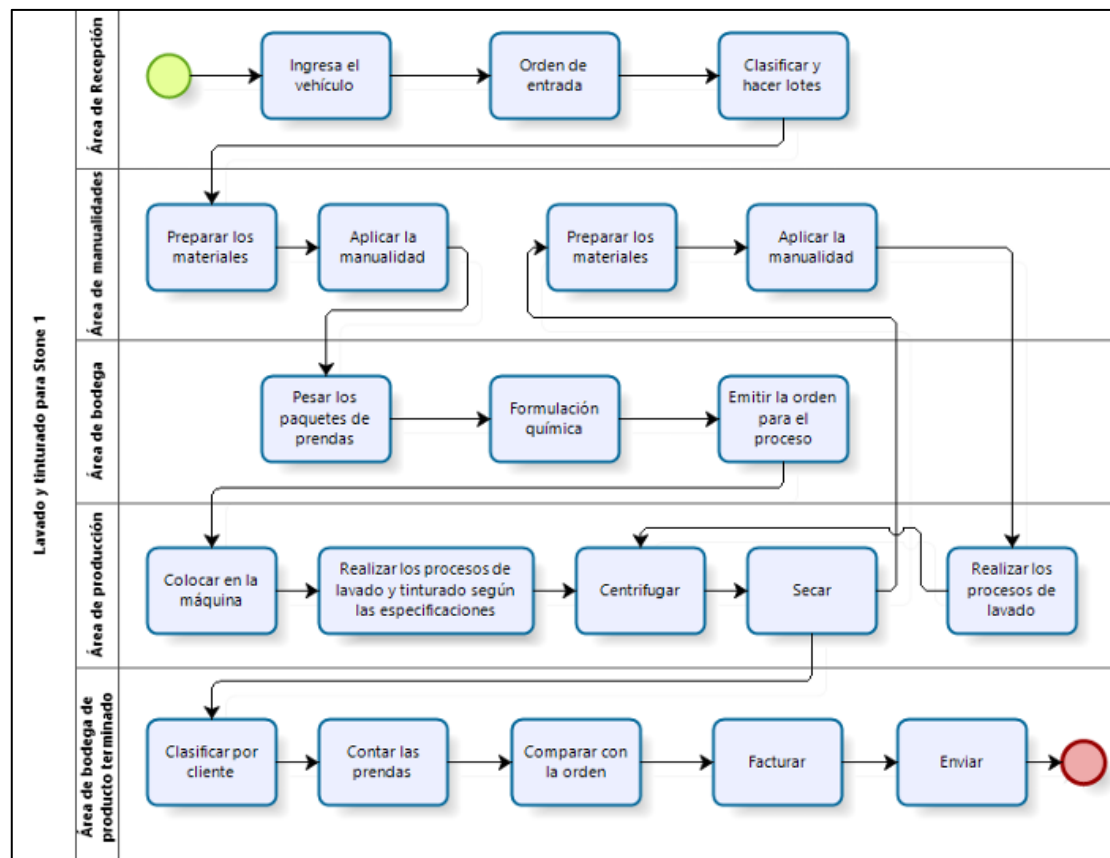


Ilustración 3-2: Flujograma de procesos de PROLAVTEX.

Fuente: Zurita Bayas, 2019.

En la empresa PROLAVTEX se realiza la tintura de las prendas textiles por dos métodos, en dependencia del tipo de tela que se esté tratando y el color que se quiera lograr. Estos procesos son: directo y reactivo. El proceso reactivo es el más extendido en las actividades de la empresa dado que permite conseguir colores que no se logran con el otro método mencionado. Además, este ofrece una mayor solidez del color, especialmente en términos de resistencia al lavado. Por otro lado, al implicar reacciones químicas y ser un proceso más complejo, la ejecución del proceso reactivo toma entre 2 y 3 horas, siendo menos accesible para la realización de ensayos experimentales. A pesar de esto, el proceso elegido para llevar a cabo las pruebas será el proceso reactivo, debido a la mayor variedad de colores que permite lograr y la resistencia de la tintura en el tiempo. La ilustración 3-2 resume en un diagrama de flujo las operaciones que componen el proceso de producción de la empresa PROLAVTEX.

El proceso de teñido reactivo es aquel en el que el tinte puede reaccionar con las fibra para formar un enlace covalente, es decir, formar una unión permanente en la fibra y no se puede eliminar mediante tratamientos repetidos con agua hirviendo en condiciones neutras. En consecuencia, los tintes pasan a formar parte de la fibra, lo que da lugar a una excelente solidez del color al lavado. (Shang, 2013, pág. 302). La ilustración 3-3 muestra una curva general de teñido reactivo. Es importante recalcar que la curva de teñido es propia de cada proceso y puede variar en dependencia de factores como el color o la tasa de agotamiento.




Ilustración 3-3: Curva general de teñido reactivo.

Fuente: Shang, 2013.

Los diferentes procesos de tintura se aplican de acuerdo al tipo de tejido que se quiera teñir (tabla 3-2). El teñido reactivo se usa principalmente en fibras celulósicas (algodón, viscosa, rayón, ...) dada la compatibilidad estas fibras con los colorantes reactivos, por lo que, estos colorantes se adhieren bien a la fibra (Shang, 2013, pág. 300-301). La composición de las muestras de tela que se utilizarán para este estudio es de 98% algodón y 2% elastano de acuerdo a lo que marca el fabricante.

Tabla 3-2: Clasificación de tintura de acuerdo a su uso

Tipo de tintura	Celulosa (algodón, viscosa, rayón)	Proteína (seda, lana)	Poliéster	Nylon	Acrílicos
Directa	X	-	-	-	-
Reactiva	X	X	-	-	-
Al azufre	X	-	-	-	-
De tina	X	-	-	-	-
Dispersa	-	-	X	-	X
Ácida	-	X	-	X	-
Básica	-	-	-	-	X

Fuente: Shang, 2013.

Realizado por: Ocaña, L., 2024.

Luego, para las pruebas se generan combinaciones con los colores primarios (amarillo, azul y rojo) de acuerdo a las formulaciones de las que dispone la empresa PROLAVTEX para colores específicos, de manera que se obtienen formulaciones coherentes para las variables implicadas. Como las prendas que se van a teñir en este proyecto son elaboradas a base de algodón, se utilizarán colorantes que tengan afinidad con este tipo de fibra y con el procedimiento que se va a seguir. Se usan los de tipo Bodactive ELF, que son colorantes reactivos de alto rendimiento diseñados para sustratos celulósicos. La tabla 3-3 detalla las formulaciones a usar en los ensayos con la cantidad (en peso) por colorante para cada una.

Tabla 3-3: Formulaciones de color utilizadas para las pruebas

Formulación	Amarillo	Azul	Rojo
1	0.25 g	0.35 g	0.20 g
2	0.25 g	0.10 g	0.10 g
3	0.50 g	0.05 g	0.05 g
4	0.40 g	1.00 g	0.35 g
5	0.20 g	0.20 g	0.10 g

Realizado por: Ocaña, L., 2024.

3.2.1. Descripción del proceso

El procedimiento que se usa para el teñido de cada muestra se realiza en 4 partes: descruce, tintura, enjabonado y suavizado. Este proceso se lo realiza en condiciones controladas y bajo la supervisión de los operarios experimentados de la empresa con el fin de obtener los mejores

resultados y que la tintura de los textiles sea la adecuada de acuerdo a los procedimientos que realiza PROLAVTEX. El proceso paso a paso se detalla a continuación:

3.2.1.1. *Descrude*

El descrude es un tratamiento preparatorio de determinados materiales textiles. Consiste en eliminar las impurezas solubles e insolubles que se encuentran en los textiles como aceites, ceras, grasas, materia vegetal, así como suciedad. La eliminación de estos contaminantes mediante el lavado prepara los textiles para procesos posteriores como el teñido (Orcón Basilio et al., 2019, pág. 176-177). El proceso de descrude se realizó de la siguiente manera:

- Se introdujo la prenda en la máquina de pruebas y se agregaron 20 litros de agua, procurando que la parte interna de la prenda esté hacia afuera.
- Se encendió la máquina y se agregaron los reactivos para el descrude. El antiqiebre para evitar que la prenda se arrugue o quiebre, el humectante para que las fibras no se resequen y el detergente para eliminar la suciedad (ilustración 3-4).



Ilustración 3-4: Incorporación de los reactivos

Realizado por: Ocaña, L., 2024.

- Se aumentó progresivamente la temperatura hasta los 60°C y se agregó la alfa amilasa para eliminar los almidones de la fibra.
- En este punto, se dejó que los reactivos actúen durante 12 minutos.
- Una vez transcurridos los 12 minutos, se realizaron tres enjuagues y la prenda quedó lista para la tintura.

3.2.1.2. Tintura

Es la parte principal del proceso y es donde la fibra textil absorbe las moléculas de tinte de su solución de modo que el material teñido retiene el tinte y resiste la liberación del tinte a la solución de la que ha sido absorbido (Grishanov, 2011, pág. 43). Se lleva a cabo después de que la prenda ha sido sometida al pretratamiento y las fibras están listas para absorber el tinte. El proceso de tintura que se realizó se describe a continuación:

- Luego de drenar el agua del proceso previo, se agregaron 6 litros agua.
- Se encendió la máquina de pruebas y se agregaron los primeros reactivos previo a los tintes. El agente secuestrante sirve eliminar los iones metálicos de la solución, el agente igualante mejora la afinidad de las fibras y el colorante, permitiendo un teñido uniforme y el humectante evita que se reseque la prenda.
- Durante 5 minutos, se aumentó la temperatura progresivamente hasta los 30°C. Cuando se alcanzó la temperatura deseada se agregaron los tres colorantes en la cantidad previamente determinada (ilustración 3-5).



Ilustración 3-5: Adición de los colorantes en el proceso de tintura

Realizado por: Ocaña, L., 2024.

- Una vez agregados los tintes, se elevó la temperatura 1°C/min durante 10 min hasta alcanzar los 40°C. En este punto, se añadió la sal industrial, que sirve para minimizar la decoloración de las fibras.

- En un lapso de 10 min se elevó la temperatura uniformemente de los 40°C hasta los 50°C. Cuando se llegó a los 50°C se añadió el carbonato de sodio (Na_2CO_3) para ajustar el pH del baño y mejorar la fijación del tinte.
- Por último, la temperatura se llevó hasta los 60°C y se extendió el proceso por 30 minutos manteniendo la temperatura constante. En este paso actúan todos los reactivos y el tinte penetra en las fibras de la prenda.

3.2.1.3. Enjabonado

La etapa de enjabonado se realiza para lograr la eliminación total del exceso de tinte no fijado presente en la superficie de la fibra y así obtener un producto teñido con excelente solidez. Además, sirve para dispersar el tinte eliminado en el baño y evitar que se vuelva a adherir a la fibra (Akcakoca et al., 2007, pág. 23-24). Esta etapa del proceso se realizó como se describe a continuación:

- Se agregaron 10 litros de agua en la máquina de pruebas. Previamente se enjuagó la máquina para eliminar cualquier residuo del proceso anterior.
- Se aumentó la temperatura de manera uniforme hasta los 50°C y se agregó el reactivo Asugal Albi (ilustración 3-6), que es un agente químico que sirve como auxiliar del jabonado y permite mejorar y facilitar la acción del jabón durante el proceso de lavado de las fibras.



Ilustración 3-6: Incorporación del auxiliar de jabonado

Realizado por: Ocaña, L., 2024.

- A una temperatura constante de 50°C se realizó el enjabonado de la prenda durante 10 minutos, de forma que se elimine totalmente el exceso de tinte.
- Se realizaron tres enjuagues a la prenda.

3.2.1.4. Suavizado

El suavizado se refiere al proceso que hace que la tela se sienta suave porque los textiles que se someten a un tratamiento térmico húmedo con diversos agentes químicos y a tensión mecánica durante el proceso de teñido sufren deformaciones en su estructura. Además, la exposición a estos efectos físicos y químicos causa rigidez y rugosidad en la tela (Paul, 2015, pág. 1-3). A continuación se detallan los pasos que se siguieron en el proceso de suavizado:

- En la máquina de pruebas, se introdujeron 6 litros de agua después de realizar un enjuague previo para eliminar cualquier residuo del proceso anterior.
- Luego, la temperatura se elevó de manera uniforme hasta alcanzar los 40°C, y se incorporó el agente suavizante, un compuesto químico destinado a mejorar la suavidad y manejabilidad de la prenda, proporcionándole un acabado más refinado.
- Bajo una temperatura constante de 40°C, se llevó a cabo el proceso de suavizado de la prenda durante un periodo de 10 minutos, logrando así un tacto más agradable y eliminando la rigidez.
- Finalmente, la prenda fue dirigida a la secadora para completar el proceso.



Ilustración 3-7: Ajuste de la temperatura de suavizado

Realizado por: Ocaña, L., 2024.

3.2.2. Medición del color

De acuerdo a las formulaciones que se muestran en la tabla 3-3, se tiñeron 4 muestras de tela con cada una de las combinaciones, de manera que se obtuvieron 20 muestras totales con las que se experimentaron. A cada una de estas unidades experimentales se les cuantificó el color mediante el programa de identificación de color *ColorMania*, identificador de color que indica valores para diferentes formatos de color. Estas mediciones se tomaron en 20 puntos diferentes de cada una de las muestras, generando un conjunto de 400 pares de datos para el entrenamiento de la RNA.

Para las mediciones de color se utilizó la aplicación *ColorMania* (ilustración 3-8) del desarrollador *Blacksun Software*, programa gratuito que brinda la posibilidad de elegir colores desde cualquier lugar de la pantalla y ofrece soporte para una serie de modelos de color (RGB, HTML, HSV, CMYK, entre otros), permitiendo cuantificar de manera objetiva el color y expresarlo en términos numéricos, obteniendo una medida precisa y reproducible del color. Se usó el modelo de color CMYK (Cian/Magenta/Amarillo/Negro) dado que *ColorMania* no permite medir directamente en términos del espacio de color CIELAB. Por esto, a partir de los valores CMYK, con la ayuda de un conversor de color en línea, se obtuvo los valores referentes a las coordenadas de color L, a*, b*.

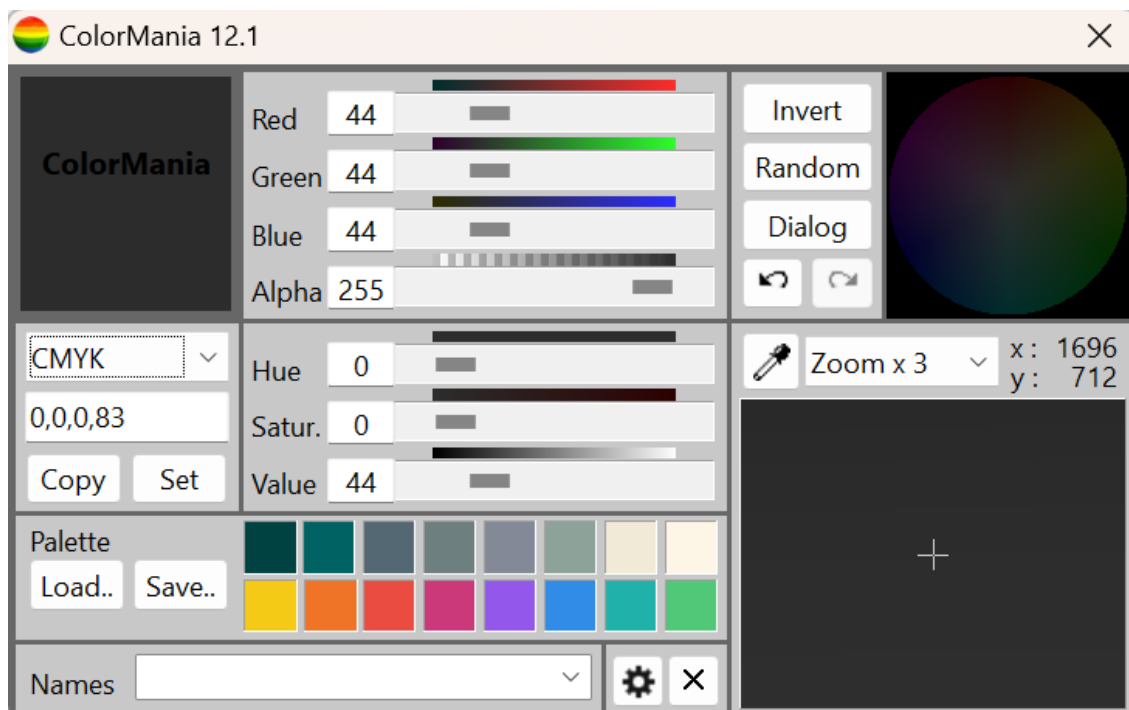


Ilustración 3-8: Interfaz principal del programa *ColorMania*

Realizado por: Ocaña, L., 2024.

CIELAB es un espacio de color que se define en 3 dimensiones: L para luminosidad y a^* - b^* para las dimensiones de color opuesto de rojo-verde y azul-amarillo (ilustración 3-9), respectivamente, basado en coordenadas del espacio de color CIE XYZ comprimidas no linealmente (Warner, 2024, pág. 480). Este sistema de coordenadas no solo permite identificar el color en términos físicos, sino que también brinda la posibilidad de ubicar el color en el espacio tridimensional, utilizado especialmente para objetos.




Ilustración 3-9: Representación del espacio de color CIELAB

Fuente: Warner, 2024.

Se realizaron 20 mediciones en diferentes puntos de las 4 muestras de las distintas formulaciones que se sometió al proceso de teñido. Con el fin de aumentar la uniformidad en las medidas, se realizaron en puntos específicos de los textiles y sin tomar en cuenta los extremos de los mismos.

3.3. Procesamiento de datos

La base de datos que se utilizarán para el diseño de la RNA se genera mediante la realización de las pruebas en los textiles de la empresa PROLAVTEX. Para esto, se realizaron 400 repeticiones con diferentes formulaciones para los valores de los parámetros de entrada, que se muestran en la tabla 3-3. Los 400 pares de datos experimentales que se recabaron se muestran en la tabla 3-6, mostrando valores para las variables de entrada y las variables de salida.

Tabla 3-4: Parámetros de entrada de la RNA

ENTRADAS		
Parámetro	Identificación	Unidad
Amarillo	Y	g
Azul	B	g
Rojo	R	g

Realizado por: Ocaña, Lisbeth, 2024.

Tabla 3-5: Parámetros de salida de la RNA

SALIDAS		
Parámetro	Identificación	Unidad
Luminosidad	L	-
Coordenadas rojo/verde	a*	-
Coordenadas amarillo/azul	b*	-

Realizado por: Ocaña, Lisbeth, 2024.

Los primeros 280 pares de datos del conjunto se seleccionarán para entrenar la red neuronal artificial en MATLAB, y los últimos 120 pares de datos se utilizarán para la validación y testeo del funcionamiento del modelo de predicción (ilustración 3-13).

Tabla 3-6: Base de datos generados para la RNA

ENTRADAS			SALIDAS		
Y	B	R	L	a*	b*
0.25	0.35	0.2	83.43	-2.55	-0.99
0.25	0.35	0.2	82.01	-2.53	-1.06
0.25	0.35	0.2	82.96	-3.18	0.2
0.25	0.35	0.2	83.66	-3.19	0.25
0.25	0.35	0.2	85.06	-3.22	0.33
0.25	0.35	0.2	82.01	-2.53	-1.06
0.25	0.35	0.2	82.96	-3.18	0.2
0.25	0.35	0.2	82.25	-3.16	0.16
0.25	0.35	0.2	84.89	-1.87	1.03
0.25	0.35	0.2	82.96	-3.18	0.2
0.25	0.35	0.2	84.36	-3.2	0.29
0.25	0.35	0.2	82.96	-3.18	0.2
0.25	0.35	0.2	82.72	-2.54	-1.03
0.25	0.35	0.2	84.36	-3.2	0.29
0.25	0.35	0.2	85.06	-3.22	0.33
0.25	0.35	0.2	84.36	-3.2	0.29
0.25	0.35	0.2	82.33	-2.28	0.32
0.25	0.35	0.2	82.01	-2.53	-1.06

0.25	0.35	0.2	82.96	-3.18	0.2
0.25	0.35	0.2	78.68	-3.09	-0.06
0.25	0.35	0.2	84.36	-3.2	0.29
0.25	0.35	0.2	82.96	-3.18	0.2
0.25	0.35	0.2	81.3	-2.52	-1.1
0.25	0.35	0.2	80.83	-3.13	0.07
0.25	0.35	0.2	85.61	-1.88	1.09
0.25	0.35	0.2	84.14	-2.56	-0.96
0.25	0.35	0.2	80.12	-3.12	0.03
0.25	0.35	0.2	82.96	-3.18	0.2
0.25	0.35	0.2	85.55	-2.57	-0.89
0.25	0.35	0.2	83.66	-3.19	0.25
0.25	0.35	0.2	83.46	-1.87	0.93
0.25	0.35	0.2	79.44	-2.25	0.13
0.25	0.35	0.2	82.96	-3.18	0.2
0.25	0.35	0.2	83.66	-3.19	0.25
0.25	0.35	0.2	83.51	-1.74	0.05
0.25	0.35	0.2	82.74	-1.87	0.87
0.25	0.35	0.2	80.89	-2.27	0.22
0.25	0.35	0.2	82.74	-1.87	0.87
0.25	0.35	0.2	78.73	-2.97	-0.84
0.25	0.35	0.2	82.96	-3.18	0.2
0.25	0.35	0.2	83.38	-2.68	-0.11
0.25	0.35	0.2	83.66	-3.19	0.25
0.25	0.35	0.2	84.68	-3.6	-0.18
0.25	0.35	0.2	82.96	-3.18	0.2
0.25	0.35	0.2	85.31	-2.01	-1.46
0.25	0.35	0.2	85.01	-3.34	1.14
0.25	0.35	0.2	85.76	-3.23	0.38
0.25	0.35	0.2	85.18	-2.3	0.51
0.25	0.35	0.2	85.74	-2.67	3
0.25	0.35	0.2	84.79	-2.7	-0.02
0.25	0.35	0.2	84.09	-2.69	-0.06
0.25	0.35	0.2	79.44	-2.25	0.13
0.25	0.35	0.2	82.96	-3.18	0.2
0.25	0.35	0.2	82.23	-2.51	1.9
0.25	0.35	0.2	81.54	-3.15	0.12
0.25	0.35	0.2	80.89	-2.27	0.22
0.25	0.35	0.2	80.16	-2.26	0.18
0.25	0.35	0.2	78.71	-2.25	0.08
0.25	0.35	0.2	78.76	-2.12	-0.76
0.25	0.35	0.2	77.23	-2.23	0
0.25	0.35	0.2	82.25	-3.16	0.16
0.25	0.35	0.2	82.25	-3.16	0.16
0.25	0.35	0.2	82.96	-3.18	0.2
0.25	0.35	0.2	82.72	-2.54	-1.03

0.25	0.35	0.2	82.28	-2.4	1.12
0.25	0.35	0.2	82.96	-3.18	0.2
0.25	0.35	0.2	85.06	-3.22	0.33
0.25	0.35	0.2	82.25	-3.16	0.16
0.25	0.35	0.2	80.16	-2.26	0.18
0.25	0.35	0.2	83.46	-1.87	0.93
0.25	0.35	0.2	82.25	-3.16	0.16
0.25	0.35	0.2	80.12	-3.12	0.03
0.25	0.35	0.2	80.89	-2.27	0.22
0.25	0.35	0.2	84.36	-3.2	0.29
0.25	0.35	0.2	84.95	-1.74	0.14
0.25	0.35	0.2	80.89	-2.27	0.22
0.25	0.35	0.2	82.74	-1.87	0.87
0.25	0.35	0.2	83.66	-3.19	0.25
0.25	0.35	0.2	80.84	-2.38	1.02
0.25	0.35	0.2	84.36	-3.2	0.29
0.25	0.1	0.1	84.8	2.45	13.49
0.25	0.1	0.1	86.1	2.44	14.58
0.25	0.1	0.1	84.3	3	14.07
0.25	0.1	0.1	82.26	2.88	13.62
0.25	0.1	0.1	84.8	2.45	13.49
0.25	0.1	0.1	84.8	2.45	13.49
0.25	0.1	0.1	84.25	2.91	14.83
0.25	0.1	0.1	82.9	2.83	14.52
0.25	0.1	0.1	86.15	2.53	13.8
0.25	0.1	0.1	87.54	2.62	14.12
0.25	0.1	0.1	84.92	2.95	14.99
0.25	0.1	0.1	82.26	2.88	13.62
0.25	0.1	0.1	84.12	2.41	13.35
0.25	0.1	0.1	83.2	1.7	13.24
0.25	0.1	0.1	89.54	2.76	14.59
0.25	0.1	0.1	84.8	2.45	13.49
0.25	0.1	0.1	83.39	2.29	13.96
0.25	0.1	0.1	84.8	2.45	13.49
0.25	0.1	0.1	84.8	2.45	13.49
0.25	0.1	0.1	82.26	2.88	13.62
0.25	0.1	0.1	82.26	2.88	13.62
0.25	0.1	0.1	82.94	2.92	13.77
0.25	0.1	0.1	82.26	2.88	13.62
0.25	0.1	0.1	81.58	2.83	13.47
0.25	0.1	0.1	85.64	3.09	14.38
0.25	0.1	0.1	84.75	2.36	14.26
0.25	0.1	0.1	84.8	2.45	13.49
0.25	0.1	0.1	80.89	2.79	13.31
0.25	0.1	0.1	85.33	2.21	15.97
0.25	0.1	0.1	88.82	2.62	15.24

0.25	0.1	0.1	84.98	3.04	14.22
0.25	0.1	0.1	83.39	2.29	13.96
0.25	0.1	0.1	81.58	2.83	13.47
0.25	0.1	0.1	85.64	3.09	14.38
0.25	0.1	0.1	86.32	3.14	14.54
0.25	0.1	0.1	86.15	2.53	13.8
0.25	0.1	0.1	82.26	2.88	13.62
0.25	0.1	0.1	85.64	3.09	14.38
0.25	0.1	0.1	85.48	2.49	13.64
0.25	0.1	0.1	84.07	2.32	14.11
0.25	0.1	0.1	86.78	2.48	14.74
0.25	0.1	0.1	83.39	2.29	13.96
0.25	0.1	0.1	86.1	2.44	14.58
0.25	0.1	0.1	84.07	2.32	14.11
0.25	0.1	0.1	86.15	2.53	13.8
0.25	0.1	0.1	86.1	2.44	14.58
0.25	0.1	0.1	83.57	2.87	14.68
0.25	0.1	0.1	82.94	2.92	13.77
0.25	0.1	0.1	90.1	2.61	16.38
0.25	0.1	0.1	84.98	3.04	14.22
0.25	0.1	0.1	84.7	2.27	15.03
0.25	0.1	0.1	83.39	2.29	13.96
0.25	0.1	0.1	88.22	2.67	14.28
0.25	0.1	0.1	84.07	2.32	14.11
0.25	0.1	0.1	85.64	3.09	14.38
0.25	0.1	0.1	84.07	2.32	14.11
0.25	0.1	0.1	87.54	2.62	14.12
0.25	0.1	0.1	84.75	2.36	14.26
0.25	0.1	0.1	85.48	2.49	13.64
0.25	0.1	0.1	84.8	2.45	13.49
0.25	0.1	0.1	86.1	2.44	14.58
0.25	0.1	0.1	88.82	2.62	15.24
0.25	0.1	0.1	85.43	2.4	14.41
0.25	0.1	0.1	81.32	2.17	13.5
0.25	0.1	0.1	87.49	2.53	14.92
0.25	0.1	0.1	86.32	3.14	14.54
0.25	0.1	0.1	84.07	2.32	14.11
0.25	0.1	0.1	81.37	2.26	12.76
0.25	0.1	0.1	85.54	2.91	15.94
0.25	0.1	0.1	88.87	2.71	14.44
0.25	0.1	0.1	82.26	2.88	13.62
0.25	0.1	0.1	79.93	2.1	13.19
0.25	0.1	0.1	88.17	2.58	15.08
0.25	0.1	0.1	85.64	3.09	14.38
0.25	0.1	0.1	83.34	2.2	14.72
0.25	0.1	0.1	80.89	2.79	13.31

0.25	0.1	0.1	85.54	2.91	15.94
0.25	0.1	0.1	85.64	3.09	14.38
0.25	0.1	0.1	83.44	2.38	13.2
0.25	0.1	0.1	83.57	2.87	14.68
0.5	0.05	0.05	90.48	4.59	27.34
0.5	0.05	0.05	84.41	5.19	28.39
0.5	0.05	0.05	87.76	5.7	27.94
0.5	0.05	0.05	86.03	3.42	25.83
0.5	0.05	0.05	91.64	4.62	28.67
0.5	0.05	0.05	86.95	4.93	26.85
0.5	0.05	0.05	85.04	5.26	28.63
0.5	0.05	0.05	86.95	4.93	26.85
0.5	0.05	0.05	89.47	4.34	28.76
0.5	0.05	0.05	90.42	4.51	28.22
0.5	0.05	0.05	89.52	4.42	27.89
0.5	0.05	0.05	86.37	5.48	28.29
0.5	0.05	0.05	86.37	5.48	28.29
0.5	0.05	0.05	86.29	4.86	26.61
0.5	0.05	0.05	88.39	5.63	29.95
0.5	0.05	0.05	85.67	5.33	28.88
0.5	0.05	0.05	87.98	3.58	26.53
0.5	0.05	0.05	85.72	5.41	28.04
0.5	0.05	0.05	87.02	5.55	28.54
0.5	0.05	0.05	84.89	4.06	25.33
0.5	0.05	0.05	85.6	4.72	27.21
0.5	0.05	0.05	87.02	5.55	28.54
0.5	0.05	0.05	86.67	3.47	26.06
0.5	0.05	0.05	86.95	4.93	26.85
0.5	0.05	0.05	85.6	4.72	27.21
0.5	0.05	0.05	88.49	5.79	28.22
0.5	0.05	0.05	86.24	4.78	27.45
0.5	0.05	0.05	88.34	5.15	26.48
0.5	0.05	0.05	88.87	4.91	30.22
0.5	0.05	0.05	86.61	6.34	27.44
0.5	0.05	0.05	83.75	5.11	28.13
0.5	0.05	0.05	83.71	5.05	28.96
0.5	0.05	0.05	89.52	4.42	27.89
0.5	0.05	0.05	86.32	5.4	29.14
0.5	0.05	0.05	87.6	5	27.09
0.5	0.05	0.05	85.55	4.64	28.05
0.5	0.05	0.05	85.6	4.72	27.21
0.5	0.05	0.05	86.29	4.86	26.61
0.5	0.05	0.05	86.18	4.18	25.8
0.5	0.05	0.05	85.37	3.36	25.59
0.5	0.05	0.05	87.32	3.53	26.29
0.5	0.05	0.05	88.44	5.71	29.08

0.5	0.05	0.05	92.82	3.37	26.56
0.5	0.05	0.05	88.7	3.72	25.92
0.5	0.05	0.05	85.55	4.12	25.57
0.5	0.05	0.05	88.92	4.99	29.35
0.5	0.05	0.05	86.95	4.93	26.85
0.5	0.05	0.05	87.53	4.38	25.42
0.5	0.05	0.05	90.14	3.84	26.43
0.5	0.05	0.05	88.44	5.71	29.08
0.5	0.05	0.05	90.48	4.59	27.34
0.5	0.05	0.05	87.02	5.55	28.54
0.5	0.05	0.05	86.29	4.86	26.61
0.5	0.05	0.05	90.32	4.35	29.98
0.5	0.05	0.05	86.32	5.4	29.14
0.5	0.05	0.05	88.44	5.71	29.08
0.5	0.05	0.05	91.44	3.04	28.78
0.5	0.05	0.05	89.33	5.81	29.43
0.5	0.05	0.05	87.65	5.55	29.66
0.5	0.05	0.05	89.47	4.34	28.76
0.5	0.05	0.05	86.37	5.48	28.29
0.5	0.05	0.05	87.02	5.55	28.54
0.5	0.05	0.05	85.72	5.41	28.04
0.5	0.05	0.05	88.54	5.87	27.36
0.5	0.05	0.05	86.18	4.18	25.8
0.5	0.05	0.05	91.64	4.62	28.67
0.5	0.05	0.05	89.87	5.16	28.82
0.5	0.05	0.05	88.44	5.71	29.08
0.5	0.05	0.05	86.67	3.47	26.06
0.5	0.05	0.05	88.8	6.46	30.04
0.5	0.05	0.05	90.26	4.27	30.86
0.5	0.05	0.05	84.63	6.03	27.55
0.5	0.05	0.05	84.84	3.98	26.16
0.5	0.05	0.05	86.46	6.12	29.99
0.5	0.05	0.05	90.32	4.35	29.98
0.5	0.05	0.05	87.7	5.63	28.8
0.5	0.05	0.05	85.6	4.72	27.21
0.5	0.05	0.05	88.44	5.71	29.08
0.5	0.05	0.05	86.95	4.93	26.85
0.5	0.05	0.05	86.95	4.93	26.85
0.4	1	0.35	66.85	-3.61	-2.41
0.4	1	0.35	69.4	-4.14	-2.08
0.4	1	0.35	69.45	-4.03	-2.78
0.4	1	0.35	65.94	-3.62	-4.4
0.4	1	0.35	66.98	-4.26	-3.22
0.4	1	0.35	69.75	-3.72	-2.37
0.4	1	0.35	70.89	-4.09	-2.77
0.4	1	0.35	65.59	-4.07	-3.94

0.4	1	0.35	68.72	-4	-2.79
0.4	1	0.35	67.3	-4.84	-2.28
0.4	1	0.35	71.62	-4.12	-2.76
0.4	1	0.35	68.3	-5.57	-0.71
0.4	1	0.35	65.54	-4.19	-3.21
0.4	1	0.35	68.35	-3.54	-3.14
0.4	1	0.35	70.89	-4.09	-2.77
0.4	1	0.35	67.28	-3.94	-2.8
0.4	1	0.35	68.37	-4.44	-2.52
0.4	1	0.35	68.83	-3.73	-4.44
0.4	1	0.35	69.07	-3.57	-3.13
0.4	1	0.35	69.45	-4.03	-2.78
0.4	1	0.35	68	-3.97	-2.8
0.4	1	0.35	69.36	-3.27	-2.74
0.4	1	0.35	68.77	-3.88	-3.54
0.4	1	0.35	63.95	-3.49	-2.41
0.4	1	0.35	69.45	-4.03	-2.78
0.4	1	0.35	69.36	-3.27	-2.74
0.4	1	0.35	66.98	-4.26	-3.22
0.4	1	0.35	65.4	-3.55	-2.41
0.4	1	0.35	66.26	-4.23	-3.22
0.4	1	0.35	69.4	-4.14	-2.08
0.4	1	0.35	67.57	-3.64	-2.4
0.4	1	0.35	66.12	-3.58	-2.41
0.4	1	0.35	67.57	-3.64	-2.4
0.4	1	0.35	68	-3.97	-2.8
0.4	1	0.35	66.85	-3.61	-2.41
0.4	1	0.35	66.12	-3.58	-2.41
0.4	1	0.35	68.98	-3.8	-1.68
0.4	1	0.35	64.82	-4.26	-3.2
0.4	1	0.35	66.04	-3.8	-1.09
0.4	1	0.35	65.03	-4.06	-1.49
0.4	1	0.35	68.72	-4	-2.79
0.4	1	0.35	69.8	-3.6	-3.13
0.4	1	0.35	68.05	-3.85	-3.54
0.4	1	0.35	64.15	-4	-3.91
0.4	1	0.35	67.28	-3.94	-2.8
0.4	1	0.35	67.28	-3.94	-2.8
0.4	1	0.35	67.33	-3.82	-3.54
0.4	1	0.35	66.12	-3.58	-2.41
0.4	1	0.35	66.98	-4.26	-3.22
0.4	1	0.35	68	-3.97	-2.8
0.4	1	0.35	65.54	-4.19	-3.21
0.4	1	0.35	66.12	-3.58	-2.41
0.4	1	0.35	66.26	-4.23	-3.22
0.4	1	0.35	68.77	-3.88	-3.54

0.4	1	0.35	63.95	-3.49	-2.41
0.4	1	0.35	67.28	-3.94	-2.8
0.4	1	0.35	67.28	-3.94	-2.8
0.4	1	0.35	64.82	-4.26	-3.2
0.4	1	0.35	64.68	-3.52	-2.41
0.4	1	0.35	65.4	-3.55	-2.41
0.4	1	0.35	70.22	-3.94	-3.54
0.4	1	0.35	65.59	-4.07	-3.94
0.4	1	0.35	65.51	-3.29	-3.99
0.4	1	0.35	65.54	-4.19	-3.21
0.4	1	0.35	69.45	-4.03	-2.78
0.4	1	0.35	68	-3.97	-2.8
0.4	1	0.35	65.59	-4.07	-3.94
0.4	1	0.35	65.4	-3.55	-2.41
0.4	1	0.35	70.17	-4.06	-2.77
0.4	1	0.35	68.77	-3.88	-3.54
0.4	1	0.35	66.84	-4.59	-1.23
0.4	1	0.35	64.15	-4	-3.91
0.4	1	0.35	71.62	-4.12	-2.76
0.4	1	0.35	69.45	-4.03	-2.78
0.4	1	0.35	68	-3.97	-2.8
0.4	1	0.35	66.26	-4.23	-3.22
0.4	1	0.35	68.05	-3.85	-3.54
0.4	1	0.35	67.28	-3.94	-2.8
0.4	1	0.35	65.51	-3.29	-3.99
0.4	1	0.35	69.5	-3.91	-3.54
0.2	0.2	0.1	82.06	-3.62	3.21
0.2	0.2	0.1	83.51	-3.54	2.59
0.2	0.2	0.1	82.44	-3.9	2.02
0.2	0.2	0.1	82.81	-3.52	2.53
0.2	0.2	0.1	81.4	-3.49	2.4
0.2	0.2	0.1	82.81	-3.52	2.53
0.2	0.2	0.1	83.51	-3.54	2.59
0.2	0.2	0.1	82.81	-3.52	2.53
0.2	0.2	0.1	79.62	-3.82	1.79
0.2	0.2	0.1	81.35	-3.6	3.14
0.2	0.2	0.1	84.96	-3.46	1.93
0.2	0.2	0.1	81.35	-3.6	3.14
0.2	0.2	0.1	81.4	-3.49	2.4
0.2	0.2	0.1	81.4	-3.49	2.4
0.2	0.2	0.1	82.39	-4.01	2.77
0.2	0.2	0.1	82.76	-3.64	3.27
0.2	0.2	0.1	82.06	-3.62	3.21
0.2	0.2	0.1	82.44	-3.9	2.02
0.2	0.2	0.1	81.4	-3.49	2.4
0.2	0.2	0.1	82.39	-4.01	2.77

0.2	0.2	0.1	83.09	-4.03	2.83
0.2	0.2	0.1	82.44	-3.9	2.02
0.2	0.2	0.1	83.04	-4.51	3.61
0.2	0.2	0.1	81.4	-3.49	2.4
0.2	0.2	0.1	82.03	-4.38	2.27
0.2	0.2	0.1	83.79	-4.05	2.9
0.2	0.2	0.1	83.84	-3.94	2.14
0.2	0.2	0.1	82.76	-3.64	3.27
0.2	0.2	0.1	79.98	-4.94	0.46
0.2	0.2	0.1	82.01	-3.73	3.97
0.2	0.2	0.1	82.8	-5.37	5.81
0.2	0.2	0.1	82.39	-4.01	2.77
0.2	0.2	0.1	81.04	-3.86	1.91
0.2	0.2	0.1	83.79	-4.05	2.9
0.2	0.2	0.1	82.39	-4.01	2.77
0.2	0.2	0.1	81.35	-3.6	3.14
0.2	0.2	0.1	81.69	-3.99	2.71
0.2	0.2	0.1	81.23	-4.6	3.77
0.2	0.2	0.1	81.35	-3.6	3.14
0.2	0.2	0.1	83.26	-4.79	4.77
0.2	0.2	0.1	82.76	-3.64	3.27
0.2	0.2	0.1	81.69	-3.99	2.71
0.2	0.2	0.1	82.39	-4.01	2.77
0.2	0.2	0.1	81.35	-3.6	3.14
0.2	0.2	0.1	80.99	-3.97	2.64
0.2	0.2	0.1	81.69	-3.99	2.71
0.2	0.2	0.1	83.14	-3.92	2.08
0.2	0.2	0.1	82.76	-3.64	3.27
0.2	0.2	0.1	83.37	-4.55	3.17
0.2	0.2	0.1	82.06	-3.62	3.21
0.2	0.2	0.1	81.69	-3.99	2.71
0.2	0.2	0.1	82.1	-3.51	2.47
0.2	0.2	0.1	82.76	-3.64	3.27
0.2	0.2	0.1	83.79	-4.05	2.9
0.2	0.2	0.1	82.39	-4.01	2.77
0.2	0.2	0.1	82.76	-3.64	3.27
0.2	0.2	0.1	82.06	-3.62	3.21
0.2	0.2	0.1	81.69	-3.99	2.71
0.2	0.2	0.1	81.35	-3.6	3.14
0.2	0.2	0.1	80.99	-3.97	2.64
0.2	0.2	0.1	83.79	-4.05	2.9
0.2	0.2	0.1	82.39	-4.01	2.77
0.2	0.2	0.1	81.69	-3.99	2.71
0.2	0.2	0.1	80.99	-3.97	2.64
0.2	0.2	0.1	83.79	-4.05	2.9
0.2	0.2	0.1	85.17	-4.09	3.02

0.2	0.2	0.1	83.79	-4.05	2.9
0.2	0.2	0.1	83.09	-4.03	2.83
0.2	0.2	0.1	81.35	-3.6	3.14
0.2	0.2	0.1	83.79	-4.05	2.9
0.2	0.2	0.1	83.04	-4.51	3.61
0.2	0.2	0.1	82.39	-4.01	2.77
0.2	0.2	0.1	81.35	-3.6	3.14
0.2	0.2	0.1	83.09	-4.03	2.83
0.2	0.2	0.1	83.79	-4.05	2.9
0.2	0.2	0.1	82.81	-3.52	2.53
0.2	0.2	0.1	83.09	-4.03	2.83
0.2	0.2	0.1	80.99	-3.97	2.64
0.2	0.2	0.1	82.1	-3.51	2.47
0.2	0.2	0.1	82.39	-4.01	2.77

Realizado por: Ocaña, Lisbeth, 2024.

3.4. Diseño de la RNA en MATLAB

El primer paso para el diseño de una red neuronal artificial es establecer los parámetros de entrada y salida. En este caso se utilizarán 3 variables de entrada que darán lugar 3 variables de salida, con las que se entrenará el modelo. Las tablas 3-4 y 3-5 especifican las variables de entrada y salida del proceso que se tomaron en cuenta. La ilustración 3-10 muestra cómo se introducen los datos para las entradas y salidas de la RNA.

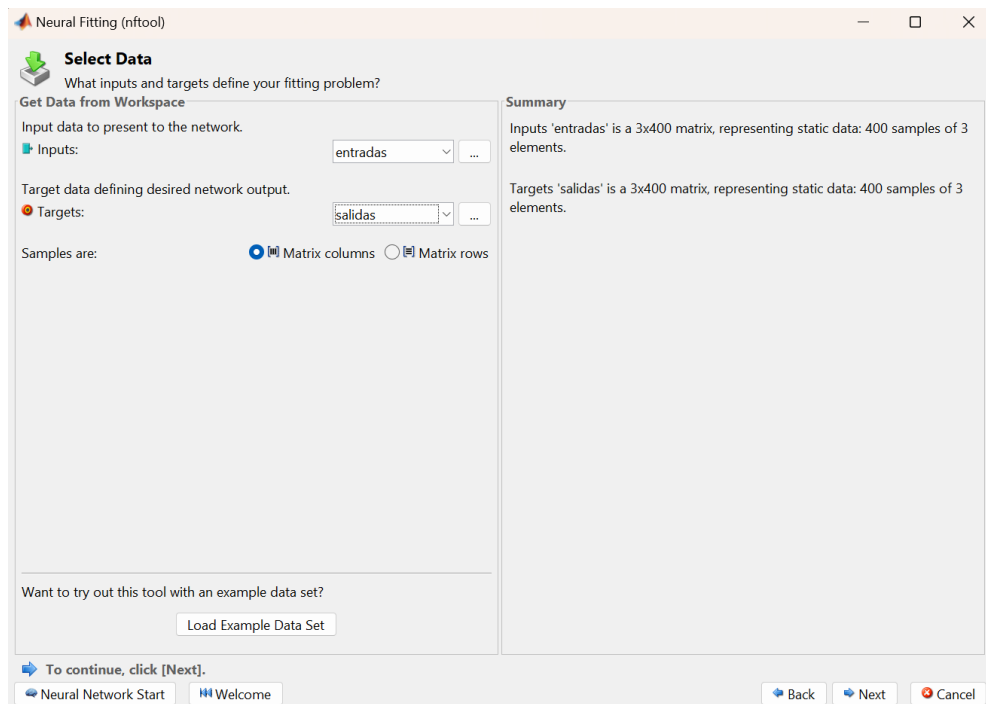


Ilustración 3-10: Selección de los parámetros de entrada y salida

Realizado por: Ocaña, L., 2024.

Resulta conveniente normalizar los datos obtenidos de los parámetros de entrada y salida escogidos para la red (ilustración 3-11), ya que esto ayuda a acondicionar los datos y que el procesamiento sea óptimo. La normalización de los datos se realizará con la siguiente ecuación:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (4)$$

Donde:

x' = valor normalizado

x = valor obtenido

x_{max} = valor máximo

x_{min} = valor mínimo

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
1	DATOS														
2	0.66666667	0.16666667	0	0.66666667	0	1	0	1	0.16666667	0.16666667	0.66666667	0.66666667	0	1	0.16666667
3	1	0.31578947	0.15789474	1	0.15789474	0	0.15789474	0	0.05263158	0.05263158	1	1	0.15789474	0	0.05263158
4	1	0.5	0.16666667	1	0.16666667	0	0.16666667	0	0.16666667	0.16666667	1	1	0.16666667	0	0.16666667
5	0.19050918	0.7253204	0.68721857	0.20263249	0.59023207	0.74194666	0.6144787	0.76480776	0.76723242	0.75129893	0.14028403	0.19050918	0.67267059	0.95912712	0.69691722
6	0.1280133	0.30756442	0.12635079	0.16375727	0.13300083	0.74231089	0.13133832	0.74729842	0.66583541	0.719867	0.13300083	0.1280133	0.08478803	0.84704904	0.65586035
7	0.0470255	0.15495751	0.20793201	0.03711048	0.20056657	0.85070822	0.20254958	0.85750708	0.5388102	0.53314448	0.04645892	0.0470255	0.21558074	0.93796034	0.52549575
8															
9															
10															
11															
12															
13															
14															
15															
16															
17															
18															
19															
20															

Ilustración 3-11: Datos normalizados dispuestos en forma de matriz en Excel

Realizado por: Ocaña, L., 2024.

3.5. Entrenamiento de datos

Después de normalizar los datos obtenidos, la red neuronal se construirá con la ayuda de la herramienta Neural Net Fitting que es la interfaz gráfica de usuario que ofrece MATLAB para facilitar el proceso de diseño, entrenamiento y evaluación de redes neuronales (ilustración 3-12). En este punto, se introduce la base de datos con la que se cuenta, diferenciando entre aquellos datos correspondientes a variables de entrada y salida.

De la misma forma, para entrenar al modelo de la red neuronal artificial debemos determinar su arquitectura, ya que esto definirá cómo la red procesa la información de entrada y genera la salida

correspondiente. Se elige la topología de red (número de neuronas en la capa oculta) que arroja mejores resultados de acuerdo a los indicadores de desempeño que ofrece la herramienta Neural Net Fitting de MATLAB.

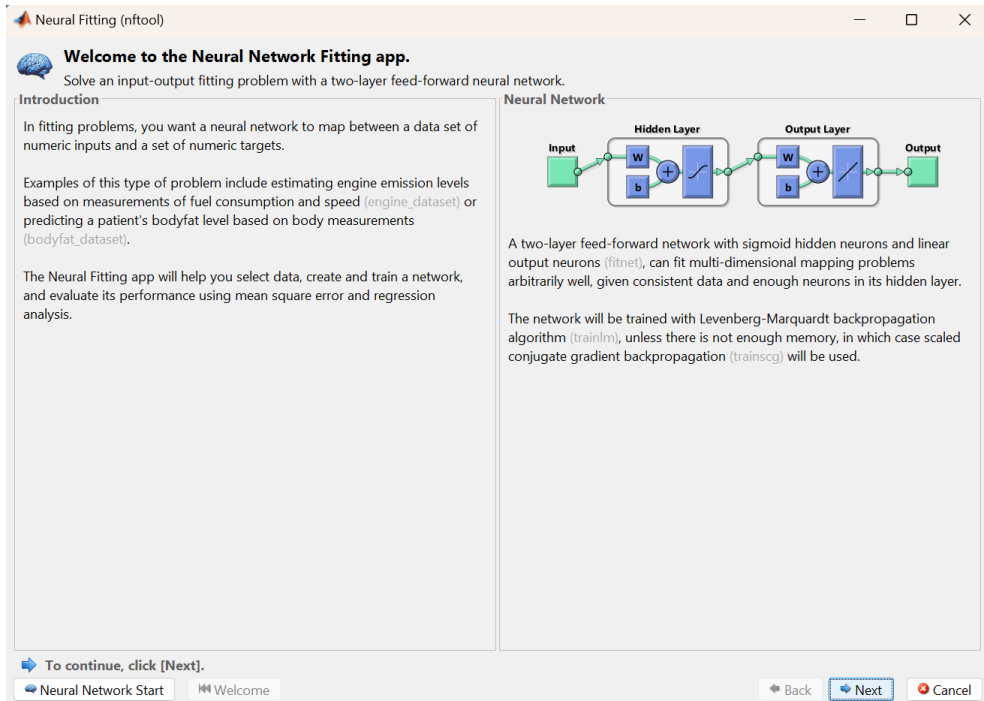


Ilustración 3-12: Herramienta Neural Net Fitting (nftool)

Realizado por: Ocaña, L., 2024.

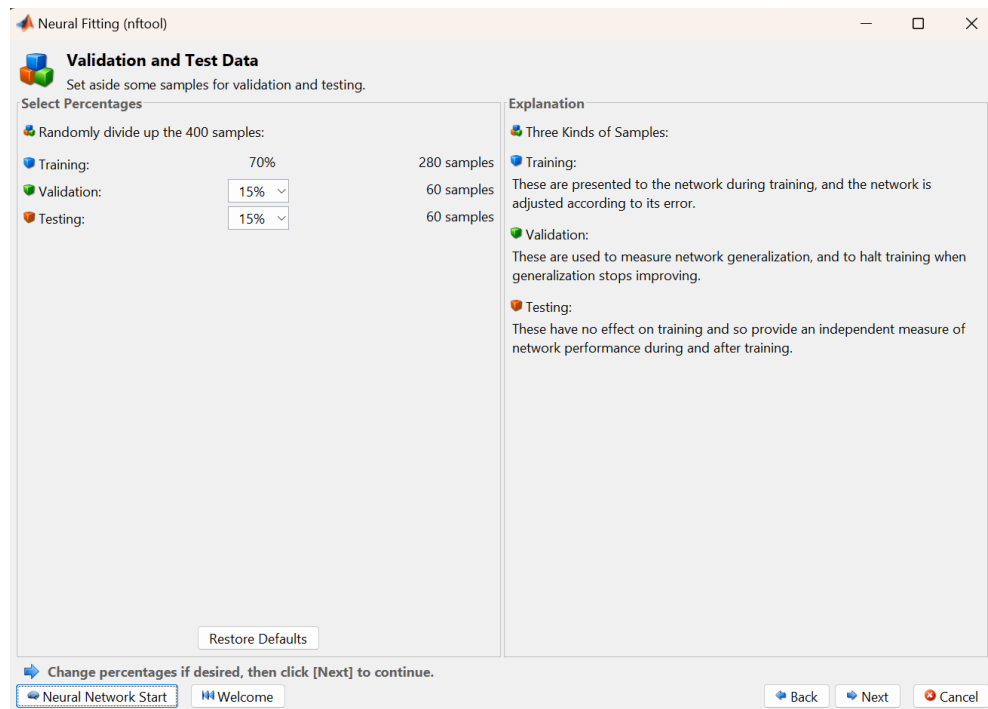


Ilustración 3-13: Datos destinados a cada etapa de la creación de la RNA

Realizado por: Ocaña, L., 2024.

El primer indicador de desempeño es el error cuadrático medio (MSE), que nos indica "cuánto" error existe entre los datos reales y los predichos, y evalúa la calidad del modelo de regresión. Se determina por la siguiente ecuación:

$$\text{MSE} = \frac{1}{n} \sum_{t=1}^n (y_t - y'_t)^2 \quad (5)$$

Donde:

n = número de observaciones

y_t = resultados experimentales

y'_t = resultados predichos

Por otro lado, el coeficiente de correlación de Pearson (R) mide la relación lineal existente entre dos variables. En este caso, entre los resultados experimentales y los resultados del modelo. Un valor de R igual a 1 indica una relación lineal entre las variables comparadas, es decir, entre más cercano sea este valor a 1, mejor será el desempeño de la topología de red. La fórmula para el cálculo de R es:

$$R = \frac{n \sum_{i=1}^n (y'y) [\sum_{i=1}^n y'] [\sum_{i=1}^n y]}{\sqrt{[n \sum_{i=1}^n y^2 - \sum_{i=1}^n y^2] [n \sum_{i=1}^n y'^2 - \sum_{i=1}^n y'^2]}} \quad (6)$$

Donde:

R = coeficiente de correlación de Pearson

y = resultados experimentales

y' = resultados predichos

En cuanto a los algoritmos para el entrenamiento de la RNA, MATLAB ofrece tres opciones: Levenberg-Marquardt (el más comúnmente utilizado), Bayesian Regularization y Scaled Conjugate Gradient (ilustración 3-14). Se utilizaron los dos primeros algoritmos para las pruebas de topología de red y se eligió el que mejores resultados arrojó.

El algoritmo Levenberg-Marquardt es un algoritmo popular de región de confianza que se utiliza para encontrar el mínimo de una función (ya sea lineal o no lineal) en un espacio de parámetros (Merjulah y Chandra, 2019, pág. 212). Por otro lado, el algoritmo de regularización bayesiana (Bayesian Regularization) es otro algoritmo que se aplica con frecuencia para entrenar redes neuronales artificiales de perceptrón multicapa. Esta puede considerarse como una forma del algoritmo

Levenberg-Marquardt, ya que utiliza su concepto al actualizar los pesos y sesgos en el algoritmo (Hemmati-Sarapardeh et al., 2020, pág. 54).

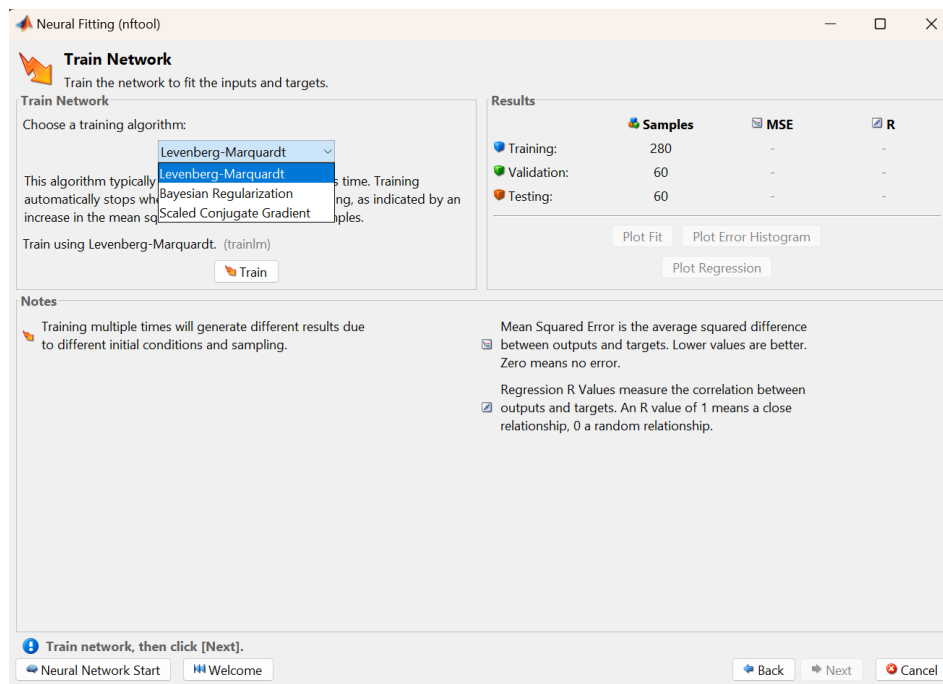


Ilustración 3-14: Algoritmos de entrenamiento disponibles en MATLAB®

Realizado por: Ocaña, L., 2024.

3.6. Validación de resultados de la RNA

Es fundamental la validación del modelo de RNA, ya que, de esta forma se demuestra cuán confiable es la red neuronal para la predicción en la dosificación de tintes en los textiles. Para validar el modelo, se realizará una comparación de los resultados arrojados por la red neuronal artificial con los previamente obtenidos experimentalmente mediante ensayos con los textiles de la empresa PROLAVTEX. Para esto se utilizará un conjunto de X pares de datos experimentales y la predicción se evaluará detalladamente mediante un análisis gráfico y estadístico.

El diseño para el entrenamiento de la red neuronal en MATLAB se distribuirá de la siguiente manera: del total de la base de datos disponibles, el 70% de los pares de datos son destinados al entrenamiento y serán los datos que servirán como base del aprendizaje de la red neuronal, el 15% de los pares de datos se destinarán a la prueba de funcionamiento de la red, midiendo la capacidad de la red para realizar predicciones precisas en datos no vistos, y el porcentaje restante de datos del conjunto se utilizarán para la validación y proporcionarán una visión de la calidad de resultados que ofrece el modelo de predicción dado que se están utilizando datos independientes de los que se usaron para el entrenamiento.

Además, debido a que el software utilizado no valida internamente el modelo a partir del conjunto de datos que se ingresó, se validará la red de forma externa, usando 20 valores distintos de los parámetros de entrada y así corroborar la calidad de los resultados de la red mediante la comparación de los resultados experimentales y los predichos.

3.7. Análisis estadístico

Por último, se realizará un análisis estadístico usando los resultados obtenido con el modelo de predicción realizado con la herramienta Neural Net Fitting del software MATLAB en contraste con los datos obtenidos experimentalmente en los ensayos realizados en la empresa PROLAVTEX. Este análisis se apoyará en el software estadístico avanzado SPSS y se fundamentará, principalmente, en un análisis de varianza (ANOVA).

El análisis de varianza (ANOVA) se utiliza para probar diferencias entre tres o más medias poblacionales. Permite múltiples comparaciones manteniendo la probabilidad de un error de tipo I (rechazo de una hipótesis nula verdadera) en un nivel preseleccionado. ANOVA funciona comparando estimaciones de varianza: una debida únicamente a factores aleatorios y otra debida al azar más el efecto del tratamiento (si hay un efecto del tratamiento) (King 2010). Entonces, se plantean dos hipótesis:

- Hipótesis nula: $\mu_A = \mu_B$
- Hipótesis alternativa: $\mu_A \neq \mu_B$

Donde μ_n indica la media poblacional de la que hemos extraído la n-ésima muestra. Si mediante la evidencia brindada por el análisis ANOVA rechazamos la hipótesis nula, significará que las muestras evaluadas son provenientes de poblaciones con medias distintas (King 2010). La tabla 3-7 muestra cómo se dispone una tabla ANOVA para un análisis de varianza.

Tabla 3-7: Tabla ANOVA para el análisis de la varianza

<i>Fuente</i>	<i>Suma de cuadrados</i>	<i>GL</i>	<i>Cuadrado medio</i>	<i>Razón-F</i>	<i>Valor-p</i>
Entre grupos	-	-	-	-	-
Intra grupos	-	-	-		
Total (Corr.)	-	-			

Realizado por: Ocaña, Lisbeth, 2024

Como podemos observar, la tabla del análisis de varianza descompone la fuentes de variación del conjuntos de datos en un componente entre grupos, que se refiere a la varianza encontrada entre los datos experimentales, y otro componente “intra grupos”, que mide la varianza existente en los resultados predichos por el modelo. Si la diferencia entre la variabilidad de los componentes es estadísticamente significativa, se podrá concluir que las medias de los grupos son diferentes. Por otro lado, la razón-F representa el cociente entre el cuadrado medio entre grupos e intra grupos.

Por último, el valor-p que se presenta en la última columna de la tabla 3-7 es el estadístico más importante al momento de extraer una conclusión del análisis de varianza. Por ejemplo, si operamos con un nivel de significancia del 5%, valores-p por debajo del 0.05 nos indican que existe suficiente evidencia estadística para rechazar la hipótesis nula con un nivel de confianza del 95% y afirmar que existe diferencia significativa entre los grupos analizados.

CAPÍTULO IV

4. RESULTADOS

4.1. Informe de resultados del proceso de tintura

De acuerdo al proceso que se planteó en el capítulo 3.2 del presente trabajo de integración curricular, se realizan ensayos experimentales con el fin de obtener un conjunto de datos real que sirva como base para el entreno y aprendizaje del modelo de red neuronal artificial a diseñar.

4.1.1. Variables del proceso

Por medio de una exhaustiva búsqueda bibliográfica y con la asistencia de los experimentados técnicos de la empresa PROLAVTEX, no solo se realizan los ensayos de prueba, sino que se identifican las principales variables a analizar en un proceso de tintura reactiva. Dada la aproximación empírica que se sigue en la empresa para muchos procesos y los limitados recursos disponibles, la ayuda de los técnicos es fundamental para conseguir detectar las variables de entrada y salida de la red, que se presentan en la tabla 4-1.

Tabla 4-1: Ensayos de entrenamientos seleccionados

		VARIABLES	UNIDAD	
ENTRADAS	1	Colorante amarillo BODACTIVE ELF	Y	g
	2	Colorante azul BODACTIVE ELF	B	g
	3	Colorante rojo BODACTIVE ELF	R	g
SALIDAS	1	Luminosidad	L	-
	2	Coordenadas rojo/verde	a*	-
	3	Coordenadas amarillo/azul	b*	-

Realizado por: Ocaña, Lisbeth, 2024.

Las 3 variables de entrada para el modelo de red neuronal artificial corresponden a los 3 colorantes de los colores primarios, utilizados para conseguir una amplia gama de colores. Los colorantes son de tipo BODACTIVE ELF, utilizados en la empresa en el proceso de tintura reactiva de fibras celulósicas en colores de baja pigmentación. Por otro lado, las 3 variables de salida corresponden

al espacio de color CIELAB, ideal para tener una medida objetiva y tangible del color de elementos físicos.

4.1.2. *Muestras experimentales*

Se somete al proceso de tintura especificado a 20 muestras totales de fibras celulósicas con una composición de 98% algodón y 2% elastano, según lo indicado por el fabricante. Para cada formulación (tabla 3-3) se introducen 4 muestras en el proceso de tintura.



Ilustración 4-1: Muestra tinturada con la formulación 1

Realizado por: Ocaña, L., 2024.

Una de las muestras que se tinturaron con la formulación 1 ($Y = 0.25$, $B = 0.35$ y $R = 0.20$) se puede visualizar en la ilustración 4-1. A cada muestra se la digitalizó por medio de un escáner, y esto permitió utilizar el software *ColorMania* para la toma de los datos de color en 20 puntos diferentes de cada muestra, espaciados uniformemente. La medición del color en primera instancia se realizó en términos del espacio de color CMYK, dado que el software no dispone de la opción de medir el color directamente en coordenadas CIELAB. Por esta razón, posteriormente se utilizó un convertidor online, que permitió obtener los datos de color en coordenadas L , a^* , b^* (ilustración 4-2). En los Anexos A-E se presentan imágenes tanto del proceso de tintura, como de todas las muestras finales tinturadas.

Aporte	Producción
C (0% a 100%) <input type="text" value="0"/>	sRGB (0 a 255): 0 0 0
M (0% a 100%) <input type="text" value="0"/>	HEX (#): 000000
Y (0% a 100%) <input type="text" value="0"/>	CMYK (0% a 100%): 75% 68% 67% 90%
K (0% a 100%) <input type="text" value="0"/>	CIELAB (0 a 100, -128 a 128, -128 a 128): 0,00 0,00 0,00
	XYZ (0 a 0,9642, 0 a 1,0000, 0 a 0,8252): 0,0000 0,0000 0,0000
	<input type="text"/>

Ilustración 4-2: Convertidor online de coordenadas de color

Realizado por: Ocaña, L., 2024.

4.2. Resultados de la red neuronal artificial (RNA)

4.2.1. Arquitectura de la RNA

Para determinar la arquitectura ideal para el modelo de red neuronal artificial se realizaron ensayos variando el número de neuronas en la capa oculta para los algoritmos Levenberg-Marquardt y Bayesian Regularization y se analizó la calidad de la topología de red de acuerdo al error cuadrático medio (MSE) y el coeficiente de correlación de Pearson (R). En la tabla 4-2 se resumen los resultados obtenidos en los ensayos realizados y de acuerdo a esto se determinó la topología y el algoritmo óptimo para el modelo de RNA a utilizar en el presente proyecto.

Tabla 4-2: Ensayos de entrenamientos seleccionados

N°	# Neuronas Capa Oculta	Levenberg-Marquardt		Bayesian Regularization	
		R	MSE	R	MSE
1	10	0.98737	2.473E-03	0.98955	1.964E-03
2	20	0.98821	2.226E-03	0.98912	2.149E-03
3	30	0.99125	1.609E-03	0.98917	1.824E-03
4	40	0.98973	2.108E-03	0.98787	1.996E-03
5	50	0.98757	2.336E-03	0.99064	1.789E-03
6	60	0.98912	1.964E-03	0.98912	2.022E-03
7	70	0.98424	2.827E-03	0.99067	1.961E-03
8	80	0.98849	2.118E-03	0.9878	2.213E-03
9	90	0.98889	2.215E-03	0.98902	2.108E-03
10	100	0.98916	2.079E-03	0.98911	2.065E-03

Realizado por: Ocaña, Lisbeth, 2024.

De acuerdo a los datos reflejados en la tabla, en función de los mejores valores de R (más alto) y MSE (más bajo), el número de neuronas óptimo en la capa oculta fue de 30, utilizando el algoritmo de entrenamiento Levenberg-Marquardt. Entonces, la RNA que se diseñó para la predicción de formulaciones de colorantes en la tintura de textiles de la empresa PROLAVTEX se muestra en la ilustración 4-3 y su topología se resume de la siguiente manera:

- 3 variables de entrada a la red
- 30 neuronas en la capa oculta que procesan la información de entrada
- 3 variables de salida de la red
- Algoritmo Levenberg-Marquardt

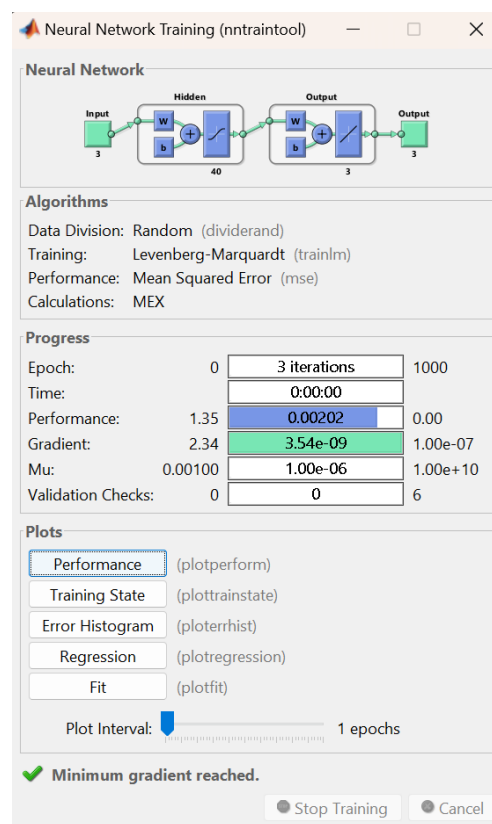


Ilustración 4-3: Resumen de la RNA diseñada en Matlab

Realizado por: Ocaña, L., 2024.

4.2.2. Comportamiento de la RNA

La ilustración 4-4 resume los resultados obtenidos en el entrenamiento de la RNA con la topología especificada. Se obtuvieron valores de 0.00160861 y 0.99125 para el error cuadrático medio (MSE) y la correlación de Pearson (R), respectivamente. Por otro lado, en la ilustración 4-5 se

observa que el ajuste del modelo con los datos ingresados es bastante bueno, evidenciándose una relación cercana a una lineal, con valores de R igual a 0.98911, 0.98732 y 0.99125 para las etapas de entrenamiento, validación y prueba, respectivamente. Estos valores se aproximan a 1, lo que nos indica una correlación idónea para la posterior utilización del modelo en la predicción.



Ilustración 4-4: Valores de MSE y R obtenidos de MATLAB®

Realizado por: Ocaña, L., 2024.

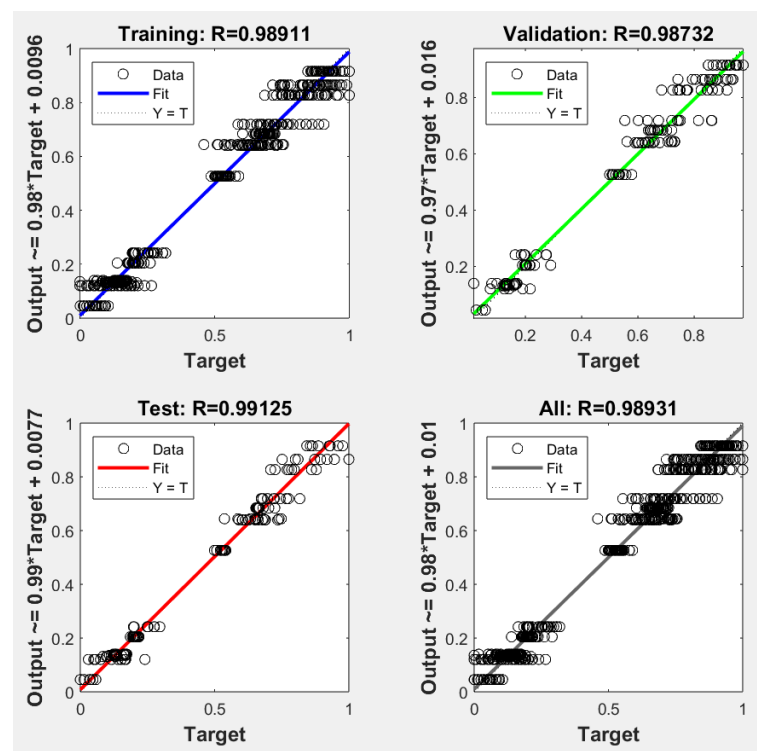


Ilustración 4-5: Gráficas de regresión obtenidas en MATLAB®

Realizado por: Ocaña, L., 2024.

En la tabla 4-3 se pueden observar los valores para el error cuadrático medio (MSE) que se obtuvieron para las 3 fases del diseño de la RNA (entrenamiento, validación y prueba) mediante el algoritmo de entrenamiento Levenberg-Marquardt. Este algoritmo, a diferencia del algoritmo de regularización Bayesiana, sí cuenta con una etapa de validación.

Tabla 4-3: MSE para cada etapa del diseño de la RNA

Etapa	MSE
trainPerformance (entrenamiento)	0.00205896
valPerformance (validación)	0.00236618
testPerformance (prueba)	0.00169861

Realizado por: Ocaña, Lisbeth, 2024.

Un valor más pequeño de error cuadrático medio quiere decir que hay una menor desviación entre los datos reales y los datos predichos por la RNA, es decir, mejor potencial predictivo. Los valores de 0.00205896, 0.00236618 y 0.00169861 para cada una de las etapas del diseño indican un funcionamiento aceptable del modelo de RNA propuesto.

La ilustración 4-6 presenta una representación gráfica de la evolución de los valores de MSE durante las iteraciones que realizó el software en el diseño de la RNA. Podemos evidenciar las curvas correspondientes a las etapas de entrenamiento (azul), validación (verde) y prueba (rojo). Los valores se encuentran en un rango deseable y la superposición de las curvas sugiere que el modelo está aprendiendo de manera efectiva y su capacidad de predicción es alta.




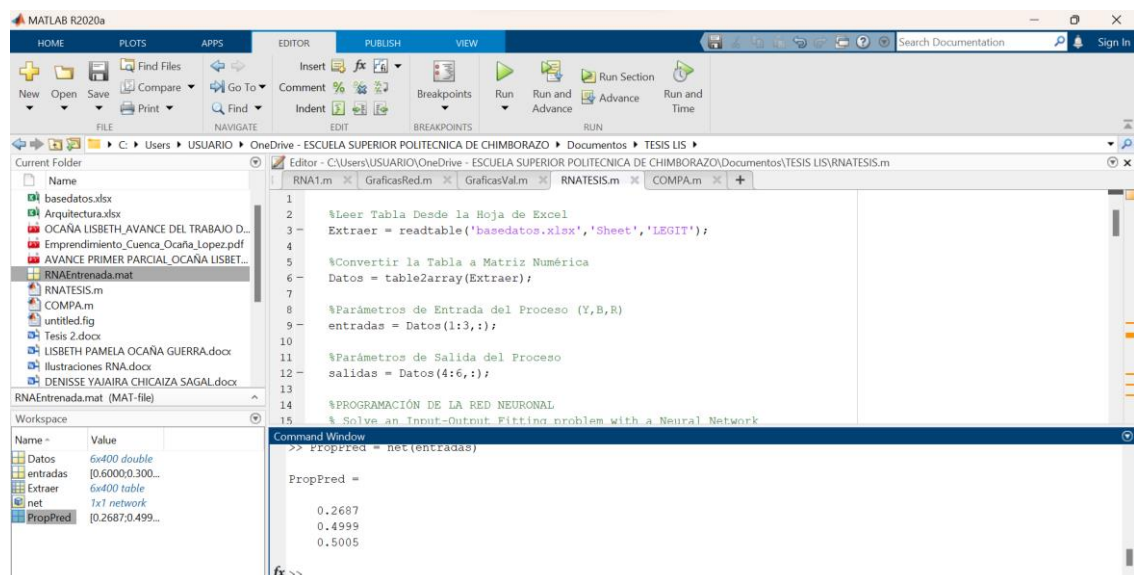
Ilustración 4-6: Rendimiento del entrenamiento de la red

Realizado por: Ocaña, L., 2024.

4.2.3. Código de programación de la RNA

El código de MATLAB con el que se entrenó y diseñó la RNA (ilustración 4-7) y la identificación de cada variable utilizada en el software se detallan en los anexos F-I. Aquí se incluyen especificaciones para la realización de:

- Ingreso del conjunto de datos.
- Identificación de variables de entrada y salida.
- Diseño del modelo de RNA.
- Resultados predichos por el modelo de RNA.
- Gráficas de comparación de resultados reales vs predichos.



```
1 %Leer Tabla Desde la Hoja de Excel
2 Extraer = readtable('basedatos.xlsx','Sheet','LEGIT');
3
4
5 %Convertir la Tabla a Matriz Numérica
6 Datos = table2array(Extraer);
7
8 %Parámetros de Entrada del Proceso (Y,B,R)
9 entradas = Datos(1:3,:);
10
11 %Parámetros de Salida del Proceso
12 salidas = Datos(4:6,:);
13
14 %PROGRAMACIÓN DE LA RED NEURONAL
15 % Solve an Input-Output Fitting problem with a Neural Network
16
17 Command Window
18 >>> PropPred = net(entradas)
19
20 PropPred =
21
22     0.2687
23     0.4999
24     0.5005
```

Ilustración 4-7: Código de programación del entrenamiento de la RNA

Realizado por: Ocaña, L., 2024.

4.2.4. Comparación entre los datos de la RNA y los datos experimentales

En la presente sección se comparan y analizan los datos obtenidos por el modelo de predicción propuesto en contraste con dos grupos diferentes de datos. En primer lugar, la base de datos usada para el entrenamiento y validación de la red neuronal artificial que cuenta con 340 pares de datos, que sirve para comprobar su capacidad de predicción. Por otro lado, se utiliza un conjunto de 60 pares de datos externos, que no fueron utilizados en el entrenamiento de la red, de manera que se pueda probar la eficacia y utilidad en un ambiente práctico, ingresando valores ajenos a los previamente aprendidos.

4.2.4.1. RNA vs valores de entrenamiento

En la tabla 4-4 se presentan los resultados de la comparación entre los datos arrojados por la RNA y los recabados experimentalmente para las 3 variables de salida (luminosidad, coordenadas rojo/verde y coordenadas amarillo/azul). Se comparan los datos normalizados y a cada comparación se asocia su respectivo error porcentual.

Tabla 4-4: Valores reales comparados con los predichos por la RNA

Luminosidad			Coordenadas rojo/verde			Coordenadas amarillo/azul		
L	L (RNA)	Error (%)	a*	a* (RNA)	Error (%)	b*	b* (RNA)	Error (%)
0.19051	0.11405	40.14	0.12801	0.13962	9.06	0.04703	0.04369	7.09
0.72532	0.65835	9.23	0.30756	0.23812	22.58	0.15496	0.13153	15.12
0.68722	0.64016	6.85	0.12635	0.13778	9.05	0.20793	0.20846	0.26
0.20263	0.11405	43.72	0.16376	0.13962	14.74	0.03711	0.04369	17.73
0.59023	0.64016	8.46	0.13300	0.13778	3.60	0.20057	0.20846	3.94
0.74195	0.81400	9.71	0.74231	0.86893	17.06	0.85071	0.91226	7.24
0.61448	0.64016	4.18	0.13134	0.13778	4.91	0.20255	0.20846	2.92
0.76481	0.81400	6.43	0.74730	0.86893	16.28	0.85751	0.91226	6.38
0.76723	0.72364	5.68	0.66584	0.68302	2.58	0.53881	0.52801	2.00
0.75130	0.72364	3.68	0.71987	0.68302	5.12	0.53314	0.52801	0.96
0.14028	0.11405	18.70	0.13300	0.13962	4.97	0.04646	0.04369	5.96
0.19051	0.11405	40.14	0.12801	0.13962	9.06	0.04703	0.04369	7.09
0.67267	0.64016	4.83	0.08479	0.13778	62.50	0.21558	0.20846	3.30
0.95913	0.81400	15.13	0.84705	0.86893	2.58	0.93796	0.91226	2.74
0.69692	0.72364	3.83	0.65586	0.68302	4.14	0.52550	0.52801	0.48
0.72359	0.81400	12.49	0.79385	0.86893	9.46	0.86686	0.91226	5.24
0.72220	0.72364	0.20	0.66667	0.68302	2.45	0.50793	0.52801	3.95
0.00000	0.11405	11.40	0.17290	0.13962	19.25	0.05751	0.04369	24.03
0.10045	0.11405	13.53	0.16293	0.13962	14.31	0.05751	0.04369	24.03
0.67960	0.72364	6.48	0.70158	0.68302	2.65	0.54164	0.52801	2.52
0.63665	0.65835	3.41	0.27348	0.23812	12.93	0.13484	0.13153	2.46
0.81711	0.72364	11.44	0.68080	0.68302	0.33	0.52578	0.52801	0.42
0.16903	0.11405	32.53	0.15295	0.13962	8.72	0.00000	0.04369	4.37
0.83235	0.81400	2.20	0.76060	0.86893	14.24	0.87734	0.91226	3.98
0.75130	0.72364	3.68	0.71987	0.68302	5.12	0.53314	0.52801	0.96
0.61448	0.64016	4.18	0.13134	0.13778	4.91	0.20255	0.20846	2.92
0.68722	0.64016	6.85	0.12635	0.13778	9.05	0.20793	0.20846	0.26
0.67579	0.65835	2.58	0.30756	0.23812	22.58	0.15212	0.13153	13.54
0.67336	0.72364	7.47	0.65337	0.68302	4.54	0.52125	0.52801	1.30
0.70696	0.65835	6.88	0.19701	0.23812	20.87	0.13399	0.13153	1.84
0.65847	0.65835	0.02	0.19867	0.23812	19.86	0.13144	0.13153	0.07
0.18878	0.11405	39.59	0.11887	0.13962	17.45	0.06686	0.04369	34.65
0.74576	0.72364	2.97	0.66999	0.68302	1.94	0.51218	0.52801	3.09

0.08001	0.11405	42.53	0.11139	0.13962	25.34	0.03456	0.04369	26.42
0.72532	0.81400	12.23	0.80050	0.86893	8.55	0.84334	0.91226	8.17
0.69692	0.72364	3.83	0.65586	0.68302	4.14	0.52550	0.52801	0.48
0.63422	0.72364	14.10	0.70241	0.68302	2.76	0.51161	0.52801	3.21
0.08001	0.11405	42.53	0.11139	0.13962	25.34	0.03456	0.04369	26.42
0.72220	0.72364	0.20	0.66667	0.68302	2.45	0.50793	0.52801	3.95
0.07516	0.11405	51.73	0.16542	0.13962	15.60	0.05751	0.04369	24.03
0.54278	0.64016	17.94	0.14547	0.13778	5.28	0.17649	0.20846	18.12
0.72047	0.72364	0.44	0.65919	0.68302	3.62	0.52975	0.52801	0.33
0.75476	0.65835	12.77	0.24106	0.23812	1.22	0.21076	0.13153	37.59
0.65847	0.65835	0.02	0.19867	0.23812	19.86	0.13144	0.13153	0.07
0.84829	0.81400	4.04	0.93766	0.86893	7.33	0.94958	0.91226	3.93
0.19224	0.11405	40.68	0.13799	0.13962	1.18	0.02550	0.04369	71.37
0.65847	0.65835	0.02	0.19867	0.23812	19.86	0.13144	0.13153	0.07
0.11534	0.11405	1.13	0.13549	0.13962	3.04	0.04646	0.04369	5.96
0.86318	0.81400	5.70	0.87116	0.86893	0.26	0.98187	0.91226	7.09
0.79667	0.81400	2.17	0.87282	0.86893	0.45	0.88640	0.91226	2.92
0.05507	0.11405	107.08	0.11471	0.13962	21.71	0.03484	0.04369	25.39
0.58504	0.65835	12.53	0.26517	0.23812	10.20	0.15467	0.13153	14.96
0.63873	0.64016	0.23	0.12968	0.13778	6.25	0.20425	0.20846	2.06
0.75407	0.81400	7.95	0.91272	0.86893	4.80	0.92011	0.91226	0.85
0.62556	0.65835	5.24	0.25270	0.23812	5.77	0.09575	0.13153	37.37
0.74402	0.72364	2.74	0.66251	0.68302	3.10	0.53399	0.52801	1.12
0.77970	0.81400	4.40	0.97174	0.86893	10.58	0.97535	0.91226	6.47
0.65327	0.64016	2.01	0.17041	0.13778	19.14	0.19745	0.20846	5.58
0.67163	0.72364	7.74	0.64589	0.68302	5.75	0.54278	0.52801	2.72
0.10045	0.11405	13.53	0.16293	0.13962	14.31	0.05751	0.04369	24.03
0.65327	0.64016	2.01	0.17041	0.13778	19.14	0.19745	0.20846	5.58
0.24039	0.11405	52.56	0.12303	0.13962	13.49	0.04731	0.04369	7.65
0.84829	0.81400	4.04	0.93766	0.86893	7.33	0.94958	0.91226	3.93
0.05507	0.11405	107.08	0.11471	0.13962	21.71	0.03484	0.04369	25.39
0.65847	0.65835	0.02	0.19867	0.23812	19.86	0.13144	0.13153	0.07
0.60270	0.64016	6.22	0.16376	0.13778	15.86	0.21473	0.20846	2.92
0.56148	0.65835	17.25	0.27515	0.23812	13.46	0.13088	0.13153	0.50
0.51195	0.65835	28.60	0.21613	0.23812	10.18	0.10198	0.13153	28.97
0.56010	0.65835	17.54	0.20366	0.23812	16.92	0.12663	0.13153	3.87
0.62556	0.65835	5.24	0.25270	0.23812	5.77	0.09575	0.13153	37.37
0.82473	0.81400	1.30	0.93682	0.86893	7.25	0.91728	0.91226	0.55
0.86145	0.72364	16.00	0.68080	0.68302	0.33	0.55751	0.52801	5.29
0.18878	0.11405	39.59	0.11887	0.13962	17.45	0.06686	0.04369	34.65
0.77381	0.81400	5.19	0.86700	0.86893	0.22	0.87960	0.91226	3.71
0.65847	0.65835	0.02	0.19867	0.23812	19.86	0.13144	0.13153	0.07
0.65154	0.64016	1.75	0.16043	0.13778	14.12	0.21841	0.20846	4.56
0.55352	0.72364	30.73	0.63757	0.68302	7.13	0.49943	0.52801	5.72
0.73537	0.65835	10.47	0.27182	0.23812	12.40	0.14023	0.13153	6.20
0.16696	0.11405	31.69	0.14048	0.13962	0.62	0.02550	0.04369	71.37

0.00693	0.11405	1546.25	0.13051	0.13962	6.98	0.01501	0.04369	191.00
0.95220	0.81400	14.51	0.71571	0.86893	21.41	0.94108	0.91226	3.06
0.79079	0.72364	8.49	0.66916	0.68302	2.07	0.54334	0.52801	2.82
0.16522	0.11405	30.97	0.13051	0.13962	6.98	0.04674	0.04369	6.53
0.65847	0.65835	0.02	0.19867	0.23812	19.86	0.13144	0.13153	0.07
0.63422	0.72364	14.10	0.70241	0.68302	2.76	0.51161	0.52801	3.21
0.61067	0.72364	18.50	0.69825	0.68302	2.18	0.50737	0.52801	4.07
0.58677	0.65835	12.20	0.27431	0.23812	13.19	0.13201	0.13153	0.36
0.70696	0.65835	6.88	0.19701	0.23812	20.87	0.13399	0.13153	1.84
0.81676	0.81400	0.34	0.82710	0.86893	5.06	0.84589	0.91226	7.85
0.72220	0.72364	0.20	0.66667	0.68302	2.45	0.50793	0.52801	3.95
0.63318	0.65835	3.97	0.25436	0.23812	6.39	0.17960	0.13153	26.77
0.72740	0.65835	9.49	0.31837	0.23812	25.21	0.12975	0.13153	1.38
0.63388	0.65835	3.86	0.20033	0.23812	18.86	0.13031	0.13153	0.94
0.62626	0.64016	2.22	0.09892	0.13778	39.29	0.19008	0.20846	9.67
0.71805	0.65835	8.31	0.16376	0.23812	45.41	0.12068	0.13153	8.99
0.60270	0.64016	6.22	0.16376	0.13778	15.86	0.21473	0.20846	2.92
0.51299	0.65835	28.34	0.28678	0.23812	16.97	0.10425	0.13153	26.17
0.67579	0.65835	2.58	0.30756	0.23812	22.58	0.15212	0.13153	13.54
0.65847	0.65835	0.02	0.19867	0.23812	19.86	0.13144	0.13153	0.07
0.70696	0.65835	6.88	0.19701	0.23812	20.87	0.13399	0.13153	1.84
0.62556	0.64016	2.33	0.15295	0.13778	9.92	0.23824	0.20846	12.50
0.60443	0.64016	5.91	0.17290	0.13778	20.31	0.19377	0.20846	7.58
0.68272	0.65835	3.57	0.19784	0.23812	20.36	0.13286	0.13153	1.00
0.90717	0.81400	10.27	0.78221	0.86893	11.09	0.87450	0.91226	4.32
0.03014	0.11405	278.45	0.10889	0.13962	28.21	0.03513	0.04369	24.38
0.75130	0.72364	3.68	0.71987	0.68302	5.12	0.53314	0.52801	0.96
0.70488	0.72364	2.66	0.71239	0.68302	4.12	0.52436	0.52801	0.70
0.16696	0.11405	31.69	0.14048	0.13962	0.62	0.02550	0.04369	71.37
0.05023	0.11405	127.07	0.16791	0.13962	16.85	0.05751	0.04369	24.03
0.16696	0.11405	31.69	0.14048	0.13962	0.62	0.02550	0.04369	71.37
0.88639	0.72364	18.36	0.69244	0.68302	1.36	0.53909	0.52801	2.06
0.15241	0.11405	25.17	0.16874	0.13962	17.26	0.03683	0.04369	18.64
0.75130	0.72364	3.68	0.71987	0.68302	5.12	0.53314	0.52801	0.96
0.77485	0.72364	6.61	0.72402	0.68302	5.66	0.53768	0.52801	1.80
0.05023	0.11405	127.07	0.16791	0.13962	16.85	0.05751	0.04369	24.03
0.79910	0.81400	1.86	0.92436	0.86893	6.00	0.93428	0.91226	2.36
0.68722	0.64016	6.85	0.12635	0.13778	9.05	0.20793	0.20846	0.26
0.63873	0.64016	0.23	0.12968	0.13778	6.25	0.20425	0.20846	2.06
0.18739	0.11405	39.14	0.19119	0.13962	26.97	0.04816	0.04369	9.28
0.62729	0.64016	2.05	0.16209	0.13778	15.00	0.21671	0.20846	3.81
0.06893	0.11405	65.45	0.16209	0.13962	13.87	0.00113	0.04369	3755.73
0.77485	0.81400	5.05	0.91189	0.86893	4.71	0.95127	0.91226	4.10
0.11534	0.11405	1.13	0.13549	0.13962	3.04	0.04646	0.04369	5.96
0.63492	0.65835	3.69	0.26351	0.23812	9.63	0.15751	0.13153	16.49
0.63388	0.65835	3.86	0.20033	0.23812	18.86	0.13031	0.13153	0.94

0.03014	0.11405	278.45	0.10889	0.13962	28.21	0.03513	0.04369	24.38
0.76896	0.72364	5.89	0.67332	0.68302	1.44	0.51671	0.52801	2.19
0.73052	0.81400	11.43	0.90025	0.86893	3.48	0.93683	0.91226	2.62
0.91133	0.81400	10.68	0.81796	0.86893	6.23	1.00000	0.91226	8.77
0.69865	0.72364	3.58	0.66334	0.68302	2.97	0.50397	0.52801	4.77
0.65778	0.72364	10.01	0.70574	0.68302	3.22	0.51586	0.52801	2.36
0.88569	0.81400	8.09	0.83042	0.86893	4.64	0.91586	0.91226	0.39
0.91340	0.81400	10.88	0.82461	0.86893	5.37	0.97507	0.91226	6.44
0.74991	0.81400	8.55	0.85536	0.86893	1.59	0.89660	0.91226	1.75
0.60339	0.72364	19.93	0.65087	0.68302	4.94	0.48725	0.52801	8.37
0.56010	0.65835	17.54	0.20366	0.23812	16.92	0.12663	0.13153	3.87
0.74991	0.81400	8.55	0.85536	0.86893	1.59	0.89660	0.91226	1.75
0.14202	0.11405	19.70	0.14298	0.13962	2.35	0.02550	0.04369	71.37
0.10010	0.11405	13.93	0.08146	0.13962	71.39	0.09093	0.04369	51.95
0.79667	0.81400	2.17	0.87282	0.86893	0.45	0.88640	0.91226	2.92
0.70315	0.72364	2.91	0.70490	0.68302	3.10	0.54589	0.52801	3.28
0.05681	0.11405	100.76	0.12469	0.13962	11.97	0.01416	0.04369	208.46
0.60443	0.64016	5.91	0.17290	0.13778	20.31	0.19377	0.20846	7.58
0.72948	0.65835	9.75	0.18537	0.23812	28.46	0.15807	0.13153	16.79
0.63388	0.65835	3.86	0.20033	0.23812	18.86	0.13031	0.13153	0.94
0.65154	0.64016	1.75	0.16043	0.13778	14.12	0.21841	0.20846	4.56
0.17735	0.11405	35.69	0.16625	0.13962	16.02	0.03711	0.04369	17.73
0.65085	0.65835	1.15	0.30756	0.23812	22.58	0.15042	0.13153	12.56
0.72636	0.72364	0.38	0.70823	0.68302	3.56	0.55042	0.52801	4.07
0.69692	0.72364	3.83	0.65586	0.68302	4.14	0.52550	0.52801	0.48
0.58677	0.65835	12.20	0.27431	0.23812	13.19	0.13201	0.13153	0.36
0.65154	0.64016	1.75	0.16043	0.13778	14.12	0.21841	0.20846	4.56
0.67960	0.72364	6.48	0.70158	0.68302	2.65	0.54164	0.52801	2.52
0.88396	0.81400	7.91	0.82377	0.86893	5.48	0.94051	0.91226	3.00
0.63873	0.64016	0.23	0.12968	0.13778	6.25	0.20425	0.20846	2.06
0.72844	0.72364	0.66	0.71571	0.68302	4.57	0.52861	0.52801	0.11
0.63873	0.64016	0.23	0.12968	0.13778	6.25	0.20425	0.20846	2.06
0.74056	0.72364	2.29	0.64672	0.68302	5.61	0.57819	0.52801	8.68
0.89782	0.81400	9.34	0.89194	0.86893	2.58	0.94221	0.91226	3.18
0.05681	0.11405	100.76	0.12469	0.13962	11.97	0.01416	0.04369	208.46
0.70696	0.65835	6.88	0.19701	0.23812	20.87	0.13399	0.13153	1.84
0.65847	0.65835	0.02	0.19867	0.23812	19.86	0.13144	0.13153	0.07
0.05507	0.11405	107.08	0.11471	0.13962	21.71	0.03484	0.04369	25.39
0.91687	0.81400	11.22	0.83791	0.86893	3.70	0.92521	0.91226	1.40
0.75234	0.81400	8.20	0.90607	0.86893	4.10	0.94391	0.91226	3.35
0.65847	0.65835	0.02	0.19867	0.23812	19.86	0.13144	0.13153	0.07
0.68272	0.65835	3.57	0.19784	0.23812	20.36	0.13286	0.13153	1.00
0.65154	0.64016	1.75	0.16043	0.13778	14.12	0.21841	0.20846	4.56
0.61448	0.64016	4.18	0.13134	0.13778	4.91	0.20255	0.20846	2.92
0.60270	0.64016	6.22	0.16376	0.13778	15.86	0.21473	0.20846	2.92
0.11534	0.11405	1.13	0.13549	0.13962	3.04	0.04646	0.04369	5.96

0.58677	0.65835	12.20	0.27431	0.23812	13.19	0.13201	0.13153	0.36
0.05404	0.11405	111.06	0.18953	0.13962	26.33	0.01275	0.04369	242.73
0.66297	0.64016	3.44	0.12801	0.13778	7.63	0.20595	0.20846	1.22
0.21545	0.11405	47.07	0.12552	0.13962	11.23	0.04731	0.04369	7.65
0.51022	0.65835	29.03	0.20615	0.23812	15.51	0.12408	0.13153	6.01
0.76723	0.72364	5.68	0.66584	0.68302	2.58	0.53881	0.52801	2.00
0.60166	0.72364	20.27	0.64339	0.68302	6.16	0.50822	0.52801	3.90
0.15310	0.11405	25.51	0.09393	0.13962	48.64	0.05439	0.04369	19.67
0.63873	0.64016	0.23	0.12968	0.13778	6.25	0.20425	0.20846	2.06
0.12539	0.11405	9.05	0.16043	0.13962	12.97	0.05779	0.04369	24.40
0.75407	0.81400	7.95	0.91272	0.86893	4.80	0.92011	0.91226	0.85
0.19051	0.11405	40.14	0.12801	0.13962	9.06	0.04703	0.04369	7.09
0.19051	0.11405	40.14	0.12801	0.13962	9.06	0.04703	0.04369	7.09
0.72220	0.72364	0.20	0.66667	0.68302	2.45	0.50793	0.52801	3.95
0.61448	0.64016	4.18	0.13134	0.13778	4.91	0.20255	0.20846	2.92
0.72047	0.72364	0.44	0.65919	0.68302	3.62	0.52975	0.52801	0.33
0.79667	0.81400	2.17	0.87282	0.86893	0.45	0.88640	0.91226	2.92
0.10495	0.11405	8.66	0.10889	0.13962	28.21	0.03456	0.04369	26.42
0.84482	0.81400	3.65	0.89111	0.86893	2.49	0.87592	0.91226	4.15
0.66297	0.64016	3.44	0.12801	0.13778	7.63	0.20595	0.20846	1.22
0.74818	0.81400	8.80	0.84871	0.86893	2.38	0.92040	0.91226	0.88
0.79667	0.81400	2.17	0.87282	0.86893	0.45	0.88640	0.91226	2.92
0.66124	0.64016	3.19	0.08811	0.13778	56.37	0.22805	0.20846	8.59
0.72775	0.64016	12.03	0.17539	0.13778	21.44	0.18045	0.20846	15.52
0.65639	0.72364	10.24	0.69825	0.68302	2.18	0.53711	0.52801	1.69
0.53654	0.65835	22.70	0.27598	0.23812	13.72	0.12946	0.13153	1.60
0.65847	0.65835	0.02	0.19867	0.23812	19.86	0.13144	0.13153	0.07
0.64046	0.64016	0.05	0.13882	0.13778	0.75	0.18300	0.20846	13.91
0.07239	0.11405	57.54	0.14713	0.13962	5.11	0.09490	0.04369	53.96
0.10495	0.11405	8.66	0.10889	0.13962	28.21	0.03456	0.04369	26.42
0.45999	0.65835	43.12	0.27764	0.23812	14.23	0.12578	0.13153	4.57
0.60097	0.65835	9.55	0.25353	0.23812	6.08	0.09462	0.13153	39.01
0.67475	0.65835	2.43	0.25104	0.23812	5.15	0.09773	0.13153	34.58
0.75130	0.72364	3.68	0.71987	0.68302	5.12	0.53314	0.52801	0.96
0.91895	0.81400	11.42	0.84456	0.86893	2.89	0.90028	0.91226	1.33
0.00693	0.11405	1546.25	0.13051	0.13962	6.98	0.01501	0.04369	191.00
0.65154	0.64016	1.75	0.16043	0.13778	14.12	0.21841	0.20846	4.56
0.68722	0.64016	6.85	0.12635	0.13778	9.05	0.20793	0.20846	0.26
0.71874	0.72364	0.68	0.65170	0.68302	4.81	0.55156	0.52801	4.27
0.11604	0.11405	1.72	0.06068	0.13962	130.08	0.06119	0.04369	28.60
0.77485	0.72364	6.61	0.72402	0.68302	5.66	0.53768	0.52801	1.80
0.68272	0.65835	3.57	0.19784	0.23812	20.36	0.13286	0.13153	1.00
0.70869	0.81400	14.86	0.89443	0.86893	2.85	0.93003	0.91226	1.91
0.81919	0.81400	0.63	0.87864	0.86893	1.11	0.89320	0.91226	2.13
0.59855	0.64016	6.95	0.08063	0.13778	70.88	0.23258	0.20846	10.37
0.72186	0.65835	8.80	0.23857	0.23812	0.19	0.12521	0.13153	5.05

0.62729	0.64016	2.05	0.16209	0.13778	15.00	0.21671	0.20846	3.81
0.74784	0.72364	3.24	0.70490	0.68302	3.10	0.57734	0.52801	8.54
0.78698	0.81400	3.43	0.75145	0.86893	15.63	0.86402	0.91226	5.58
0.65085	0.65835	1.15	0.30756	0.23812	22.58	0.15042	0.13153	12.56
0.58677	0.72364	23.33	0.69493	0.68302	1.71	0.50283	0.52801	5.01
0.79910	0.81400	1.86	0.92436	0.86893	6.00	0.93428	0.91226	2.36
0.84067	0.72364	13.92	0.68495	0.68302	0.28	0.53031	0.52801	0.43
0.77381	0.81400	5.19	0.86700	0.86893	0.22	0.87960	0.91226	3.71
0.63422	0.72364	14.10	0.70241	0.68302	2.76	0.51161	0.52801	3.21
0.53654	0.65835	22.70	0.27598	0.23812	13.72	0.12946	0.13153	1.60
0.14028	0.11405	18.70	0.13300	0.13962	4.97	0.04646	0.04369	5.96
0.62556	0.65835	5.24	0.25270	0.23812	5.77	0.09575	0.13153	37.37
0.26567	0.11405	57.07	0.12053	0.13962	15.83	0.04759	0.04369	8.20
0.74784	0.72364	3.24	0.70490	0.68302	3.10	0.57734	0.52801	8.54
0.75546	0.65835	12.85	0.19451	0.23812	22.42	0.13654	0.13153	3.67
0.70696	0.65835	6.88	0.19701	0.23812	20.87	0.13399	0.13153	1.84
0.72220	0.72364	0.20	0.66667	0.68302	2.45	0.50793	0.52801	3.95
0.60270	0.64016	6.22	0.16376	0.13778	15.86	0.21473	0.20846	2.92
0.07516	0.11405	51.73	0.16542	0.13962	15.60	0.05751	0.04369	24.03
0.55525	0.64016	15.29	0.05237	0.13778	163.10	0.13881	0.20846	50.18
0.86318	0.72364	16.17	0.68828	0.68302	0.76	0.53484	0.52801	1.28
0.14028	0.11405	18.70	0.13300	0.13962	4.97	0.04646	0.04369	5.96
0.77485	0.81400	5.05	0.91189	0.86893	4.71	0.95127	0.91226	4.10
0.74818	0.81400	8.80	0.80549	0.86893	7.88	0.85014	0.91226	7.31
0.72220	0.72364	0.20	0.66667	0.68302	2.45	0.50793	0.52801	3.95
0.11708	0.11405	2.59	0.14547	0.13962	4.02	0.02550	0.04369	71.37
0.61448	0.64016	4.18	0.13134	0.13778	4.91	0.20255	0.20846	2.92
0.60443	0.64016	5.91	0.17290	0.13778	20.31	0.19377	0.20846	7.58
0.73121	0.65835	9.96	0.19534	0.23812	21.90	0.13513	0.13153	2.66
0.69692	0.72364	3.83	0.65586	0.68302	4.14	0.52550	0.52801	0.48
0.05681	0.11405	100.76	0.12469	0.13962	11.97	0.01416	0.04369	208.46
0.63873	0.64016	0.23	0.12968	0.13778	6.25	0.20425	0.20846	2.06
0.68583	0.81400	18.69	0.88778	0.86893	2.12	0.92266	0.91226	1.13
0.07516	0.11405	51.73	0.16542	0.13962	15.60	0.05751	0.04369	24.03
0.62729	0.64016	2.05	0.16209	0.13778	15.00	0.21671	0.20846	3.81
0.60270	0.64016	6.22	0.16376	0.13778	15.86	0.21473	0.20846	2.92
0.63873	0.64016	0.23	0.12968	0.13778	6.25	0.20425	0.20846	2.06
0.84829	0.81400	4.04	0.93766	0.86893	7.33	0.94958	0.91226	3.93
0.68722	0.64016	6.85	0.12635	0.13778	9.05	0.20793	0.20846	0.26
0.14202	0.11405	19.70	0.14298	0.13962	2.35	0.02550	0.04369	71.37
0.65327	0.64016	2.01	0.17041	0.13778	19.14	0.19745	0.20846	5.58
0.60270	0.64016	6.22	0.16376	0.13778	15.86	0.21473	0.20846	2.92
0.75026	0.65835	12.25	0.30673	0.23812	22.37	0.15666	0.13153	16.04
0.26567	0.11405	57.07	0.12053	0.13962	15.83	0.04759	0.04369	8.20
0.86076	0.81400	5.43	1.00000	0.86893	13.11	0.97677	0.91226	6.60
0.82092	0.81400	0.84	0.92436	0.86893	6.00	0.96601	0.91226	5.56

0.68722	0.64016	6.85	0.12635	0.13778	9.05	0.20793	0.20846	0.26
0.84829	0.81400	4.04	0.93766	0.86893	7.33	0.94958	0.91226	3.93
0.24039	0.11405	52.56	0.12303	0.13962	13.49	0.04731	0.04369	7.65
0.00000	0.11405	11.40	0.17290	0.13962	19.25	0.05751	0.04369	24.03
0.72220	0.72364	0.20	0.66667	0.68302	2.45	0.50793	0.52801	3.95
0.66886	0.64016	4.29	0.06484	0.13778	112.50	0.26091	0.20846	20.10
0.62868	0.64016	1.83	0.17124	0.13778	19.54	0.19575	0.20846	6.49
0.75130	0.72364	3.68	0.71987	0.68302	5.12	0.53314	0.52801	0.96
0.60270	0.64016	6.22	0.16376	0.13778	15.86	0.21473	0.20846	2.92
0.69761	0.65835	5.63	0.23940	0.23812	0.53	0.12408	0.13153	6.01
0.87911	0.81400	7.41	0.94597	0.86893	8.14	0.95949	0.91226	4.92
0.62868	0.64016	1.83	0.17124	0.13778	19.54	0.19575	0.20846	6.49
0.66470	0.64016	3.69	0.13716	0.13778	0.46	0.18470	0.20846	12.86
0.56148	0.65835	17.25	0.27515	0.23812	13.46	0.13088	0.13153	0.50
0.77208	0.81400	5.43	0.86035	0.86893	1.00	0.90340	0.91226	0.98
0.86145	0.72364	16.00	0.68080	0.68302	0.33	0.55751	0.52801	5.29
0.76723	0.72364	5.68	0.66584	0.68302	2.58	0.53881	0.52801	2.00
0.66124	0.64016	3.19	0.08811	0.13778	56.37	0.22805	0.20846	8.59
0.67336	0.72364	7.47	0.65337	0.68302	4.54	0.52125	0.52801	1.30
0.76896	0.72364	5.89	0.67332	0.68302	1.44	0.51671	0.52801	2.19
0.77381	0.81400	5.19	0.86700	0.86893	0.22	0.87960	0.91226	3.71
0.58677	0.65835	12.20	0.27431	0.23812	13.19	0.13201	0.13153	0.36
0.60443	0.64016	5.91	0.17290	0.13778	20.31	0.19377	0.20846	7.58
0.66297	0.64016	3.44	0.12801	0.13778	7.63	0.20595	0.20846	1.22
0.19051	0.11405	40.14	0.12801	0.13962	9.06	0.04703	0.04369	7.09
0.74576	0.72364	2.97	0.66999	0.68302	1.94	0.51218	0.52801	3.09
0.65154	0.64016	1.75	0.16043	0.13778	14.12	0.21841	0.20846	4.56
0.65847	0.65835	0.02	0.19867	0.23812	19.86	0.13144	0.13153	0.07
0.08001	0.11405	42.53	0.11139	0.13962	25.34	0.03456	0.04369	26.42
0.95913	0.81400	15.13	0.84705	0.86893	2.58	0.93796	0.91226	2.74
0.72220	0.72364	0.20	0.66667	0.68302	2.45	0.50793	0.52801	3.95
0.05404	0.11405	111.06	0.18953	0.13962	26.33	0.01275	0.04369	242.73
0.68895	0.64016	7.08	0.13549	0.13778	1.69	0.18640	0.20846	11.84
0.67752	0.65835	2.83	0.31837	0.23812	25.21	0.12720	0.13153	3.41
0.69692	0.72364	3.83	0.65586	0.68302	4.14	0.52550	0.52801	0.48
0.85002	0.81400	4.24	0.94431	0.86893	7.98	0.92521	0.91226	1.40
0.70696	0.65835	6.88	0.19701	0.23812	20.87	0.13399	0.13153	1.84
0.79910	0.81400	1.86	0.92436	0.86893	6.00	0.93428	0.91226	2.36
0.05023	0.11405	127.07	0.16791	0.13962	16.85	0.05751	0.04369	24.03
0.59023	0.64016	8.46	0.13300	0.13778	3.60	0.20057	0.20846	3.94
0.80949	0.81400	0.56	0.75644	0.86893	14.87	0.87054	0.91226	4.79
0.60443	0.64016	5.91	0.17290	0.13778	20.31	0.19377	0.20846	7.58
0.60270	0.64016	6.22	0.16376	0.13778	15.86	0.21473	0.20846	2.92
0.83893	0.72364	13.74	0.67747	0.68302	0.82	0.55297	0.52801	4.51
0.71631	0.81400	13.64	0.96426	0.86893	9.89	0.90623	0.91226	0.66
0.66678	0.72364	8.53	0.60432	0.68302	13.02	0.50085	0.52801	5.42

0.63422	0.72364	14.10	0.70241	0.68302	2.76	0.51161	0.52801	3.21
0.67302	0.65835	2.18	0.24023	0.23812	0.88	0.12266	0.13153	7.23
0.67752	0.64016	5.51	0.16874	0.13778	18.35	0.19915	0.20846	4.68
0.59023	0.64016	8.46	0.13300	0.13778	3.60	0.20057	0.20846	3.94
0.90578	0.72364	20.11	0.67997	0.68302	0.45	0.58980	0.52801	10.48
0.11534	0.11405	1.13	0.13549	0.13962	3.04	0.04646	0.04369	5.96
0.68272	0.65835	3.57	0.19784	0.23812	20.36	0.13286	0.13153	1.00
0.91895	0.81400	11.42	0.84456	0.86893	2.89	0.90028	0.91226	1.33
0.66297	0.64016	3.44	0.12801	0.13778	7.63	0.20595	0.20846	1.22
0.74991	0.81400	8.55	0.85536	0.86893	1.59	0.89660	0.91226	1.75
0.77658	0.81400	4.82	0.91854	0.86893	5.40	0.92720	0.91226	1.61
0.77658	0.81400	4.82	0.91854	0.86893	5.40	0.92720	0.91226	1.61
0.81538	0.72364	11.25	0.67332	0.68302	1.44	0.54844	0.52801	3.72
0.64046	0.64016	0.05	0.13882	0.13778	0.75	0.18300	0.20846	13.91
1.00000	0.81400	18.60	0.74314	0.86893	16.93	0.87819	0.91226	3.88
0.60928	0.65835	8.05	0.20116	0.23812	18.37	0.12918	0.13153	1.82
0.78490	0.81400	3.71	0.99002	0.86893	12.23	0.90312	0.91226	1.01
0.86491	0.81400	5.89	0.87781	0.86893	1.01	0.95722	0.91226	4.70
0.63422	0.72364	14.10	0.70241	0.68302	2.76	0.51161	0.52801	3.21
0.85175	0.81400	4.43	0.95096	0.86893	8.63	0.90085	0.91226	1.27
0.16522	0.11405	30.97	0.13051	0.13962	6.98	0.04674	0.04369	6.53
0.73502	0.64016	12.91	0.12303	0.13778	12.00	0.21133	0.20846	1.36
0.65085	0.65835	1.15	0.30756	0.23812	22.58	0.15042	0.13153	12.56
0.15068	0.11405	24.31	0.00000	0.13962	13.96	0.10567	0.04369	58.65
0.84655	0.81400	3.85	0.93101	0.86893	6.67	0.97422	0.91226	6.36
0.63873	0.64016	0.23	0.12968	0.13778	6.25	0.20425	0.20846	2.06
0.59023	0.64016	8.46	0.13300	0.13778	3.60	0.20057	0.20846	3.94
0.73121	0.65835	9.96	0.19534	0.23812	21.90	0.13513	0.13153	2.66
Error promedio (%)	24.60	Error promedio (%)	12.13	Error promedio (%)	24.24			

Realizado por: Ocaña, Lisbeth, 2024.

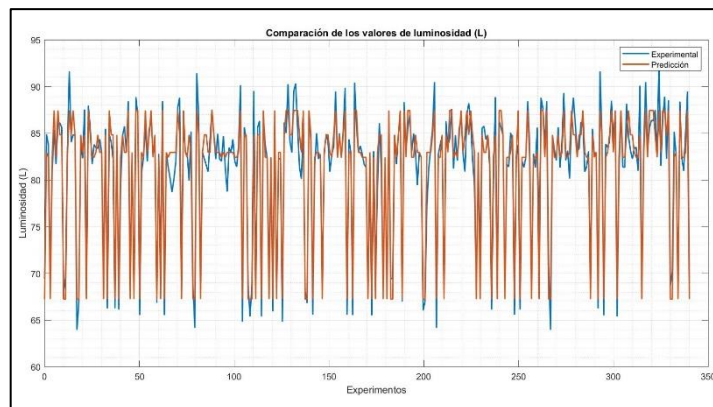


Ilustración 4-8: Datos experimentales de L vs predichos

Realizado por: Ocaña, L., 2024.

Las ilustraciones 4-8 a 4-10 muestran una comparación gráfica entre los resultados predichos por la RNA y los datos obtenidos experimentalmente para las 3 variables de salidas dispuestas en la red neuronal.

La ilustración 4-8 corresponde a la comparación de los valores de luminosidad. Podemos observar que el patrón que siguen los datos predichos es muy similar al que siguen los datos experimentales y, en muchos puntos, ambas líneas se superponen. El error promedio expresado en unidades de porcentaje para los valores de luminosidad es de 24.6%.




Ilustración 4-9: Datos experimentales de a^* vs predichos

Realizado por: Ocaña, L., 2024.

Por otro lado, la ilustración 4-9 muestra los valores experimentales versus los obtenidos por el modelo de predicción para la variable de coordenadas rojo/verde (a^*). Se evidencia superposición entre las curvas representativas de los datos experimentales y las predicciones, lo que indica que hay similitud entre ambos conjuntos de datos. La media del error porcentual encontrada en la comparación de los grupos de datos mencionados es del 12.13%.

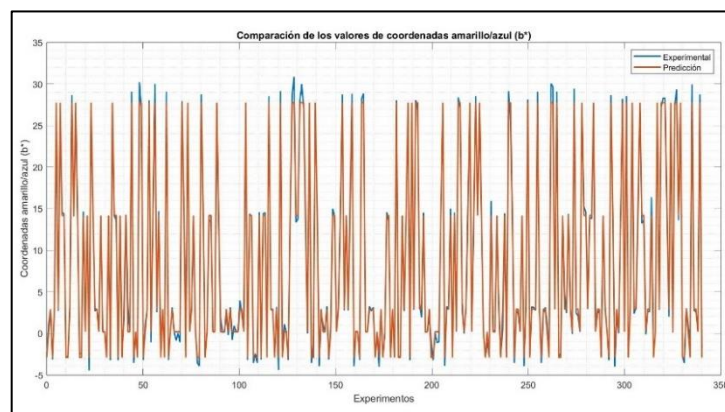


Ilustración 4-10: Datos experimentales de b^* vs predichos

Realizado por: Ocaña, L., 2024.

En la ilustración 4-10 están representados los datos de b^* experimentales en contraste con los de la RNA. De igual forma, las curvas se solapan, siguiendo un patrón semejante a lo largo de los experimentos. El error porcentual medio de la comparación de esta variable es de 24.24%.

En general, las gráficas de dispersión observadas en la presente sección denotan una afinidad elevada entre los grupos de datos evaluados. Las curvas en la gran mayoría de su extensión se superponen y no se visualizan valores atípicos. Los pequeños desfases entre las curvas se explican con el MSE que presentó el modelo de predicción en el entrenamiento (0.00205896).

4.2.4.2. RNA vs datos externos

Es fundamental demostrar el funcionamiento del modelo de predicción diseñado y entrenado, de manera que se pueda convertir en una herramienta confiable en la estimación precisa de formulaciones específicas para la obtención del color deseado en el tinturado de los textiles.

Con este fin, se seleccionó un conjunto de 60 pares de datos, correspondientes a las 3 variables de entrada y salida, que no fueron utilizados en el entrenamiento de la RNA. De esta forma, en la tabla 4-5, con la comparación de los datos predichos con datos externos que la red no aprendió previamente, se trató de comprobar qué tan extrapolable es el poder de predicción del modelo.

Tabla 4-5: Base de datos para la validación vs predicciones de la RNA

Luminosidad			Coordenadas rojo/verde			Coordenadas amarillo/azul		
L	L (RNA)	Error (%)	a*	a* (RNA)	Error (%)	b*	b* (RNA)	Error (%)
0.81711	0.72364	11.44	0.68080	0.68302	0.33	0.52578	0.52801	0.42
0.03741	0.11405	204.86	0.12552	0.13962	11.23	0.08357	0.04369	47.72
0.14028	0.11405	18.70	0.13300	0.13962	4.97	0.04646	0.04369	5.96
0.65016	0.65835	1.26	0.25187	0.23812	5.46	0.09660	0.13153	36.16
0.65293	0.64016	1.95	0.01663	0.13778	728.77	0.29037	0.20846	28.21
0.79910	0.81400	1.86	0.92436	0.86893	6.00	0.93428	0.91226	2.36
0.11534	0.11405	1.13	0.13549	0.13962	3.04	0.04646	0.04369	5.96
0.77658	0.81400	4.82	0.91854	0.86893	5.40	0.92720	0.91226	1.61
0.84829	0.81400	4.04	0.93766	0.86893	7.33	0.94958	0.91226	3.93
0.73987	0.65835	11.02	0.29593	0.23812	19.53	0.08442	0.13153	55.81
0.77000	0.81400	5.71	0.81047	0.86893	7.21	0.85666	0.91226	6.49
0.65847	0.65835	0.02	0.19867	0.23812	19.86	0.13144	0.13153	0.07
0.74991	0.81400	8.55	0.85536	0.86893	1.59	0.89660	0.91226	1.75
0.85729	0.81400	5.05	0.77224	0.86893	12.52	0.86006	0.91226	6.07
0.59196	0.64016	8.14	0.14214	0.13778	3.07	0.17989	0.20846	15.89
0.58677	0.72364	23.33	0.69493	0.68302	1.71	0.50283	0.52801	5.01
0.14028	0.11405	18.70	0.13300	0.13962	4.97	0.04646	0.04369	5.96

0.51126	0.65835	28.77	0.27598	0.23812	13.72	0.12805	0.13153	2.72
0.91340	0.81400	10.88	0.82461	0.86893	5.37	0.97507	0.91226	6.44
0.79667	0.81400	2.17	0.87282	0.86893	0.45	0.88640	0.91226	2.92
0.67752	0.64016	5.51	0.16874	0.13778	18.35	0.19915	0.20846	4.68
0.65847	0.65835	0.02	0.19867	0.23812	19.86	0.13144	0.13153	0.07
0.11534	0.11405	1.13	0.13549	0.13962	3.04	0.04646	0.04369	5.96
0.63388	0.65835	3.86	0.20033	0.23812	18.86	0.13031	0.13153	0.94
0.07516	0.11405	51.73	0.16542	0.13962	15.60	0.05751	0.04369	24.03
0.63873	0.64016	0.23	0.12968	0.13778	6.25	0.20425	0.20846	2.06
0.67336	0.72364	7.47	0.65337	0.68302	4.54	0.52125	0.52801	1.30
0.68272	0.65835	3.57	0.19784	0.23812	20.36	0.13286	0.13153	1.00
0.10495	0.11405	8.66	0.10889	0.13962	28.21	0.03456	0.04369	26.42
0.12539	0.11405	9.05	0.16043	0.13962	12.97	0.05779	0.04369	24.40
0.62729	0.64016	2.05	0.16209	0.13778	15.00	0.21671	0.20846	3.81
0.69934	0.65835	5.86	0.25021	0.23812	4.83	0.09858	0.13153	33.42
0.63422	0.72364	14.10	0.70241	0.68302	2.76	0.51161	0.52801	3.21
0.79667	0.81400	2.17	0.87282	0.86893	0.45	0.88640	0.91226	2.92
0.02529	0.11405	351.03	0.17041	0.13962	18.07	0.05751	0.04369	24.03
0.76723	0.72364	5.68	0.66584	0.68302	2.58	0.53881	0.52801	2.00
0.65778	0.72364	10.01	0.70574	0.68302	3.22	0.51586	0.52801	2.36
0.82265	0.81400	1.05	0.93101	0.86893	6.67	0.94164	0.91226	3.12
0.65016	0.65835	1.26	0.25187	0.23812	5.46	0.09660	0.13153	36.16
0.58469	0.65835	12.60	0.20283	0.23812	17.40	0.12776	0.13153	2.95
0.61067	0.72364	18.50	0.69825	0.68302	2.18	0.50737	0.52801	4.07
0.68445	0.81400	18.93	0.88279	0.86893	1.57	0.94618	0.91226	3.58
0.65327	0.64016	2.01	0.17041	0.13778	19.14	0.19745	0.20846	5.58
0.78698	0.81400	3.43	0.75145	0.86893	15.63	0.86402	0.91226	5.58
0.88569	0.81400	8.09	0.83042	0.86893	4.64	0.91586	0.91226	0.39
0.72844	0.72364	0.66	0.71571	0.68302	4.57	0.52861	0.52801	0.11
0.18739	0.11405	39.14	0.19119	0.13962	26.97	0.04816	0.04369	9.28
0.64046	0.64016	0.05	0.13882	0.13778	0.75	0.18300	0.20846	13.91
0.68722	0.64016	6.85	0.12635	0.13778	9.05	0.20793	0.20846	0.26
0.61448	0.64016	4.18	0.13134	0.13778	4.91	0.20255	0.20846	2.92
0.74818	0.65835	12.01	0.24938	0.23812	4.51	0.10057	0.13153	30.79
0.20090	0.11405	43.23	0.15378	0.13962	9.21	0.05864	0.04369	25.49
0.67510	0.72364	7.19	0.66085	0.68302	3.36	0.49972	0.52801	5.66
0.73121	0.65835	9.96	0.19534	0.23812	21.90	0.13513	0.13153	2.66
0.67336	0.72364	7.47	0.65337	0.68302	4.54	0.52125	0.52801	1.30
0.68722	0.64016	6.85	0.12635	0.13778	9.05	0.20793	0.20846	0.26
0.63388	0.65835	3.86	0.20033	0.23812	18.86	0.13031	0.13153	0.94
0.76896	0.72364	5.89	0.67332	0.68302	1.44	0.51671	0.52801	2.19
0.77000	0.81400	5.71	0.81047	0.86893	7.21	0.85666	0.91226	6.49
0.63422	0.72364	14.10	0.70241	0.68302	2.76	0.51161	0.52801	3.21
Error promedio (%)		18.13	Error promedio (%)		20.99	Error promedio (%)		9.52

Realizado por: Ocaña, Lisbeth, 2024.

De igual manera, las ilustraciones que se muestran (4-11 a 4-13) representan las gráficas de dispersión para la comparación de los valores de salida de la red en contraste con la base de datos externa que se utilizó.




Ilustración 4-11: Datos experimentales de luminosidad vs RNA en la validación
Realizado por: Ocaña, L., 2024.

En la ilustración 4-11 se grafican las curvas correspondientes a los valores experimentales para la validación (azul) y los predichos por la RNA (roja). Observamos que el patrón que siguen ambas curvas es similar y existe una considerable superposición en los valores. El error porcentual medio de la comparación de esta variable resultó en un 18.13%.

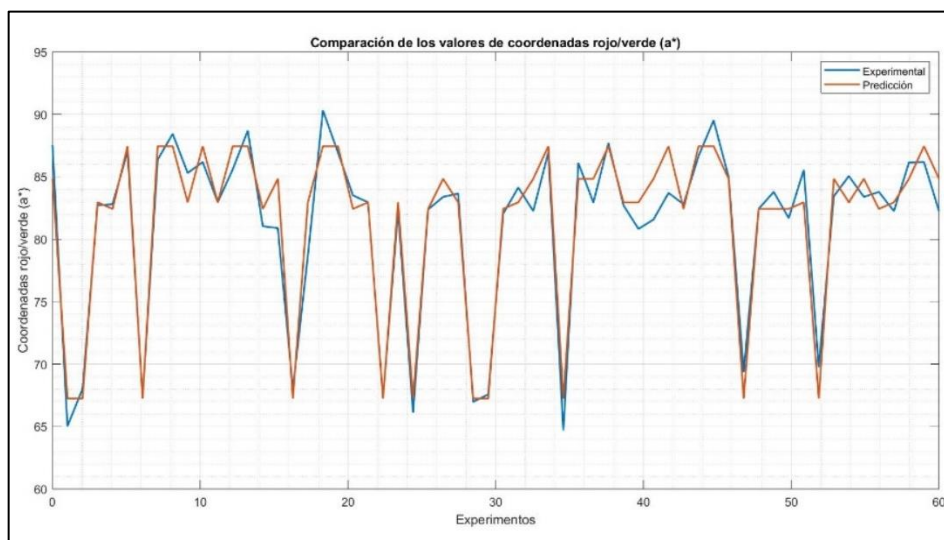


Ilustración 4-12: Datos experimentales de a^* vs RNA en la validación
Realizado por: Ocaña, L., 2024.

El gráfico de dispersión de la ilustración 4-12 compara los valores reales con los valores predichos por el modelo de la variable coordenadas rojo/verde (a^*). Podemos observar que las curvas se superponen en muchos puntos y el comportamiento es similar. El porcentaje de error asociado a la comparación de los valores de salida para esta variable es de 20.99%.

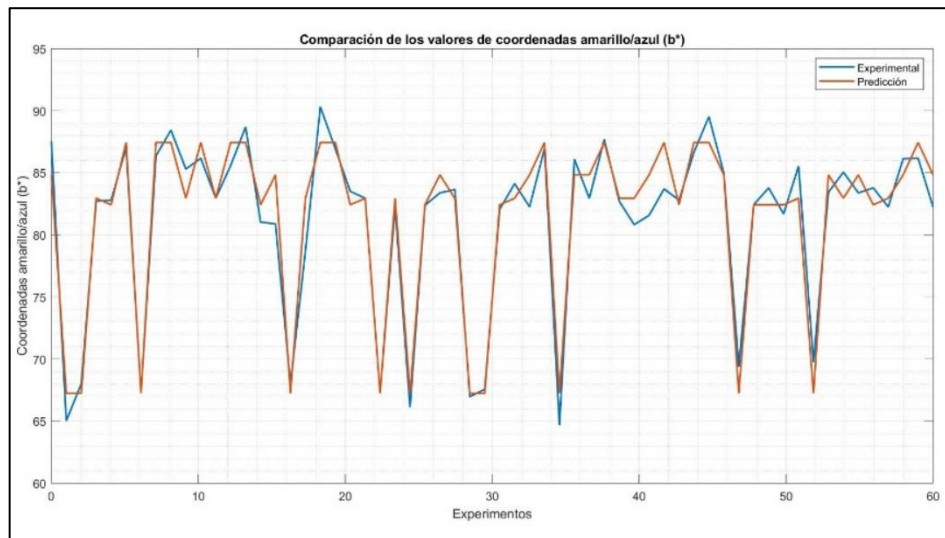


Ilustración 4-13: Datos experimentales de b^* vs RNA en la validación

Realizado por: Ocaña, L., 2024.

Por último, la ilustración 4-13 es la representación gráfica de los valores de la variable coordenadas amarillo/azul (b^*), tanto experimentales como predichos por la red. En la gráfica podemos visualizar un comportamiento de las variables similar a los anteriores casos, con superposición de las curvas en ciertos valores y una concordancia en la evolución de ambos valores. Un 9.52% es el error porcentual promedio que se asocia a la variable que se compara.

De forma general, el nivel de compatibilidad mostrado en los gráficos de dispersión expuestos en la presente sección es bueno. En los 3 casos existe una superposición entre las curvas y patrones similares en su evolución.

La superposición es el rasgo más importante que nos indica concordancia entre los valores reales y los predichos. Además, no se evidencian valores atípicos de forma gráfica, por lo que, bajo este análisis, se puede afirmar que la RNA diseñada tiene un funcionamiento aceptable. En la siguiente sección se lleva a cabo un análisis para determinar estadísticamente si el modelo de predicción posee la robustez y confiabilidad necesaria para ser utilizado en la predicción.

4.2.5. Análisis estadístico

Para determinar de forma objetiva la validez del modelo propuesto, es necesario realizar un análisis estadístico que corrobore su nivel de seguridad en la predicción de las formulaciones de color para el tinturado de textiles en las condiciones establecidas.

Para el análisis estadístico del presente trabajo de integración curricular se utilizó el software STATGRAPHICS 18, y los datos procesados fueron los que se utilizaron en la validación del modelo.

Tabla 4-6: Análisis ANOVA para todas las variables

<i>Luminosidad (L)</i>					
<i>Fuente</i>	<i>Suma de cuadrados</i>	<i>GL</i>	<i>Cuadrado medio</i>	<i>Razón-F</i>	<i>Valor-p</i>
Entre grupos	0.00198763	1	0.00198763	0.03	0.8550
Intra grupos	6.99418	118	0.0592727		
Total (Corr.)	6.99617	119			
<i>Coordenadas rojo/verde (a*)</i>					
<i>Fuente</i>	<i>Suma de cuadrados</i>	<i>GL</i>	<i>Cuadrado medio</i>	<i>Razón-F</i>	<i>Valor-p</i>
Entre grupos	0.000625633	1	0.000625633	0.01	0.9361
Intra grupos	11.4357	118	0.0969125		
Total (Corr.)	11.4363	119			
<i>Coordenadas amarillo/azul (b*)</i>					
<i>Fuente</i>	<i>Suma de cuadrados</i>	<i>GL</i>	<i>Cuadrado medio</i>	<i>Razón-F</i>	<i>Valor-p</i>
Entre grupos	0.000690912	1	0.000690912	0.01	0.9372
Intra grupos	13.0764	118	0.110817		
Total (Corr.)	13.077	119			

Fuente: STATGRAPHICS® 18.

Realizado por: Ocaña, Lisbeth, 2024.

El análisis de varianza (ANOVA) que se muestra en la tabla 4-6 sirve para comparar las dos muestras (experimental vs predicha) de cada variable. Este divide el análisis en dos componentes: uno entre grupos y otro intra grupos.

El valor de la razón-F, que en este caso es 0.03, 0.01 y 0.01 para las variables L, a* y b*, respectivamente, es la relación entre ambos grupos en los que se descompone el análisis. Como el valor-p de la prueba-F es mayor o igual a 0.05 en los tres casos, se puede afirmar que no existe

una diferencia estadísticamente significativa entre las medias de las 2 variables comparadas con un 5% de nivel de significancia.

Asimismo, se realiza un análisis de la tabla de medias para las 3 variables de salida. La tabla 4-7 resume el valor de la media, el error estándar y el intervalo de confianza de cada grupo de datos. El error estándar representa una medida de la variabilidad del muestreo y se consigue dividiendo la desviación estándar para la raíz cuadrada del número de observaciones de cada nivel.

Tabla 4-7: Tabla de medias

<i>Luminosidad (L)</i>					
	<i>Casos</i>	<i>Media</i>	<i>Error estándar</i>	<i>Límite inferior</i>	<i>Límite superior</i>
L (Exp)	60	0.596767	0.0314305	0.552756	0.640778
L (RNA)	60	0.604906	0.0314305	0.560895	0.648917
Total	120	0.600837			
<i>Coordenadas rojo/verde (a*)</i>					
	<i>Casos</i>	<i>Media</i>	<i>Error estándar</i>	<i>Límite inferior</i>	<i>Límite superior</i>
a* (Exp)	60	0.434941	0.0401896	0.378664	0.491217
a* (RNA)	60	0.439507	0.0401896	0.383231	0.495784
Total	120	0.437224			
<i>Coordenadas amarillo/azul (b*)</i>					
	<i>Casos</i>	<i>Media</i>	<i>Error estándar</i>	<i>Límite inferior</i>	<i>Límite superior</i>
b* (Exp)	60	0.434941	0.0429761	0.324737	0.445093
b* (RNA)	60	0.439507	0.0429761	0.329536	0.449892
Total	120	0.437224			

Fuente: STATGRAPHICS® 18.

Realizado por: Ocaña, Lisbeth, 2024.

El intervalo de confianza alrededor de la media de cada muestra también se muestra en la tabla 4-7. Este intervalo está construido de tal manera que si dos medias son iguales, sus intervalos se superpondrán en el 95% de las ocasiones. Este es el caso de los grupos analizados, que en todas las variables que se comparan existe un error estándar igual y sus intervalos de confianza se traslapan. Los intervalos de confianza obtenidos para cada variable son: 0.552756-0.640778 y 0.560895-0.648917 para los valores experimentales y predichos de luminosidad, respectivamente, 0.378664-0.491217 para las coordenadas rojo/verde, y 0.324737-0.445093 y 0.329536-0.449892 para las coordenadas amarillo/azul. De esto podemos concluir que las medias de ambos grupos son estadísticamente iguales con un nivel del 95% de confianza.

De forma general, el análisis estadístico nos indica que los valores predichos por el modelo de red neuronal artificial planteado son de buena calidad y se confirma la validez del mismo para la predicción de las formulaciones de colorantes en el proceso de tintura de fibras textiles en los procesos de la empresa PROLAVTEX.

CONCLUSIONES

- Se aplicó satisfactoriamente un modelo de redes neuronales artificiales (RNA) para la dosificación adecuada de los colores en textiles de la empresa PROLAVTEX. La implementación exitosa de este modelo representa un avance significativo en la optimización y eficiencia del proceso de tinturado de textiles, permitiendo una dosificación más precisa y una reducción en el error de concordancia de los colores. Los resultados obtenidos demuestran la viabilidad y la utilidad práctica de la aplicación de tecnologías innovadoras como las redes neuronales en el ámbito industrial, ofreciendo beneficios tangibles en términos de calidad del producto, eficiencia operativa y competitividad empresarial. Este proyecto sienta las bases para futuras investigaciones y aplicaciones de tecnologías de inteligencia artificial en la industria manufacturera.
- Se identificaron y definieron las variables clave del proceso de dosificación de colores en textiles de la empresa PROLAVTEX, lo que permitió establecer claramente las entradas y salidas del modelo de red neuronal artificiales (RNA). Esta fase proporcionó la base necesaria para el desarrollo exitoso del proyecto, determinando 3 variables de entrada y 3 variables de salida para el modelo predictivo que se consiguió. Al seleccionar las variables de entrada representativas de los colorantes más comunes utilizados en la industria textil (amarillo, azul y rojo), junto con las variables de salida que representan las coordenadas L, a* y b* del espacio de color CIELAB, se aseguró una representación exhaustiva y precisa de los aspectos clave del proceso de dosificación.
- Se determinó la arquitectura de la red neuronal artificial, resultando en una etapa fundamental para la predicción precisa de la dosificación de tintes. A través de un proceso iterativo de ajuste y evaluación, se pudo establecer una estructura óptima que maximizó la capacidad de la RNA para generar predicciones confiables y precisas. Para elegir la arquitectura ideal de la RNA, se evaluaron los valores de error cuadrático medio (MSE) y coeficiente de correlación de Pearson (R) que ofrece la herramienta Neural Net Fitting de MATLAB®. De esta forma, se eligió el número óptimo de neuronas en la capa oculta y el algoritmo de entrenamiento a utilizar. La red con 30 neuronas en la capa oculta y con el algoritmo de entrenamiento Levenberg-Marquardt presentó valores de $MSE = 0.99125$ y $R = 1.609E-03$, siendo la que mejores resultados arrojó y la arquitectura elegida para el modelo de predicción final.
- Se validó la dosificación predicha por la RNA mediante ensayos experimentales, demostrando la efectividad y la utilidad práctica del modelo desarrollado. Los resultados

obtenidos en los ensayos corroboraron la capacidad de la RNA para proporcionar recomendaciones precisas de dosificación, lo que confirma su viabilidad como una herramienta de apoyo en el proceso de tinturado de textiles en PROLAVTEX. La valoración visual, a través de gráficos de dispersión, y el análisis estadístico brindó un base objetiva sobre la que concluir que el modelo es confiable para la predicción. El error porcentual promedio fue de 18.13, 20.99 y 9.52% para la luminosidad, coordenadas rojo/verde y coordenadas amarillo/azul, respectivamente. Los valores-p del análisis ANOVA (0.8550, 0.9361 y 0.9372) fueron mayores de 0.05, por lo que, en los 3 casos se afirmó que no existe diferencia estadísticamente significativa entre las medias de los grupos.

RECOMENDACIONES

- Aunque el modelo desarrollado ha demostrado ser efectivo, siempre existe margen para la mejora continua. Se recomienda realizar ajustes adicionales en la arquitectura de la red neuronal para maximizar su precisión y eficiencia. Esto puede implicar la exploración de diferentes configuraciones de capas ocultas, algoritmos de entrenamiento y funciones de activación para optimizar el rendimiento del modelo.
- Ampliar el conjunto de datos de entrenamiento puede mejorar la capacidad de generalización del modelo y su capacidad para manejar una mayor variedad de escenarios y condiciones. Se sugiere recopilar y agregar más datos de dosificación de colores de diferentes tipos de tejidos, condiciones ambientales y lotes de producción para enriquecer el conjunto de entrenamiento y fortalecer la robustez del modelo.
- Establecer un sistema de monitoreo continuo del rendimiento del modelo de RNA en la producción en tiempo real puede ayudar a identificar y abordar rápidamente cualquier desviación o anomalía en la dosificación de colores. Se recomienda integrar sensores y dispositivos de medición automatizados en el proceso de producción para recopilar datos en tiempo real y ajustar el modelo según sea necesario.
- Es fundamental proporcionar capacitación y entrenamiento adecuados al personal involucrado en la implementación y operación del modelo de RNA. Esto garantizará una comprensión completa de cómo utilizar el modelo de manera efectiva y aprovechar al máximo su potencial

BIBLIOGRAFÍA

1. **AKCAKOCA, E.P., OZGUNEY, A.T. & ATAV, R.** "The efficiency of washing agents in the post-dyeing removal of hydrolyzed reactive dye". *Dyes and Pigments* [en línea], 2007, (Netherlands), vol. 72 (1), págs. 23-27. [Consulta: 21 enero 2024]. ISSN 0143-7208. Disponible en: <https://doi.org/10.1016/j.dyepig.2005.07.011>
2. **AMELIO, Alessia, BONIFAZI, Gianluca, CORRADINI, Enrico, DI SAVERIO, Simone, MARCHETTI, Michele, URSINO, Domenico & VIRGILI, Luca.** "Defining a deep neural network ensemble for identifying fabric colors". *Applied Soft Computing* [en línea], 2022, (Netherlands), vol. 130, págs. 1-6. [Consulta: 5 agosto 2023]. ISSN 1568-4946. Disponible en: <https://doi.org/10.1016/j.asoc.2022.109687>
3. **BAHLMANN, Claus, HEIDEMANN, Gunther & RITTER, Helge** "Artificial neural networks for automated quality control of textile seams". *Pattern Recognition* [en línea], 1999, (United Kingdom), vol. 32 (6), págs. 1049-1060. [Consulta: 5 agosto 2023]. ISSN 0031-3203. Disponible en: [https://doi.org/10.1016/S0031-3203\(98\)00128-9](https://doi.org/10.1016/S0031-3203(98)00128-9)
4. **BEST, J.** "Colour specification and visual approval methods for textiles". *Colour Design: Theories and Applications* [en línea]. Cambridge-United Kingdom: Woodhead Publishing Series in Textiles, 2012, págs. 271-294. [Consulta: 7 agosto 2023]. Disponible en: <https://doi.org/10.1533/9780857095534.2.271>
5. **BIDE, M.** "Colour measurement and fastness assessment". *Colour Measurement: Principles, Advances and Industrial Applications* [en línea]. Cambridge-United Kingdom: Woodhead Publishing Series in Textiles, 2010, págs. 196-217. [Consulta: 7 agosto 2023]. Disponible en: <https://doi.org/10.1533/9780857090195.1.196>
6. **BINJIE, X. & HU, J.** "Fabric appearance testing". *Fabric Testing* [en línea]. Cambridge-United Kingdom: Woodhead Publishing Series in Textiles, 2008, págs. 148-188. [Consulta: 7 agosto 2023]. Disponible en: <https://doi.org/10.1533/9781845695064.148>
7. **CHAKRABORTY, J.N.** "Dyeing with reactive dye". *Fundamentals and Practices in Colouration of Textiles* [en línea]. Delhi-India: Woodhead Publishing India, 2010a, págs. 57-75. [Consulta: 6 agosto 2023]. Disponible en: <https://doi.org/10.1533/9780857092823.57>

8. **CHAKRABORTY, J.N.** "Introduction to dyeing of textiles". *Fundamentals and Practices in Colouration of Textiles* [en línea]. Delhi-India: Woodhead Publishing India, 2010b, págs. 1-10. [Consulta: 6 agosto 2023]. Disponible en: <https://doi.org/10.1533/9780857092823.1>
9. **CHAKRABORTY, J.N.** "Dyeing with reactive dye". *Fundamentals and Practices in Colouration of Textiles* [en línea]. Delhi-India: Woodhead Publishing India, 2014, págs. 61-76. [Consulta: 6 agosto 2023]. Disponible en: <https://doi.org/10.1016/B978-93-80308-46-3.50015-7>
10. **DICKINSON, K.** "The use of colour in textile design". *Textile Design* [en línea]. Cambridge-United Kingdom: Woodhead Publishing Series in Textiles, 2011, págs. 171-191. [Consulta: 6 agosto 2023]. Disponible en: <https://doi.org/10.1533/9780857092564.2.171>
11. **DODANGEH, Mohammad, GHARANJIG, Kamaladin, ARAMI, Mokhtar & ATASHROUZ, Saeid.** "Surface alteration of polyamide fibers by polyamidoamine dendrimers and optimization of treatment process using neural network towards improving their dyeing properties". *Dyes and Pigments* [en línea], 2014, (Netherlands), vol. 111, págs. 30-38. [Consulta: 5 agosto 2023]. ISSN 0143-7208. Disponible en: <https://doi.org/10.1016/j.dyepig.2014.05.025>
12. **ELEMEN, Seniha, AKÇAKOCA KUMBASAR, Emriye Perrin & YAPAR, Saadet.** "Modeling the adsorption of textile dye on organoclay using an artificial neural network". *Dyes and Pigments* [en línea], 2012, (Netherlands), vol. 95 (1), págs. 102-111. [Consulta: 5 agosto 2023]. ISSN 0143-7208. Disponible en: <https://doi.org/10.1016/j.dyepig.2012.03.001>
13. **FANG, Yinchun, LIU, Xinhua, ZHENG, Hongliang & LIU, Hailong.** "Eco-friendly colorization of textile originating from polydopamine nanofilm structural color with high colorfastness". *Journal of Cleaner Production* [en línea], 2021, (United Kingdom), vol. 295, págs. 1-7. [Consulta: 5 agosto 2023]. ISSN 0959-6526. Disponible en: <https://doi.org/10.1016/j.jclepro.2021.126523>
14. **FÁVERO, Luiz Paulo, BELFIORE, Patrícia & DE FREITAS SOUZA, Rafael.** "Artificial neural networks". *Data Science, Analytics and Machine Learning with R* [en línea]. Oxford-United Kingdom: Academic Press, 2023, págs. 441-467. [Consulta: 7 agosto 2023]. Disponible en: <https://doi.org/10.1016/B978-0-12-824271-1.00023-8>

15. **GANGAKHEDKAR, N.S.** "Colour measurement methods for textiles". *Colour Measurement: Principles, Advances and Industrial Applications* [en línea]. Cambridge-United Kingdom: Woodhead Publishing Series in Textiles, 2010, págs. 221-252. [Consulta: 7 agosto 2023]. Disponible en: <https://doi.org/10.1533/9780857090195.2.221>
16. **GARCIA, Vanessa S.G., ROSA, Jorge M. y BORRELY, Suelí I.** "Toxicity and color reduction of a textile effluent containing reactive red 239 dye by electron beam irradiation". *Radiation Physics and Chemistry* [en línea], 2020, (United Kingdom), vol. 172, págs. 1-6. [Consulta: 5 agosto 2023]. ISSN 0969-806X. Disponible en: <https://doi.org/10.1016/j.radphyschem.2020.108765>
17. **GRISHANOV, S.** "Structure and properties of textile materials". *Handbook of Textile and Industrial Dyeing: Principles, Processes and Types of Dyes* [en línea]. Cambridge-United Kingdom: Woodhead Publishing Series in Textiles, 2011, págs. 28-63. [Consulta: 6 agosto 2023]. Disponible en: <https://doi.org/10.1533/9780857093974.1.28>
18. **HE, Zhenglei, TRAN, Kim Phuc, THOMASSEY, Sebastien, ZENG, Xianyi, XU, Jie & YI, Changhai.** "A deep reinforcement learning based multi-criteria decision support system for optimizing textile chemical process". *Computers in Industry* [en línea], 2021, (Netherlands), vol. 125, págs 1-6. [Consulta: 5 agosto 2023]. ISSN 0166-3615. Disponible en: <https://doi.org/10.1016/j.compind.2020.103373>
19. **HE, Zhenglei, TRAN, Kim Phuc, THOMASSEY, Sebastien, ZENG, Xianyi, XU, Jie y YI, Changhai.** "Multi-objective optimization of the textile manufacturing process using deep-Q-network based multi-agent reinforcement learning". *Journal of Manufacturing Systems* [en línea], 2022, (Netherlands), vol. 62, págs. 939-949. [Consulta: 5 agosto 2023]. ISSN 0278-6125. Disponible en: <https://doi.org/10.1016/j.jmsy.2021.03.017>
20. **HEMMATI-SARAPARDEH, Abdolhossein, LARESTANI, Aydin, NAIT AMAR, Menad & HAJIREZAIE, Sassan.** "Training and optimization algorithms". *Applications of Artificial Intelligence Techniques in the Petroleum Industry* [en línea]. Houston-United States of America: Gulf Professional Publishing, 2020, págs. 51-78. [Consulta: 6 agosto 2023]. Disponible en: <https://doi.org/10.1016/B978-0-12-818680-0.00003-5>
21. **IBRAHIM, N.A.** "Dyeing of textile fibre blends". *Handbook of Textile and Industrial Dyeing* [en línea]. Cambridge-United Kingdom: Woodhead Publishing Series in Textiles,

2011, págs. 147-172. [Consulta: 6 agosto 2023]. Disponible en: <https://doi.org/10.1533/9780857094919.1.147>

22. **IBRAHIM, Rehab Ali, ELSHEIKH, Ammar H., ELASYED ABD ELAZIZ, Mohamed & AL-QANESS, Mohammed A.A.** "Basics of artificial neural networks". *Artificial Neural Networks for Renewable Energy Systems and Real-World Applications* [en línea]. Oxford-United Kingdom: Academic Press, 2022, págs. 1-10. [Consulta: 7 agosto 2023]. Disponible en: <https://doi.org/10.1016/B978-0-12-820793-2.00002-1>
23. **IERACE, Stefano, PINTO, Roberto & CAVALIERI, Sergio.** "APPLICATION OF NEURAL NETWORKS TO CONDITION BASED MAINTENANCE: A CASE STUDY IN THE TEXTILE INDUSTRY". *IFAC Proceedings Volumes* [en línea], 2007, (United Kingdom), vol. 40 (3), págs. 147-152. [Consulta: 5 agosto 2023]. ISSN 1474-6670. Disponible en: <https://doi.org/10.3182/20070523-3-ES-4908.00025>
24. **KHIAM, Goh Kheng, KARRI, Rama Rao, MUBARAK, Nabisab Mujawar, KHALID, Mohammad, WALVEKAR, Rashmi, ABDULLAH, Ezzat Chan y RAHMAN, Muhammad Ekhlaur.** "Modelling and optimization for methylene blue adsorption using graphene oxide/chitosan composites via artificial neural network-particle swarm optimization". *Materials Today Chemistry* [en línea], 2022, (United Kingdom), vol. 24, págs. 1-6. [Consulta: 5 agosto 2023]. ISSN 2468-5194. Disponible en: <https://doi.org/10.1016/j.mtchem.2022.100946>
25. **KING, Andrew P. y ALJABAR, Paul.** "Introduction to Computer Programming and MATLAB". *MATLAB Programming for Biomedical Engineers and Scientists* [en línea]. Oxford-United Kingdom: Academic Press, 2017, págs. 1-29. [Consulta: 7 agosto 2023]. Disponible en: <https://doi.org/10.1016/B978-0-12-812203-7.00001-X>
26. **KING, B.M.** "Analysis of Variance". *International Encyclopedia of Education, Third Edition* [en línea]. Amsterdam-Netherlands: Elsevier Science, 2010, págs. 32-36. [Consulta: 11 enero 2024]. Disponible en: <https://doi.org/10.1016/B978-0-08-044894-7.01306-3>
27. **KOTHARI, Manisha S., VEGAD, Kinjal G., SHAH, Kosha A. y ALY HASSAN, Ashraf.** "An artificial neural network combined with response surface methodology approach for modelling and optimization of the electro-coagulation for cationic dye". *Heliyon* [en línea], 2022, (Netherlands), vol. 8 (1), págs. 1-10. [Consulta: 5 agosto 2023]. ISSN 2405-8440.

Disponible en: <https://doi.org/10.1016/j.heliyon.2022.e08749>

28. **LEON, Vitória Brocardo de, NEGREIROS, Bruno Azevedo Ferraz de, BRUSAMARELLO, Claiton Zanini, PETROLI, Gustavo, DI DOMENICO, Michele & SOUZA, Fernanda Batista de.** 2020. "Artificial neural network for prediction of color adsorption from an industrial textile effluent using modified sugarcane bagasse: Characterization, kinetics and isotherm studies". *Environmental Nanotechnology, Monitoring & Management* [en línea], 2020, (Netherlands), vol. 14, págs. 1-5. [Consulta: 5 agosto 2023]. ISSN 2215-1532. Disponible en: <https://doi.org/10.1016/j.enmm.2020.100387>
29. **LEWIS, D.M.** "The chemistry of reactive dyes and their application processes". *Handbook of Textile and Industrial Dyeing: Principles, Processes and Types of Dyes* [en línea]. Cambridge-United Kingdom: Woodhead Publishing Series in Textiles, 2011, págs. 303-364. [Consulta: 6 agosto 2024]. Disponible en: <https://doi.org/10.1533/9780857093974.2.301>
30. **LI, Peng Fei, WANG, Jing & JING, Jun Feng.** "Application of improved back propagation algorithm in color difference detection of fabric". *Color Research & Application* [en línea], 2015, (United States), vol. 40 (3), págs. 311-317. [Consulta: 24 febrero 2023]. ISSN 1520-6378. Disponible en: <https://onlinelibrary.wiley.com/doi/full/10.1002/col.21895>.
31. **LI, Shuai, XIAO, Yuanshu, SHAN, Guohua, FAN, Xinlei, WANG, Mengru, LIU, Rui & JIA, Lixia.** 2022. "Rapid preparation of structural color coatings on flexible textiles by simple vacuum-assisted filtration self-assembly". *Physica E: Low-dimensional Systems and Nanostructures* [en línea], 2022, (Netherlands), vol. 144, págs. 1-6. [Consulta: 5 agosto 2023]. ISSN 1386-9477. Disponible en: <https://doi.org/10.1016/j.physe.2022.115424>
32. **LINDFIELD, George & PENNY, John.** "An Introduction to Matlab®". *Numerical Methods* [en línea]. Oxford-United Kingdom: Academic Press, 2019, págs. 1-72. [Consulta: 7 agosto 2023]. Disponible en: <https://doi.org/10.1016/B978-0-12-812256-3.00010-5>
33. **LIU, Xinhua, LIU, Hailong, ZHENG, Hongliang & FANG, Yinchun.** "Biomimetic fabrication of melanin-like polydopamine nanofilm coating for structural colorization of textile". *Progress in Organic Coatings* [en línea], 2021, (Netherlands), vol. 152, págs. 1-7. [Consulta: 7 agosto 2023]. ISSN 0300-9440. Disponible en: <https://doi.org/10.1016/j.porgcoat.2021.106138>

34. **MERJULAH, R. & CHANDRA, J.** "Classification of Myocardial Ischemia in Delayed Contrast Enhancement Using Machine Learning". *Intelligent Data Analysis for Biomedical Applications: Challenges and Solutions* [en línea]. Oxford-United Kingdom: Academic Press, 2019, págs. 209-235. [Consulta: 26 enero 2024]. Disponible en: <https://doi.org/10.1016/B978-0-12-815553-0.00011-2>
35. **MUKHOPADHYAY, S.** "Artificial neural network applications in textile composites". *Soft Computing in Textile Engineering* [en línea]. Cambridge-United Kingdom: Woodhead Publishing Series in Textiles, 2011, págs. 329-349. [Consulta: 5 agosto 2023]. Disponible en: <https://doi.org/10.1533/9780857090812.4.329>
36. **NIMKAR, Ullhas M. & BHAJEKAR, Rahul.** "Colour fastness". *Colourage* [en línea], 2012, (India), vol. 54 (5), págs. 82-103. [Consulta: 7 agosto 2023]. ISSN 00101826. Disponible en: <https://doi.org/10.1533/9780857097644.1.82>
37. **ORCÓN BASILIO, Beatriz, GIRALDO BORJA, Mariel, FLORES RÚA, Eduardo & YNCA BERROSPI, Anthony.** "Alternativas de pretratamiento textil: método integrado de descruce-blanqueo y blanqueo químico-enzimático, evaluación y comparación con el método clásico". *Revista de la Sociedad Química del Perú* [en línea], 2019, (Perú), vol. 85 (2), págs. 175-188. [Consulta: 21 enero 2024]. ISSN 1810-634X. Disponible en: http://www.scielo.org.pe/scielo.php?script=sci_arttext&pid=S1810-634X2019000200006&lng=es&nrm=iso&tlng=es.
38. **PAUL, R.** "Functional finishes for textiles: an overview". *Functional Finishes for Textiles: Improving Comfort, Performance and Protection* [en línea]. Cambridge-United Kingdom: Woodhead Publishing Series in Textiles, 2015, págs. 1-14. [Consulta: 22 enero 2024]. Disponible en: <https://doi.org/10.1533/9780857098450.1>
39. **PAULRAJ, M.P. & SIVANANDAM, S.N.** *Introduction to Artificial Neural Networks* [en línea]. Dehli-India: Vikas Publishing House Pvt Limited, 2003. [Consulta: 7 agosto 2023]. ISBN 9788125914259. Disponible en: <http://www.vikaspublishing.com/books/computer-science/networkingcommunication/introduction-artificial-neural-networks/9788125914259/#.Vgu2T2PXdgE.mendeley>.
40. **PLOSKAS, Nikolaos & SAMARAS, Nikolaos.** "GPU programming on MATLAB toolboxes". *GPU Programming in MATLAB* [en línea]. Burlington-United States: Morgan

Kaufmann, 2016, págs. 109-170. [Consulta: 7 agosto 2023]. Disponible en: <https://doi.org/10.1016/B978-0-12-805132-0.00005-9>

41. **SAMAD, Abdul, AHMAD, Iftikhar, KANO, Manabu & CALISKAN, Hakan.** "Prediction and Optimization of Exergetic Efficiency of Petroleum Refinery's Reactive Units under Uncertainty through Artificial Neural Network-based Surrogate Modeling". *Process Safety and Environmental Protection* [en línea], 2023, (United Kingdom), vol. 177, págs. 1403-1414. [Consulta: 5 agosto 2023]. ISSN 0957-5820. Disponible en: <https://doi.org/10.1016/j.psep.2023.07.046>
42. **SENTHILKUMAR, M.** "Use of artificial neural networks (ANNs) in colour measurement". *Colour Measurement: Principles, Advances and Industrial Applications* [en línea]. Cambridge-United Kingdom: Woodhead Publishing Series in Textiles, 2010, págs. 125-146. [Consulta: 5 agosto 2023]. Disponible en: <https://doi.org/10.1533/9780857090195.1.125>
43. **SHAMS-NATERI, A. & HASANLOU, E.** "Computer vision techniques for measuring and demonstrating color of textile". *Applications of Computer Vision in Fashion and Textiles* [en línea]. Amsterdam-Netherlands: The Textile Institute Book Series, 2018, págs. 189-220. [Consulta: 5 agosto 2023]. Disponible en: <https://doi.org/10.1016/B978-0-08-101217-8.00008-7>
44. **SHANG, S.M.** "Process control in dyeing of textiles". *Process Control in Textile Manufacturing* [en línea]. Cambridge-United Kingdom: Woodhead Publishing Series in Textiles, 2013, págs. 300-338. [Consulta: 6 agosto 2023]. Disponible en: <https://doi.org/10.1533/9780857095633.3.300>
45. **SHEHAB, Mohammad, ABUALIGAH, Laith, OMARI, Mahmoud, SHAMBOUR, Mohd Khaled Yousef, ALSHINWAN, Mohammad, ABUADDOUS, Hayfa Y. & KHASAWNEH, Ahmad M.** "Artificial neural networks for engineering applications: a review". *Artificial Neural Networks for Renewable Energy Systems and Real-World Applications* [en línea]. Oxford-United Kingdom: Academic Press, 2022, págs. 189-206. [Consulta: 7 agosto 2023]. Disponible en: <https://doi.org/10.1016/B978-0-12-820793-2.00003-3>
46. **SHOOTOV, Artyom, CHIZHOV, Yuriy, ALEKSEJEVA, Ludmila, OKS, Aleksandr & KATASHEV, Alexei.** "Artificial Neural Network Based Approach for Control Points

- Detection in Smart Textile Signals". *Procedia Computer Science* [en línea], 2017, (Netherlands), vol. 104, págs. 548-555. [Consulta: 5 agosto 2023]. ISSN 1877-0509. Disponible en: <https://doi.org/10.1016/j.procs.2017.01.171>
47. **VALENTINE, Daniel T. & HAHN, Brian D.** "MATLAB® fundamentals". *Essential MATLAB for Engineers and Scientists* [en línea]. Oxford-United Kingdom: Academic Press, 2023, págs. 29-77. [Consulta: 7 agosto 2023]. Disponible en: <https://doi.org/10.1016/B978-0-32-399548-1.00008-4>
48. **WARNER, R.D.** Measurements of water-holding capacity and color: Objective and subjective. *Encyclopedia of Meat Sciences* [en línea]. Oxford-United Kingdom: Academic Press, 2024, págs. 478-492. [Consulta: 15 enero 2024]. Disponible en: <https://doi.org/10.1016/B978-0-323-85125-1.00072-7>
49. **ZAVALA ORTIZ, Laura Delia de Jesús.** MINIMIZACIÓN DE LOS ERRORES EN LA FORMULACIÓN DEL COLOR EN LA INDUSTRIA TEXTIL MEDIANTE LA IMPLEMENTACIÓN DE UNA RED NEURONAL ARTIFICIAL. [En línea]. (Trabajo de titulación) (Pregrado). Tecnológico Nacional de México en Celaya, Departamento de Ingeniería Industrial. Celaya-México. 2019. págs. 4-5. [Consulta: 2023-02-25]. Disponible en: [https://rinacional.tecnm.mx/bitstream/TecNM/805/1/Laura Delia de Jesús Zavala Ortiz.pdf](https://rinacional.tecnm.mx/bitstream/TecNM/805/1/Laura%20Delia%20de%20Jes%C3%BA%20Zavala%20Ortiz.pdf)
50. **ZAVALA ORTIZ, Laura Delia de Jesús, VÁZQUEZ LÓPEZ, José Antonio, GUTIÉRREZ ROSAS, Paloma Teresita. & TAPIA ESQUIVAS, Moisés.** "Generación de la formulación de color en un producto textil mediante redes neuronales artificiales". *Nova scientia* [en línea], 2018, (México), vol. 10 (21), págs. 78-96. [Consulta: 24 febrero 2023]. ISSN 2007-0705. DOI 10.21640/NS.V10I21.1507. Disponible en: http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S2007-07052018000200078&lng=es&nrm=iso&tlng=es
51. **ZHANG, Jing & SU, Guanghui.** "Artificial neural network introductions". *Nuclear Power Plant Design and Analysis Codes: Development, Validation, and Application* [en línea]. Cambridge-United Kingdom: Woodhead Publishing Series in Energy, 2021, págs. 515-541. [Consulta: 7 agosto 2023]. Disponible en: <https://doi.org/10.1016/B978-0-12-818190-4.00022-X>

52. **ZURITA BAYAS, Mauricio Alejandro.** Propuesta de mejora en la productividad de la empresa de lavado de prendas de vestir PROLAVTEX [en línea]. (Trabajo de titulación) (Pregrado). Universidad Técnica de Ambato, Facultad de Ingeniería en Sistemas, Electrónica e Industrial, Carrera de Ingeniería Industrial en Procesos de Automatización. Ambato-Ecuador. 2019. pág. 19. [Consulta: 2024-01-14]. Disponible en: <https://repositorio.uta.edu.ec:8443/jspui/handle/123456789/30107>


Total: 52 referencias bibliográficas

ANEXOS


ANEXO A: MUESTRAS GENERADAS PARA EL ANÁLISIS (FORMULACIÓN 1)




ANEXO B: MUESTRAS GENERADAS PARA EL ANÁLISIS (FORMULACIÓN 2)




ANEXO C: MUESTRAS GENERADAS PARA EL ANÁLISIS (FORMULACIÓN 3)



ANEXO D: MUESTRAS GENERADAS PARA EL ANÁLISIS (FORMULACIÓN 4)



ANEXO E: MUESTRAS GENERADAS PARA EL ANÁLISIS (FORMULACIÓN 5)



ANEXO F: VARIABLES UTILIZADAS EN EL DISEÑO Y ENTRENAMIENTO DE LA RNA

Variable	Descripción
Extraer	Variable que almacena el conjunto de datos experimentales.
basedatos	Nombre del archivo de Excel que contiene el conjunto de datos.
LEGIT	Nombre de la hoja de Excel que contiene el conjunto de datos normalizados.
Datos	Variable que almacena los datos convertidos a valores numéricos.
entradas	Variable que almacena los valores de las variables de entrada a la RNA.
salidas	Variable que almacena los valores de las variables de salida a la RNA.

Realizado por: Ocaña, Lisbeth, 2024.

ANEXO G: VARIABLES UTILIZADAS EN LA VALIDACIÓN DE LA RNA

Variable	Descripción
Extraer	Variable que almacena el conjunto de datos experimentales.
Extraer1	Variable que almacena el conjunto de resultados de la RNA.
basedatos	Nombre del archivo de Excel que contiene el conjunto de datos.
LEGIT	Nombre de la hoja de Excel que contiene el conjunto de datos normalizados.
EXNOIR	Nombre de la hoja de Excel que contiene el conjunto de datos sin normalizar.
PRENOIR	Nombre de la hoja de Excel que contiene el conjunto de resultados de la RNA sin normalizar.
Datos	Variable que almacena los datos convertidos a valores numéricos.
Datos1	Resultados de la RNA convertidos a valores numéricos.
entradas	Valores de las variables de entrada a la RNA.
salidas	Variable que almacena los valores de las variables de salida a la RNA.
PropPred	Valores predichos por la RNA.
x	Valores correspondientes al n° de experimentos (entrenamiento).
x1	Valores correspondientes al n° de experimentos (validación).
y1	Valores de luminosidad experimentales (entrenamiento).
y2	Valores de luminosidad predichos (entrenamiento).
y3	Valores de a* experimentales (entrenamiento).
y4	Valores de a* predichos (entrenamiento).
y5	Valores de b* experimentales (entrenamiento).
y6	Valores de b* predichos (entrenamiento).
y7	Valores de luminosidad experimentales (validación).
y8	Valores de luminosidad predichos (validación).
y9	Valores de a* experimentales (validación).
y10	Valores de a* predichos (validación).
y11	Valores de b* experimentales (validación).
Y12	Valores de b* predichos (validación).

Realizado por: Ocaña, Lisbeth, 2024.

ANEXO H: CÓDIGO DE MATLAB® PARA EL ENTRENAMIENTO DE LA RNA

```
%Leer Tabla Desde la Hoja de Excel
Extraer = readtable('basedatos.xlsx','Sheet','LEGIT');

%Convertir la Tabla a Matriz Numérica
Datos = table2array(Extraer);

%Parámetros de Entrada del Proceso (Y,B,R)
entradas = Datos(1:3,:);

%Parámetros de Salida del Proceso
salidas = Datos(4:6,:);

%PROGRAMACIÓN DE LA RED NEURONAL
% Solve an Input-Output Fitting problem with a Neural Network
% Script generated by Neural Fitting app
% Created 13-Feb-2024 20:19:51
%
% This script assumes these variables are defined:
%
%   entradas - input data.
%   salidas  - target data.

x = entradas;
t = salidas;

% Choose a Training Function
% For a list of all training functions type: help nntrain
% 'trainlm' is usually fastest.
% 'trainbr' takes longer but may be better for challenging
problems.
% 'trainscg' uses less memory. Suitable in low memory
situations.
trainFcn = 'trainlm'; % Levenberg-Marquardt backpropagation.

% Create a Fitting Network
hiddenLayerSize = 30;
net = fitnet(hiddenLayerSize,trainFcn);

% Choose Input and Output Pre/Post-Processing Functions
% For a list of all processing functions type: help nnprocess
net.input.processFcns = {'removeconstantrows','mapminmax'};
net.output.processFcns = {'removeconstantrows','mapminmax'};

% Setup Division of Data for Training, Validation, Testing
% For a list of all data division functions type: help
nndivision
net.divideFcn = 'dividerand'; % Divide data randomly
net.divideMode = 'sample'; % Divide up every sample
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;

% Choose a Performance Function
```

```

% For a list of all performance functions type: help
nnperformance
net.performFcn = 'mse'; % Mean Squared Error

% Choose Plot Functions
% For a list of all plot functions type: help nnplot
net.plotFcns = {'plotperform','plottrainstate','ploterrhist',
...
'plotregression','plotfit'};

% Train the Network
[net,tr] = train(net,x,t);

% Test the Network
y = net(x);
e = gsubtract(t,y);
performance = perform(net,t,y)

% Recalculate Training, Validation and Test Performance
trainTargets = t .* tr.trainMask{1};
valTargets = t .* tr.valMask{1};
testTargets = t .* tr.testMask{1};
trainPerformance = perform(net,trainTargets,y)
valPerformance = perform(net,valTargets,y)
testPerformance = perform(net,testTargets,y)

% View the Network
view(net)

% Plots
% Uncomment these lines to enable various plots.
%figure, plotperform(tr)
%figure, plottrainstate(tr)
%figure, ploterrhist(e)
%figure, plotregression(t,y)
%figure, plotfit(net,x,t)

% Deployment
% Change the (false) values to (true) to enable the following
code blocks.
% See the help for each generation function for more
information.
if (false)
    % Generate MATLAB function for neural network for
application
    % deployment in MATLAB scripts or with MATLAB Compiler and
Builder
    % tools, or simply to examine the calculations your trained
neural
    % network performs.
    genFunction(net,'myNeuralNetworkFunction');
    y = myNeuralNetworkFunction(x);
end
if (false)
    % Generate a matrix-only MATLAB function for neural network
code
    % generation with MATLAB Coder tools.

```

```
genFunction(net, 'myNeuralNetworkFunction', 'MatrixOnly', 'yes');
    y = myNeuralNetworkFunction(x);
end
if (false)
    % Generate a Simulink diagram for simulation or deployment
with.
    % Simulink Coder tools.
    gensim(net);
end
```

ANEXO I: CÓDIGO DE MATLAB® PARA LA VALIDACIÓN DE LA RNA

```
%Leer Tabla Desde la Hoja de Excel
Extraer = readtable('basedatos.xlsx','Sheet','LEGIT');

%Convertir la Tabla a Matriz Numérica
Datos = table2array(Extraer);

%Parámetros de Entrada del Proceso (Y,B,R)
entradas = Datos(1:3,:);

PropPred = net(entradas);

%Leer Tabla Desde la Hoja de Excel
Extraer=readtable('basedatos.xlsx','Sheet','EXNOIR');
Extraer1=readtable('basedatos.xlsx','Sheet','PRENOIR');

%Convertir la tabla a Matriz Numérica
Datos = table2array(Extraer);
Datos1 = table2array(Extraer1);

%Parámetros de Salida del proceso(fracciones molares)
salidas = Datos(4:6,:);

x = linspace(0,340,340)

figure
y1 = salidas(1,1:340);
plot(x,y1,'LineWidth',1.5)
grid on
grid minor
hold on
y2 = Datos1(1,1:340);
plot(x,y2,'LineWidth',1.5)
xlabel('Experimentos')
ylabel("Luminosidad (L)")
legend('Experimental','Predicción')
title('Comparación de los valores de luminosidad (L)')

figure
y3 = salidas(2,1:340);
plot(x,y3,'LineWidth',1.5)
grid on
grid minor
hold on
y4 = Datos1(2,1:340);
plot(x,y4,'LineWidth',1.5)
xlabel('Experimentos')
ylabel("Coordenadas rojo/verde (a*)")
legend('Experimental','Predicción')
title('Comparación de los valores de coordenadas rojo/verde (a*)')

figure
y5 = salidas(3,1:340);
```

```

plot(x,y5,'LineWidth',1.5)
grid on
grid minor
hold on
y6 = Datos1(3,1:340);
plot(x,y6,'LineWidth',1.5)
xlabel('Experimentos')
ylabel("Coordenadas amarillo/azul (b*)")
legend('Experimental','Predicción')
title('Comparación de los valores de coordenadas amarillo/azul
(b*)')

```

```

x1 = linspace(0,60,60)

```

```

figure
y7 = salidas(1,341:400);
plot(x1,y7,'LineWidth',1.5)
grid on
grid minor
hold on
y8 = Datos1(1,341:400);
plot(x1,y8,'LineWidth',1.5)
xlabel('Experimentos')
ylabel("Luminosidad (L)")
legend('Experimental','Predicción')
title('Comparación de los valores de luminosidad (L)')

```

```

figure
y9 = salidas(1,341:400);
plot(x1,y9,'LineWidth',1.5)
grid on
grid minor
hold on
y10 = Datos1(1,341:400);
plot(x1,y10,'LineWidth',1.5)
xlabel('Experimentos')
ylabel("Coordenadas rojo/verde (a*)")
legend('Experimental','Predicción')
title('Comparación de los valores de coordenadas rojo/verde
(a*)')

```

```



figure
y11 = salidas(1,341:400);
plot(x1,y11,'LineWidth',1.5)
grid on
grid minor
hold on
y12 = Datos1(1,341:400);
plot(x1,y12,'LineWidth',1.5)
xlabel('Experimentos')
ylabel("Coordenadas amarillo/azul (b*)")
legend('Experimental','Predicción')
title('Comparación de los valores de coordenadas amarillo/azul
(b*)')

```




ESCUELA SUPERIOR POLITÉCNICA DE CHIMBORAZO
CERTIFICADO DE CUMPLIMIENTO DE LA GUÍA PARA
NORMALIZACIÓN DE TRABAJOS DE FIN DE GRADO

Fecha de entrega: 08 / 07 / 2024

INFORMACIÓN DEL AUTOR
Nombres – Apellidos: Lisbeth Pamela Ocaña Guerra
INFORMACIÓN INSTITUCIONAL
Facultad: Ciencias
Carrera: Ingeniería Química
Título a optar: Ingeniera Química
  Nombres y Apellidos Director del Trabajo de Titulación
  Nombres y Apellidos Asesor del Trabajo de Titulación