



TECNOLÓGICO NACIONAL DE MÉXICO
en Celaya



TECNOLÓGICO NACIONAL DE MÉXICO EN CELAYA
DEPARTAMENTO DE INGENIERÍA INDUSTRIAL

**“MINIMIZACIÓN DE LOS ERRORES EN LA
FORMULACIÓN DEL COLOR EN LA INDUSTRIA
TEXTIL MEDIANTE LA IMPLEMENTACIÓN
DE UNA RED NEURONAL ARTIFICIAL”**

**TESIS PROFESIONAL
PARA OBTENER EL GRADO DE:
MAESTRA EN INGENIERÍA INDUSTRIAL**

PRESENTA:

IBQ. LAURA DELIA DE JESÚS ZAVALA ORTIZ

DIRECTOR DE TESIS:

DR. JOSÉ ANTONIO VÁZQUEZ LÓPEZ

CO-DIRECTOR DE TESIS:

M.I.I. PALOMA TERESITA GUTIÉRREZ ROSAS

CELAYA, GTO., MÉXICO, FEBRERO, 2019

Asunto: Autorización de impresión de trabajo profesional.

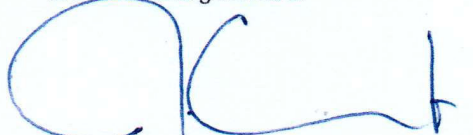
Celaya Gto., **08 de FEBRERO 2019**

M.C. MOISES TAPIA ESQUIVIAS
JEFE DEL DEPARTAMENTO DE INGENIERIA INDUSTRIAL.
Presente.

De acuerdo a la convocatoria hecha por esta jefatura a fin de aprobar o no la impresión del trabajo profesional titulado:

“MINIMIZACIÓN DE LOS ERRORES EN LA FORMULACIÓN DEL COLOR EN LA INDUSTRIA TEXTIL MEDIANTE LA IMPLEMENTACIÓN DE UNA RED NEURONAL ARTIFICIAL”

Presentado por el (a) pasante **C. IBQ. Zavala Ortiz Laura Delia de Jesús (M1703011)** alumno (a) del programa de Maestría en Ingeniería Industrial que ofrece nuestro Instituto.
Hacemos de su conocimiento que éste jurado ha tenido a bien aprobar la impresión de dicho trabajo para los efectos consiguientes.



DR. JOSÉ ANTONIO VAZQUEZ LOPEZ
Presidente



M.C. VICENTE FIGUEROA FERNANDEZ
Vocal

ATENTAMENTE



SECRETARIA DE
EDUCACION PUBLICA
TECNOLÓGICO NACIONAL
DE MEXICO
INSTITUTO TECNOLÓGICO
DE CELAYA
COORDINACION DE MAESTRIA
DE INGENIERIA INDUSTRIAL

M.C. MOISES TAPIA ESQUIVIAS
Secretario



M.C. MANUEL DARIO HERNANDEZ RIPALDA
Vocal Suplente



Ccp. Escolares
Archivo.
VFF*MTE*DMVP



Resumen:

El color es una característica indispensable en la calidad de diversos productos, para poder lograr una apropiada coloración es necesario determinar la correcta proporción de colorantes requeridos para conseguir una exacta coincidencia del color. En 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. Por tal motivo es necesario el desarrollo de nuevas técnicas para generar formulaciones de color más exactas. Las redes neuronales artificiales (RNA) pueden ser entrenadas para imitar la forma de trabajo de los coloristas. Una RNA de retro propagación, permite la minimización del error entre un objetivo y un patrón, generando así recetas de color óptimas.

Abstract:

Color is an indispensable feature in the quality of various products, in order to achieve an appropriate color it is necessary to determine the correct proportion of dyes required to achieve an exact color match. In the textile industry, the development of an appropriate coloration in their products is a standard of indispensable quality, since this one generates a direct impact in the level of liking or rejection of a product. For this reason it is necessary to develop new techniques to generate more exact color formulations. Artificial neural networks (RNAs) can be trained to imitate the way colorists work. An RNA of retro propagation, allows the minimization of the error between a target and a pattern, thus generating optimal color recipes.

ÍNDICE

1	Planteamiento del problema	1
1.1	Introducción	1
1.2	Descripción del problema	1
1.3	Objetivo general.....	3
1.4	Objetivos específicos	3
1.5	Preguntas de investigación.....	4
1.6	Justificación	4
1.7	Hipótesis	5
1.8	Alcances y limitaciones	6
1.9	Resultados esperados	6
2	Marco teórico.....	7
2.1	Color	7
2.1.1	Definición de color	7
2.1.2	Instrumentos de medición del color	8
2.1.3	Factores que inciden en la percepción del color.....	11
2.1.4	Colorantes empleados en la industria textil.....	12
2.1.5	Modelos de color	13
2.1.6	Reproducción del color.....	17
2.2	Redes neuronales artificiales.....	20
2.2.1	Definición	20
2.2.2	Características de las RNAs	21
2.2.3	Estructura básica.....	23
2.2.4	Tipos de RNAs	24
2.2.5	Métodos de entrenamiento.....	26

2.2.6	Redes de retro propagación (Backpropagation)	29
2.3	Algodón	32
2.3.1	Principales características	33
2.3.2	Teñido	33
2.4	Diseño de experimentos	37
2.4.1	Diseño de mezclas	37
2.5	Análisis estadístico de datos	39
2.5.1	Análisis de varianza (ANOVA)	39
2.6	Estado del arte	40
3	Marco metodológico	46
3.1	Etapa 1. Recopilación de información	47
3.1.1	Selección del tipo de fibra a teñir	47
3.1.2	Selección de una RNA	47
3.1.3	Determinación del tipo de colorante a usar	48
3.2	Etapa 2. Desarrollo de la experimentación	48
3.2.1	Generación de muestras	49
3.2.2	Generación de datos colorimétricos	52
3.2.3	Entrenamiento de la red	56
3.3	Etapa 3 Análisis e interpretación de los resultados de la experimentación	58
3.4	Caso de aplicación	58
4	Resultados	61
4.1	Resultados de la etapa 2: Desarrollo de la experimentación	61
4.1.1	Generación de muestras	61
4.1.2	Generación de datos colorimétricos	64
4.1.3	Entrenamiento de la red	76

4.2	Resultados del caso de aplicación.....	91
5	Conclusiones.....	104
6	Anexos.....	106
	Anexo 1. Portada del artículo publicado	106
	Anexo 2. Proceso de producción del caso de aplicación.....	107
	Anexo 2. Tablas ANOVA y Gráficas de los análisis de los casos de estudio.....	108
	ANOVA's y graficas de intervalos para 2 pigmentos	108
	ANOVA's y gráficas para las formulaciones de 3 pigmentos.	118
	Anexo 3: Cálculos del ΔE_{CMC} para ambos casos de estudio	134
7	Bibliografía.....	137

ÍNDICE DE FIGURAS

Figura 2.1:	Esquema de bloques de un espectrofotómetro.....	9
Figura 2.2:	Estructura de un colorímetro.	10
Figura 2.3:	Representación del sistema CIELAB.	14
Figura 2.4:	Neurona biológica.....	22
Figura 2.5:	Tipos de capas en una RNA.....	23
Figura 2.6:	Representación abreviada de una red de una capa.....	24
Figura 2.7:	Representación de una matriz de pesos.	25
Figura 2.8:	Notación abreviada de una red multicapa.....	26
Figura 2.9:	Estructura de una red de retro propagación con una capa oculta.	30
Figura 3.1:	Etapas del método.....	46
Figura 3.2:	Desarrollo de la experimentación	49
Figura 3.3:	Método de tinción de muestras	51
Figura 3.4:	Vectores de color	52
Figura 3.5:	Diagrama para la toma de datos colorimétricos	53
Figura 3.6:	Estructura de una RNA.....	56

Figura 3.7: Proceso de producción de la empresa Carolina performance	60
Figura 4.1: Licores de teñido	61
Figura 4.2: Muestras teñidas	62
Figura 4.3: Gráfica de intervalos para los valores L, a^*, b^*	73
Figura 4.4: Graficas de intervalos para los valores L, a^*, b^* . 3 pigmentos	75
Figura 4.5: RNA de retro propagación con 5 neuronas en la capa oculta.....	76
Figura 4.6: Ventana de entrenamiento MATLAB. 2 pigmentos.....	79
Figura 4.7: Ventana de entrenamiento de MATLAB. 3 pigmentos	81
Figura 4.8: Toma de muestras colorimétricas	91
Figura 4.9: Estructura RNA BP. Caso de aplicación	102
Figura 4.10: Ventana de entrenamiento RNA BP. Caso de aplicación.....	103

ÍNDICE DE TABLAS

Tabla 2.1: Analogía entre la neurona biológica y la neurona artificial	22
Tabla 2.2: Clasificación por la longitud media de la fibra de algodón	33
Tabla 2.3: Tipo de colorante empleado en diversas fibras	35
Tabla 2.4: Revisión del estado del arte.....	41
Tabla 3.1: Propuesta de concentración en mL de pigmento a emplear	50
Tabla 3.2: Propuesta de concentración en mL de los 3 pigmento a emplear	54
Tabla 4.1: N° de muestras por formulación, 2 pigmentos	63
Tabla 4.2: N° de muestras por formulación, 3 pigmentos.....	63
Tabla 4.3: Valores L, a^*, b^* para la formulación 0/12 mL. 2 pigmentos.....	65
Tabla 4.4: Valores L, a^*, b^* para la formulación 0 / 0 / 12 mL. 3 pigmentos	67
Tabla 4.5: ANOVA de los vectores colorimétricos. 2 pigmentos	69
Tabla 4.6: ANOVA de los vectores colorimétricos. 3 pigmentos.....	71
Tabla 4.7: Cantidad de neuronas presentes en cada capa. 2 pigmentos	77
Tabla 4.8: Cantidad de neuronas presentes en cada capa. 3 pigmentos	77
Tabla 4.9: Cantidad de corridas de entrenamiento	80
Tabla 4.10: Cantidad de corridas de entrenamiento. 3 pigmentos	82

Tabla 4.11: Valores R del entrenamiento de la RNA.....	82
Tabla 4.12: Valores R del entrenamiento de la RNA. 3 pigmentos	83
Tabla 4.13: Intervalos de confianza. 2 pigmentos	84
Tabla 4.14: Comparación de formulaciones.....	85
Tabla 4.15: Intervalo de confianza. 3 pigmentos	86
Tabla 4.16: Comparación de formulaciones.....	87
Tabla 4.17: Cálculo del MSE. 2 pigmentos.....	88
Tabla 4.18: Cálculo del MSE. 3 pigmento	89
Tabla 4.19: ΔE_{cmc} para 2 pigmentos.....	90
Tabla 4.20: ΔE_{cmc} para 3 pigmentos.....	90
Tabla 4.21: Resultado de las mediciones de la tela sin teñir	93
Tabla 4.22: Resultados de las mediciones de la tela teñida.....	98

1 Planteamiento del problema

1.1 Introducción

En la actualidad, el color de los 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 como predicción de una receta de color (Almodarresi, Mokhtari, Mohammad Taghi Almodarresi, Nouri, & Shams Nateri, 2013) (Furferi & Carfagni, 2010).

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 este genera un impacto directo en el nivel de agrado o rechazo de un producto (Mangine, Jakes, & Noel, 2005).

A pesar de los recientes desarrollos tecnológicos para la evaluación de las diferencias de coloración en la industria, estas aún se resisten a basar la decisión de elección del color completamente en la medida de diversos instrumentos que evalúan dicha diferencia. La valoración del color en la industria textil aun depende, en gran medida, de la evaluación visual del producto. Esta evaluación es altamente subjetiva, debido a que la percepción del color se ve afectada por diversos factores como pueden ser: el tipo de fuente de luz, la inclinación de la fuente luminaria, el instrumento de medición empleado, el entrenamiento del evaluador, el ángulo de observación, la distancia en la que se realiza la observación y el tipo de colorante empleado; estos son algunos de los factores que inciden en mayor grado en la percepción adecuada del color (Mangine, Jakes, & Noel, 2005) (Li, Wang, & Jing, 2015).

1.2 Descripción del problema

Actualmente el color ha sido reconocido como una característica de calidad importante para diversos productos; esta característica es usada como un medio para juzgar la calidad de un

producto individualmente en una cadena productiva, en las etapas de producción, almacenamiento y comercialización. En la industria textil esto es un factor crítico ya que se busca la reproducción de determinados patrones de color, los cuales afectan el grado de aceptación o rechazo de un determinado producto (Rautenberg & Todesco, 2006).

La evaluación de la percepción del color en la industria textil es un proceso que depende de la apreciación visual del producto; esta es altamente subjetiva, debido a que la percepción del color se ve afectada por factores físicos como: el tipo de fuente de luz, la inclinación de la fuente luminaria, el instrumento de medición empleado, el entrenamiento del evaluador, el ángulo de observación, la distancia en la que se realiza la observación; y factores químicos, donde el más relevante es el tipo de colorante empleado en la fibra a teñir. Así mismo este proceso se basa en el uso de las experiencias previas en las mezclas de colores obtenidos. Tanto los factores físicos como los químicos inciden en el grado de la percepción adecuada del color (Rautenberg & Todesco, 2006).

A causa de estos factores, los procesos empleados en la producción de recetas de color generan resultados insatisfactorios, con un elevado número de pérdidas, así como un aumento en la cantidad de desperdicios de materia prima, rechazos del producto final y un incremento en el costo final del producto (Mangine, Jakes, & Noel, 2005).

Para evitar las variaciones en la percepción del color se han empleado diferentes técnicas y herramientas que permitan generar una evaluación más acertada. La teoría de Kubelka Munk ha sido empleada de manera recurrente con el fin de obtener predicciones en la formulación de las recetas de color, esta teoría mide la reflectancia de un color en base a la proporción de los grados de absorción y dispersión de una concentración de color en una mezcla (Furferi & Carfagni, 2010).

Una vez generada la receta de color es necesario comparar el color obtenido con el deseado, para ello se emplean diversos instrumentos de medición; uno de los instrumentos más empleados en el sector industrial es el espectrofotómetro, el cual mide la reflectancia o transmitancia a través de materiales como una función de la longitud de onda del espectro visible (Kandi, Armeri, & Khalili, 2012).

A pesar del uso recurrente de la teoría de Kubelka Munk y el espectrofotómetro en la industria textil, ambos presentan limitaciones en su implementación. La teoría de Kubelka Munk se ve limitada ya que ésta solo permite evaluar una determinada clase de colorantes sin generar errores en la medición realizada. El espectrofotómetro es un aparato de medición preciso, el cual se emplea cuando se requiere obtener coordenadas cromáticas más exactas, permite obtener mediciones con un error mínimo; la desventaja de este aparato es su alto costo de adquisición y mantenimiento (Furferi & Carfagni, 2010) (Gorji Kandi, Ameri, & Khalili, 2012).

Actualmente se han desarrollado diversos métodos para la evaluación de la reproducción de un color.

Con esta investigación se pretende implementar una red neuronal artificial de retro propagación que permita producir recetas de color de una manera más eficaz, que brinden resultados más exactos y precisos. Para la evaluación del color obtenido por la red neuronal se empleará un colorímetro, el cual es un instrumento de medición de color de bajo costo.

1.3 Objetivo general

- Minimizar los errores en la formulación del color en la industria textil mediante la implementación de una red neuronal artificial

1.4 Objetivos específicos

- Seleccionar una red neuronal artificial adecuada para generar formulaciones de color en textiles
- Generar los datos colorimétricos de la formulación del color para entrenar una red neuronal artificial
- Entrenar una red neuronal que sea capaz de generar una formulación adecuada de color que minimice los errores de la igualación del color

- Validar el funcionamiento adecuado de la red neuronal artificial seleccionada, mediante la generación de una formulación adecuada de color

1.5 Preguntas de investigación

¿Cuál será la estructura adecuada para la RNA de retro propagación que permita minimizar el error en la formulación del color?

¿Cuál será la cantidad adecuada de datos a emplear en el entrenamiento y validación del funcionamiento de la red?

¿Qué nivel de error tendrá una formulación del color al emplear la RNA de retro propagación para su elaboración?

¿Qué nivel de confiabilidad tendrá la receta de color obtenida por medio de la RNA de retro propagación?

¿Qué impacto generará el aumento en el número de colorantes en la estructura de la red a considerar?

1.6 Justificación

La evaluación del color es un estándar de calidad de suma importancia, el cual incide en el nivel de agrado o rechazo de diversos productos en el sector industrial. Actualmente se han desarrollado diversos métodos para el análisis de la percepción del color. En estos se han empleado técnicas y herramientas de inteligencia artificial, como son las redes neuronales artificiales (Li, Wang, & Jing, 2015).

En la industria automotriz se han empleado sistemas ópticos dirigidos por redes neuronales artificiales; en esta industria se ha probado que por medio de sistemas ópticos es posible verificar y controlar la percepción del color de una manera adecuada; dentro de la industria cosmética, se han desarrollado sistemas de visión artificial que emplean redes neuronales

artificiales con la finalidad de desarrollar una herramienta de medición de color, la cual sea eficaz y eficiente con respecto a los dispositivos actualmente empleados (Gutiérrez-Rosas, Vázquez-López, Yáñez Mendiola, & López-Juárez, 2015)

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 apropiadas. Este proceso consiste en encontrar la coincidencia de color mezclando diversos colorantes en una proporción adecuada (Furferi & Carfagni, 2010) (Almodarresi, Mokhtari, Mohammad Taghi Almodarresi, Nouri, & Shams Nateri, 2013).

Una vez obtenida la receta de color, se emplean diferentes técnicas e instrumentos para evaluar la percepción del color obtenido; la técnica más empleada es la teoría de Kubelka Munk y el espectrofotómetro. La teoría de Kubelka Munk se ve limitada por el tipo de colorantes empleados, ya que actualmente para el teñido de algodón se emplean colorantes reactivos, los cuales, al ser evaluados por esta teoría se generan errores en la medición obtenida. A pesar de que el espectrofotómetro es un instrumento de medición que genera errores mínimos, su elevado costo ocasiona que empresas pequeñas no puedan acceder a él (Gorji Kandi, Ameri, & Khalili, 2012).

Por tal motivo es necesario desarrollar e implementar métodos alternativos que permitan generar y evaluar recetas de color de una manera más óptima y a un menor costo.

1.7 Hipótesis

Si se implementa una red neuronal artificial en la formulación del color en la industria textil entonces será posible minimizar los errores de igualación del color en textiles mediante la obtención de una receta adecuada de color.

1.8 Alcances y limitaciones

El alcance de esta investigación abarca desde la formulación de diversas recetas de color para teñir algodón y generar los datos necesarios evaluados por medio de un colorímetro para entrenar una red neuronal artificial, se implementarán las formulaciones obtenidas por la red en las telas de algodón y se medirá el grado de precisión obtenido con el colorímetro. La implementación de la red se puede ver afectada por errores en los datos de medición obtenidos.

1.9 Resultados esperados

El resultado esperado de esta investigación es probar si es viable la implementación de una RNA de retro propagación para el desarrollo de recetas óptimas de color para la industria textil. De manera de que si es viable se identifique una receta óptima para el teñido de algodón evaluada por medio de un colorímetro.

2 Marco teórico

A continuación, se describirán los conceptos necesarios para el presente trabajo, estos tendrán como objetivo brindar el conocimiento requerido para el desarrollo del mismo.

2.1 Color

2.1.1 Definición de color

Según Martínez & Celemín V (2012), el color es un fenómeno físico de percepción visual que está relacionado con las diferentes longitudes de onda en la zona visible del espectro electromagnético; el color es una consecuencia de la combinación de 3 factores, los cuales son: la luz reflejada y transmitida, el objeto observado y el observador.

El color es el resultado de la interacción de la fuente de luz, un objeto y de los ojos y cerebro del observador (sistema visual). La percepción de un color se ve afectada por factores físicos y químicos que hacen variar la intensidad del color o su claridad. El color de un objeto iluminado de manera uniforme puede ser descrito por su luminosidad, croma y su matiz (Berns, 2000).

Al observar un objeto es posible determinar sus características de color por medio de la luz reflejada, este término incluye: la identificación del objeto y su material, la geometría y textura de la superficie. Estas características son de suma importancia en el diseño y la planificación en relación con varios productos; la relación entre la estructura geométrica de la superficie de un objeto y la luz reflejada son parámetros importantes para determinar la intensidad y características de un color (Lee & Sato, 2001).

2.1.2 Instrumentos de medición del color

En la actualidad se han desarrollado diversos instrumentos de medición que permiten determinar la diferencia de color en diversos materiales; los más empleados en la rama industrial son el colorímetro y el espectrofotómetro. Ambos instrumentos pueden determinar el color de una muestra. Sin embargo, es normal que el color de un mismo objeto medido con ambos aparatos genere resultados distintos, siendo más fiable los resultados obtenidos a través de un espectrofotómetro (Artigas, 2002).

2.1.2.1 Espectrofotómetro

El espectrofotómetro es un instrumento que mide la reflectancia o transmitancia a través de materiales como una función de la longitud de onda del espectro visible, la cual está en un rango de 380 a 780 nm. Algunos componentes del espectrofotómetro son: la fuente de radiación óptica, un sistema óptico para definir las condiciones geométricas de medición, algunos medios de dispersión de luz, un detector y un sistema de procesamiento de señales que convierten la luz en señales adecuadas para el análisis (Berns, 2000).

En la Figura 2.1 se muestra la estructura básica de un espectrofotómetro; es importante distinguir entre los espectrofotómetros de haz simple y haz doble de luz; las fuentes de luz más comunes en el espectrofotómetro, tanto en haz simple como en haz doble son las lámparas de halógeno-cuarzo, en el caso del haz de luz doble la segunda fuente de luz es de deuterio y tungsteno, el cual genera una fuente de luz similar a la fuente de UV. El monocromador permite una variación continua al elegir la longitud de onda y hacer un barrido en una zona amplia de longitud de onda; luego del monocromador la luz incide sobre la muestra, la intensidad de la luz transmitida se mide con un detector que convierte el número de fotones que inciden sobre él durante un intervalo de tiempo en una señal eléctrica (Olsen, 2003) (Aldabe, Bonazzola, Aramendía, & Lacreu, 2004) .




Figura 2.1: Esquema de bloques de un espectrofotómetro.

Diversas propiedades físicas del material a analizar influyen en la detección de las pequeñas variaciones de color medidas en el espectrofotómetro, estos factores son la transmitancia, reflectancia y el factor reflectante. La fuente de luz en un espectrofotómetro debe ser idéntica a la luz del entorno de visualización (Berns, 2000).

2.1.2.2 Colorímetro

Es un instrumento de medición de color muy simple que compara, emulando el uso del ojo humano como un detector, el color a investigar con el de un patrón, este aparato emplea las coordenadas colorimétricas del espacio CIE, mediante los valores de los triestímulos de la fuente de luz. En otras palabras, un sistema detector responde a la luz incidente de manera similar a la del estándar observado; un sistema detector normalmente consiste en un filtro de vidrio y un foto detector, usualmente de silicón (Berns, 2000).

Hay dos clases de colorímetros, los diseñados para medir fuentes y los diseñados para medir materiales; cuando se miden materiales, el colorímetro está diseñado para simular un iluminante CIE tipo C o D65, actualmente el diseño más empleado es la geometría 45/0. Cuando se miden fuentes, se utilizan geometrías estandarizadas para fotometría (Berns, 2000).

Todo colorímetro se compone de tres partes fundamentales:

- Un sistema de iluminación (iluminante): fuente de luz sobre la muestra.
- Un sistema de captación: formado por filtros que captan las señales de color.

- Un sistema procesador: convierte las señales recibidas en valores numéricos que permite etiquetar la muestra según los valores del espacio CIELAB (Artigas, Capilla, & Pujol Ramo, 2002).

El sistema de captación de un colorímetro, normalmente consta de un filtro y un foto detector, generalmente un fotodiodo de silicio; la sensibilidad espectral del detector permite el cálculo de las características de transmitancia del filtro. En la Figura 2.2 se muestra la estructura básica de un colorímetro de 3 filtros, el cual fue diseñado para que coincida con el pico de longitud de onda larga correspondiente a la región de los tonos rojizos- verdosos y amarillos- azulosos.




Figura 2.2: Estructura de un colorímetro.

En un colorímetro el iluminante y las funciones de igualación de color, se tratan de imitar mediante filtros o plantillas; el iluminante empleado para iluminar la muestra con la distribución espectral adecuada, las funciones de igualación de color para modificar la respuesta espectral de la fotocélula, para obtener directamente los valores triestímulos. Esta imitación no es perfecta, por lo que los resultados obtenidos suelen discrepar de los de un espectrofotómetro (Artigas, 2002).

2.1.3 Factores que inciden en la percepción del color

El color de un producto es un factor de suma importancia, ya que este afecta el grado de aceptación o rechazo de un artículo determinado. Dentro de la industria se realizan análisis de calidad para este punto. Para que este tipo de evaluaciones sean lo más acertadas, es indispensable controlar los diversos factores naturales o artificiales que puedan llegar a afectarlos (Artigas, Capilla, & Pujol, 2002).

2.1.3.1 Naturales

Según Berns (2000), al realizar la evaluación del color en diversos productos algunos factores ambientales que se deben cuidar para minimizar el riesgo de error en la medición son:

- La fuente de luz (°K) y la intensidad (lux) en la superficie del producto: algunos autores recomiendan una intensidad de luz entre 750 y 1200 lux y la fuente de luz debe elegirse para tener un alto índice de reproducción cromática (Ra)
- Ángulo de incidencia de la luz sobre la muestra y ángulo de visión del panelista: la iluminación del área debe ubicarse verticalmente a la muestra y el ángulo de visión de los panelistas sentados debe ser aproximadamente a 45° de la muestra; es importante cuidar que el ángulo de la luz y el de visión no sean iguales, ya que de lo contrario se podría generar la reflexión de la luz y un alto brillo, lo que daría origen a errores de medición
- Color de fondo en el área de visualización: el color de fondo no debe ser reflectante y neutral, por lo general se emplean colores en la tonalidad gris mate, crema o blanquecino

2.1.3.2 Artificiales

Dentro de los factores artificiales que pueden llegar a afectar la percepción del color podemos encontrar

- Iluminante: Luz definida por una distribución de potencia espectral relativa que puede o no ser físicamente realizable como una fuente
- Efecto de un iluminante en la apariencia de color de los objetos mediante la comparación consciente o subconsciente con su aspecto de color bajo un iluminante de reflectancia
- Tipo de fuente: Efecto de un iluminante en la apariencia de color de los objetos mediante la comparación consciente o subconsciente con su aspecto de color bajo un iluminante de reflectancia (Artigas, 2002).

2.1.4 Colorantes empleados en la industria textil

Anteriormente, la mayoría de colorantes empleados en el sector industrial eran de origen natural, es decir, eran obtenidos de manera directa de diversos pigmentos; actualmente, se han desarrollado nuevos colores que requieren de diferentes tratamientos para su síntesis. Los colorantes pueden clasificarse como naturales o artificiales (Artigas, 2002).

2.1.4.1 Naturales

Los colorantes naturales pueden clasificarse como orgánicos o inorgánicos (colorantes artificiales). En el grupo de colorantes naturales orgánicos encontramos:

- Vegetales: en este grupo se encuentran los pigmentos, los más comunes son las antocianinas, flavonoides, carotenoides y la clorofila

- Animales: en este grupo se pueden observar al ácido carmínico, kermésico entre otros (Lockuán, 2012).

2.1.4.2 Artificiales

Este tipo de colorantes también son conocidos como colorantes sintéticos, debido a que se requieren diversos tratamientos para obtenerlos (Lockuán, 2012).

Actualmente en el proceso de teñido de la industria textil se emplean colorantes de acabado rápido; este tipo de colorantes permiten minimizar el tiempo de teñido comparado con el proceso tradicional, así mismo reduce el costo y energía empleados en este proceso; sin embargo se requiere mucha atención en sus parámetros de estudio para obtener un óptimo resultado (Jeyaraj, Muralidharan, Senthilvelan, & Deshmunkh, 2013).

2.1.5 Modelos de color

Los modelos de color son definidos por la CIE (*Comission Internationale de l'Eclairage*), el cual define diferentes espacios de color mediante un sistema para la especificación de los estímulos cromáticos utilizando los valores triestímulos de tres colores primarios imaginarios y un observador estándar de color; entre los espacios de color definidos por la CIE se encuentra CIE94, CIELAB, CIELUV (Berns, 2000).

2.1.5.1 CIELAB

Definición

Es un espacio de color que correlaciona la luminosidad, tonicidad y el croma de un color, recomendado para diferencias de color largas. Este espacio de color emplea coordenadas opuestas, este concepto se basa en el uso de un sistema de coordenadas rectangulares que

emplea las variables L^* , a^* y b^* , que representan la luminosidad, el rango de escala de colores rojizos- verdosos y amarillos- azulosos respectivamente. Estas coordenadas son adimensionales (Berns, 2000).

Las coordenadas L^* , a^* , b^* , mostradas en la Figura 2.3, definen el espacio de color tridimensional de CIELAB; por lo tanto, si las coordenadas son conocidas, entonces no solo es posible describir el color, sino que también se puede definir su ubicación en el espacio. El espacio de color CIELAB describe las diferencias de color definidas como la distancia entre la ubicación del color en cualquier espacio CIE (Pérez-Alvarez, Fernández-López, & Rosmini, 2004).




Figura 2.3: Representación del sistema CIELAB.

El espacio CIELAB es recomendado siempre que se desee una separación tridimensional perceptualmente más uniforme que la proporcionada por el sistema X, Y, Z . Mediante las diferencias de color en CIELAB se correlacionan las diferencias visuales en todas partes a través del espacio tridimensional (Berns, 2000).

Modo de empleo

CIELAB permite determinar las diferencias entre las muestras de color producidas y los estándares de cada una; las muestras producidas tienen que ser apropiadas para la medición

del color, midiendo las muestras y el promedio de cada una. Debido a que CIELAB es un sistema de coordenadas rectangulares, es posible describir las diferencias de luminosidad, ΔL^* (2.1); diferencia de escalas rojizo- verdoso, Δa^* (2.2); amarillo- azulado, Δb^* (2.3); mediante las siguientes ecuaciones:

$$\Delta L^* = L_{batch}^* - L_{standar}^* \quad (2.1)$$

$$\Delta a^* = a_{batch}^* - a_{standar}^* \quad (2.2)$$

$$\Delta b^* = b_{batch}^* - b_{standar}^* \quad (2.3)$$

En este espacio colorimétrico la diferencia de color entre dos muestras es determinada por la ecuación número 2.4.

$$\Delta E_{ab}^* = \left[(\Delta L^*)^2 + (\Delta a^*)^2 + (\Delta b^*)^2 \right]^{1/2} \quad (2.4)$$

Esta diferencia indica la distancia entre el color obtenido y el patrón deseado en el espacio de color CIELAB (Berns, 2000).

En 1984 el “comité de la medición del color” (por sus siglas en ingles CMC), propuso la fórmula para la diferencia del color CMC ($k_l : k_c$) (2.5), la cual se conoce como estándar internacional de la industria textil (ISO105-J03) (Berns, 2000).

$$\Delta E_{CMC} = \left[\left(\frac{\Delta L^*}{k_l S_L} \right)^2 + \left(\frac{\Delta C^*}{k_c S_C} \right)^2 + \left(\frac{\Delta H^*}{S_H} \right)^2 \right]^{1/2} \quad (2.5)$$

Donde las variables de la ecuación se determinan por medio de:

$$\Delta C^* = C_{batch}^* - C_{s\ tan\ dar}^* = (a_{batch}^{*2} + b_{batch}^{*2})^{1/2} - (a_{s\ tan\ dar}^{*2} - b_{s\ tan\ dar}^{*2})^{1/2} \quad (2.6)$$

$$\Delta H^* = \left[(\Delta E_{ab}^*)^2 - (\Delta L^*)^2 - (\Delta C^*)^2 \right]^{1/2} \quad (2.7)$$

$$S_L = 0.511 \quad (2.8)$$

$$S_C = \left[\frac{0.0638C^*}{(0.0131C^*)} \right] + 0.638 \quad (2.9)$$

$$C^* = (a^{*2} - b^{*2})^{1/2} \quad (2.10)$$

$$S_H = S_C(TF + 1 - F) \quad (2.11)$$

$$F = \left\{ \frac{(C^*)^4}{[(C^*)^4 + 1900]} \right\}^{1/2} \quad (2.12)$$

$$T = 0.38 + |0.2 \cos(h + 168)| \quad (2.13)$$

Los factores k_l y k_c son coeficientes para ajustar la luminosidad y croma. Para predecir el color de la tela dentro de un rango aceptable, las investigaciones han encontrado que funciona bien cuando $k_l = 2$ y $k_c = 1$, mientras que si se requiere predecir si el textil es perceptible en un gama de color específico $k_l = k_c = 1$ (Berns, 2000).

2.1.6 Reproducción del color

Los colores percibidos por medio del ojo humano se encuentran dentro del espectro de luz visible, el cual se encuentra en un rango de 380 a 780 nm. En este rango la sensibilidad fotópica se divide en tres bandas espectrales, en las que interaccionan diversos foto receptores; la banda de luz roja (R) es la zona de acción de los foto receptores L o ρ , en la banda de luz verde (G) actúan los foto receptores M o γ , en la banda azul (B) actúan los foto receptores S o β (Artigas, 2002) (Berns, 2000).

Artiga (2002) señala que estos valores representan la integración o captura de los fotones incidentes sobre tres filtros de banda ancha RGB. En un sistema visual se puede considerar como un sistema aditivo que integra sobre tres canales espectrales la luz visible que incide sobre la córnea.

En la actualidad poder igualar colores a los de un patrón establecido es un factor de suma importancia en el sector industrial, por tal motivo se han desarrollado diversas técnicas para conseguir este fin; estas se denominan como técnicas de reproducción del color, de las cuales el objetivo principal es controlar la terna de luces RGB de la copia conseguida mediante procedimientos aditivos o sustractivos para que se asemejen lo mejor posible a los valores originales RGB de la referencia. La evaluación de la reproducción del color depende estrechamente de la opinión del observador o del experto colorista para la aprobación final, así como de la aplicación de diversos instrumentos que permiten ver las variaciones entre una muestra y el patrón. Dentro de las diversas teorías desarrolladas para la reproducción del color, encontramos para la industria textil, la técnica de Kubelka Munk (Artigas, 2002).

2.1.6.1 Técnica Kubelka- Munk

Definición

Un material puede ser considerado turbido si la intensidad de un haz de luz que lo atraviesa se ve considerablemente reducida. La teoría Kubelka- Munk permite tratar la óptica de este tipo de materiales partiendo de un modelo simplificado que trata el paso de la luz a través del

material. Las condiciones de partida son las siguientes: se supone un medio turbido formado por una capa de espesor constante y finito. Supone que el material es homogéneo y que el medio en el que se sumerge la muestra es el mismo que aquel de donde proviene la luz. Solo se ilumina un lado de la muestra (Artigas, Capilla, & Pujol, 2002).

La técnica Kubelka- Munk considera una capa de colorante translúcida encima de un fondo opaco, dentro de la capa de colorante, tanto la absorción como la dispersión se producen. La teoría Kubelka- Munk asume que el flujo de luz dentro de una capa de absorción y dispersión translúcida viaja hacia abajo, arriba o perpendicular al plano de la muestra. Debido a que la luz se supone un sistema difuso sin una dirección preferente, la teoría Kubelka- Munk no se aplica a los colorantes metálicos y perlados o fluorescentes, así como a capas de colorante que cambian significativamente el grado de polarización de la luz incidente (Artigas, Capilla, & Pujol, 2002) (Berns, 2000).

La teoría Kubelka Munk es empleada para desarrollar leyes de mezcla para tres tipos de muestras, la primera es para plástico translúcido, tintas de impresión con dispersión apreciable y para pintar las películas que no se ocultan completamente. El segundo tipo de muestras es una en el cual una capa transparente de colorante está en contacto con una capa opaca (dispersión difusa de apoyo), papel fotográfico y en las denominadas impresiones de tono continuo que utilizan tecnologías de transferencia térmica son ejemplos de este segundo tipo. El tercer tipo de muestra son materiales opacos con absorción y dispersión como textiles películas de pintura y plásticos con capa oculta y papel teñido (Berns, 2000).

Para materiales opacos Kubelka Munk encontró que la reflectancia interna, $R_{\lambda,i}$ depende de la absorción, K_{λ} y de la dispersión S_{λ} , esta relación se detalla en la ecuación 2.14.

$$\left(\frac{K}{S}\right)_{\lambda} = \frac{(1-R_{\lambda,i})^2}{2R_{\lambda,i}} \quad (2.14)$$

Donde R es el factor de reflectancia en la superficie para una muestra de espesor infinito, K y S son los coeficientes de absorción y dispersión de la muestra (Kandi, Armeri, & Khalili, 2012)

En la ecuación anterior se pueden apreciar dos constantes, al emplear esta ecuación se debe tener en cuenta que la reflectancia está en una escala entre cero y uno, no como un porcentaje; K y S solo aparecen como proporción (Berns, 2000).

Según Berns (2000), los productos textiles son materiales en los cuales el color no se dispersa en comparación con el sustrato. La ecuación de la mezcla de colorantes se simplifica de modo que solo es necesario conocer la relación entre la absorción y dispersión de la mezcla. Esto se basa en la teoría de Kubelka Munk de una constante, la cual indica que hay una relación lineal entre los coeficientes de absorción y dispersión $\left(\frac{K}{S}\right)$ de cada colorante y su concentración. En la ecuación 2.15, para la teoría de Kubelka Munk de una constante con n colorantes es expresada como:

$$\left(\frac{K}{S}\right)_{\lambda,mix} = c_1\left(\frac{K}{S}\right)_{\lambda,1} + c_2\left(\frac{K}{S}\right)_{\lambda,2} + c_3\left(\frac{K}{S}\right)_{\lambda,3} + \dots + c_n\left(\frac{K}{S}\right)_{\lambda,n} \quad (2.15)$$

Donde c_n representa las diversas concentraciones de colorante empleado (Berns, 2000) (Kandi, Armeri, & Khalili, 2012).

Concentración de color

Para poder obtener una apropiada percepción del color, uno de los factores más importantes es la concentración del colorante empleado; una adecuada concentración de color proporciona que el color de la muestra coincida con el patrón deseado (Berns, 2000).

Dentro de la percepción del color se tienen que diferenciar entre la concentración teórica; la cual es la concentración medida por un usuario tal como la concentración de un colorante en un baño de tinte. Esto es equivalente a los controles de usuario de un modelo de color genérico; y la concentración efectiva u óptima, la cual se define como la concentración determinada a partir de las mediciones de colorantes del material coloreado. Esto es equivalente al escalar de un modelo de color genérico (Berns, 2000) (Kandi, Armeri, & Khalili, 2012).

2.2 Redes neuronales artificiales

2.2.1 Definición

Las redes neuronales artificiales (RNA) son sistemas procesadores de información que tiene ciertas características de rendimiento en común con una red neuronal biológica. Las redes neuronales artificiales se han desarrollado como generalizaciones de modelos matemáticos de la cognición humana o de una neurona biológica, basándose en la suposición de que:

- a) El procesamiento de información ocurre en muchos elementos simples llamados neuronas.
- b) Las señales se pasan entre las neuronas sobre enlaces de conexión.
- c) Cada enlace de conexión tiene un peso asociado, que en una red neuronal típica multiplica la señal transmitida.

Cada neurona aplica una función de activación (usualmente no lineal) a su entrada neta (suma de los pesos de las señales de entrada) para determinar su señal de salida (Fausett, 1993).

Una red neuronal es un procesador paralelo distribuido masivamente, compuesto de unidades de procesamiento simples que tiene una propensión natural para almacenar conocimiento y ponerlo disponible para su uso. Las principales semejanzas entre las redes neuronales y el cerebro humano son:

- El conocimiento es adquirido por la red del entorno a través de un proceso de aprendizaje.
- Los pesos sinápticos, se emplean para almacenar el conocimiento (Haykin, 2016).

Las redes neuronales artificiales (RNAs) tratan de emular el comportamiento del cerebro humano caracterizado por el aprendizaje a través de la experiencia y la extracción de conocimiento genérico a partir de un conjunto de datos. Los sistemas de RNAs simulan esquemáticamente la estructura del cerebro mediante la simulación. Una RNA genera aprendizaje a través de las experiencias generalizadas de ejemplos previos a ejemplos nuevos y abstraen las características principales de una serie de datos. (Flórez & Fernández, 2008).

2.2.2 Características de las RNAs

Las neuronas biológicas constan de tres componentes principales, las dendritas, el cuerpo de la célula o soma y el axón. En la Figura 2.4 se muestra la estructura de una neurona biológica. Las dendritas, son los receptores de la red; son fibras nerviosas que cargan de señales eléctricas el cuerpo de la célula. El soma realiza la suma de las señales de entrada. El axón, es una fibra larga que lleva la señal desde el cuerpo de la célula hacia otras neuronas. El punto de contacto entre un axón de una célula y una dendrita de otra es llamado sinapsis, la longitud de esta es determinada por la complejidad del proceso químico que estabiliza la función de la red neuronal (Hagan, Demuth, & Beale, 2016).

Existen dos tipos de sinapsis: la sinapsis excitadora, cuyos neurotransmisores provocan disminuciones de potencial en la membrana de la célula, facilitando la generación de impulsos a mayor velocidad y la sinapsis inhibidora, cuyos neurotransmisores tienden a estabilizar el potencial de la membrana, dificultando la emisión del impulso (Haykin, 2016).

Una red neuronal artificial, está caracterizada por:

- a) Su patrón de conexión entre las neuronas (llamado arquitectura de la neurona).

- b) Su método de determinación de pesos en la conexión (llamado entrenamiento, aprendizaje o algoritmo).
- c) Su función de activación.




Figura 2.4: Neurona biológica.

En la Tabla 2.1 se muestra una analogía directa entre las principales actividades sinápticas biológicas y las redes neuronales artificiales.

Tabla 2.1: Analogía entre la neurona biológica y la neurona artificial

Neurona biológica	Neurona artificial
Señal que llega a la sinapsis	Entradas a la neurona
Carácter excitador o inhibitorio de la sinapsis de entrada	Pesos de entrada
Estímulo total de la neurona	$Net = \sum W_i X_i$
Activación o no de la neurona	Función de activación
Respuesta de la neurona	Función de salida

La matriz de pesos representa la intensidad de la sinapsis que conecta dos neuronas. Cuando las señales de entrada son variables continuas, cada una de ellas pasa a través de un peso, llamado peso sináptico o fortaleza de la conexión. Los pesos de una RNA pueden ser

positivos o negativos (Flórez & Fernández, 2008). Más adelante se señalarán las características de una matriz de pesos.

2.2.3 Estructura básica

Una RNA consta de diversos elementos básicos, los cuales son el elemento procesador (PE), el peso, el impulso y la señal de salida de la neurona. Para definir totalmente una red neuronal se debe especificar el nivel de interconexión entre cada uno de sus componentes (neuronas).

Pino & Gómez (2001) señala que las neuronas se agrupan en capas, cada una de ellas consta de número variable de neuronas con comportamiento similar. En la Figura 2.5 se muestra la estructura de las capas dentro de una RNA. Cada capa está conectada a la inmediata posterior total o parcialmente, excepto la última capa, que constituye la salida total de la red neuronal. Existen tres tipos de capas:

- 1) Capa de entrada.
- 2) Capas intermedias (también conocidas como capas ocultas).
- 3) Capas de salida




Figura 2.5: Tipos de capas en una RNA.

2.2.4 Tipos de RNAs

2.2.4.1 RNAs de una capa

Las RNAs de una sola capa, tiene solo una capa de pesos de conexión. Las unidades de esta red pueden ser distinguidas como unidades de entrada; que reciben las señales del mundo exterior; unidades de salida; desde la que se puede leer la respuesta de la red. En una red de una sola capa, el peso de una unidad de salida no influye en los pesos de otras unidades de salida (Fausett, 1993).

La capa incluye la matriz de pesos, la suma, el vector de sesgo b , la caja de función de transferencia y el vector de salida a . Cada elemento del vector de entrada p es conectado a cada neurona a través de la matriz de pesos W . Cada neurona tiene un sesgo b_i , una suma, una función de transferencia f y una salida a_i . Todas las salidas juntas forman el vector de salida a . En la Figura 2.6 se presenta la notación abreviada para una red de una capa con S -neuronas y R -entradas (Hagan, Demuth, & Beale, 2016).

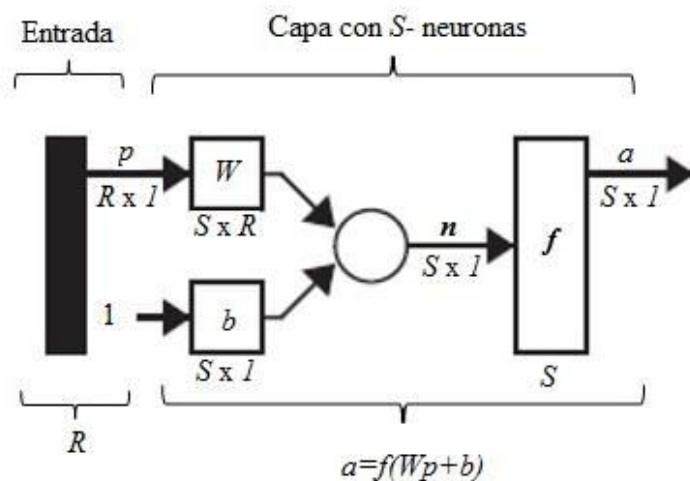


Figura 2.6: Representación abreviada de una red de una capa.

Como se ha mencionado los elementos del vector de entrada entran en la red a través de una matriz de pesos W .

$$W = \begin{bmatrix} w_{11} & w_{11} \cdots & w_{1R} \\ w_{21} & w_{22} \cdots & w_{2R} \\ \vdots & \vdots & \vdots \\ w_{S1} & w_{S2} \cdots & w_{SR} \end{bmatrix}$$

Figura 2.7: Representación de una matriz de pesos.

En la Figura 2.7 se muestra una matriz de pesos para una red neuronal artificial. En la cual, los índices de fila de los elementos de la matriz W indican la neurona de destino asociada con ese peso, mientras que la columna indica la fuente de la entrada para el peso.

2.2.4.2 RNAs multicapa

Esta segunda clase de redes, se distinguen por la presencia de una o más capas ocultas; se les denomina como capas ocultas a aquellas que no son visibles desde cualquier entrada o salida de la red. En la Figura 2.8 se muestra la estructura de una red multicapa. La función de las capas ocultas es intervenir entre las entradas externas y las salidas de la red de una manera útil. Para adicionar una o más capas ocultas la red adquiere una perspectiva global a pesar de su conectividad local, debido al conjunto extra de conexiones sinápticas y la dimensión extra de las interacciones neuronales (Haykin, 2016).

Otros elementos en este tipo de redes son las unidades de entrada y salida, la capa de pesos entre dos niveles adyacentes de unidades (unidades de entrada, salida u ocultas) (Fausett, 1993).

Las redes multicapa son más poderosas que las redes de una sola capa por lo que son capaces de solucionar problemas más complicados), pero su entrenamiento puede ser más complejo. La manera de representar una red con varias capas, cada una con su propia matriz de pesos, vector de sesgo, una red de vector de entrada y salida.




Figura 2.8: Notación abreviada de una red multicapa.

2.2.5 Métodos de entrenamiento

En una red neuronal los datos de entrada se procesan a través de la misma con el propósito de lograr una salida. Las redes neuronales extraen generalizaciones desde un conjunto de ejemplos anteriores de un problema en particular y calculan la salida correcta para cada caso. Este proceso de aprendizaje se denomina proceso de entrenamiento o acondicionamiento (Flórez & Fernández, 2008).

Para que el proceso de aprendizaje pueda ser llevado a cabo, se requieren de un conjunto de datos, los cuales se denominan datos de entrenamiento. Dentro de los procesos de aprendizaje se pueden distinguir dos métodos; el aprendizaje supervisado y el no supervisado (Fausett, 1993).

2.2.5.1 Supervisado

Este método de aprendizaje se caracteriza porque se realiza mediante un entrenamiento controlado por un agente externo, el cual determina la respuesta que debería generar la red a partir de una entrada determinada. El entrenamiento se lleva a cabo presentando una secuencia de vectores de entrenamiento, cada uno con un vector de salida asociado y los pesos son ajustados de acuerdo con el algoritmo de aprendizaje (Fausett, 1993).

Los algoritmos supervisados son utilizados para el entrenamiento de varias redes uni-capas que fueron diseñadas o usadas para la clasificación de patrones; las redes multicapa son entrenadas por backpropagation (retro propagación) (Fausett, 1993).

El aprendizaje supervisado se puede realizar de 3 diferentes formas, las cuales son:

- a) Aprendizaje por corrección de error.
- b) Aprendizaje por refuerzo.
- c) Aprendizaje estocástico.

Aprendizaje por refuerzo

Este método de aprendizaje se basa en la idea de no disponer de un ejemplo completo del comportamiento deseado, en otras palabras, durante el entrenamiento no se indica exactamente cuál es la salida que se desea que proporcione la red ante una determinada entrada.

En este método de aprendizaje la función del supervisor se reduce a indicar mediante señales de refuerzo si la salida de la red se ajusta a la deseada, en donde éxito = 1 o fracaso = -1; en función de esto los pesos son ajustados basándose en mecanismos de probabilidades (Fausett, 1993).

Aprendizaje estocástico

Consiste en realizar cambios aleatorios en los valores de los pesos de las conexiones de la red y evaluar su efecto a partir del objetivo deseado y de distribuciones de probabilidad; si al realizar el cambio aleatorio el resultado obtenido se asemeja el deseado el cambio es aceptado. Por el contrario, si el valor obtenido no es semejante al valor esperado, el cambio puede ser aceptado en función de una determinada y preestablecida distribución de probabilidad (Haykin, 2016).

Corrección de error

En este método de aprendizaje se ajustan los pesos de las conexiones de la red en función del error cometido en la salida, es decir, diferencia entre los valores deseados y los obtenidos a la salida de la red. Para cada neurona en la capa de salida se calcula la desviación a la salida objetivo como el error \mathcal{D} , el cual se emplea para cambiar los pesos sobre la conexión de la neurona precedente.

Algunas de las reglas empleadas para este método de aprendizaje son; la regla del perceptron, la regla del aprendizaje delta o regla del mínimo error cuadrado (LMS) y la regla de aprendizaje de retro propagación (LMS multicapa). Esta última es una generalización de la regla de aprendizaje delta. La regla de aprendizaje LMS multicapa permitió realizar cambios sobre los pesos en las conexiones de la capa oculta (Fausett, 1993).

2.2.5.2 No supervisado

Las redes neuronales auto organizadas agrupan vectores de entrada sin el uso de datos de entrenamiento para especificar qué aspecto tiene un miembro típico de cada grupo o en qué grupo pertenece cada vector. Una secuencia de vectores de entrada es proporcionada, pero

no se especifican los vectores objetivos. La red modifica los pesos de modo que los vectores de entrada más similares se asignan a la misma salida (Fausett, 1994).

2.2.6 Redes de retro propagación (Backpropagation)

2.2.6.1 Introducción

Se les denomina como redes de retro propagación debido a la forma en que el error es propagado hacia atrás a través de la red neuronal, es decir, el error se propaga hacia atrás de la capa de salida, lo que permite que los pesos sobre las conexiones de las neuronas ubicadas en las capas ocultas cambien durante el entrenamiento. El cambio en los pesos de las conexiones influye en la activación y en la salida de una neurona; a esto se le denomina sensibilidad de la función de activación (Fausett, 1993).

Las redes de retro propagación son un tipo de redes de aprendizaje supervisado que emplea un ciclo de propagación- adaptación de dos fases. En la primera fase un patrón de entrada se propaga de la primera capa a través de las capas superiores de la red para generar una salida; esta es comparada con una salida deseada y se calcula la señal de error para cada una de las capas. En la segunda fase las salidas del error son propagados hacia atrás, esto se realiza partiendo de la capa de salida hacia todas las neuronas de la capa oculta; sin embargo estas neuronas solo reciben una fracción de la señal total del error que se basa en la fracción relativa que cada neurona aporta a la salida original. Este proceso es repetido en cada capa; en base a la señal de error percibido, los pesos de conexión de cada neurona son actualizados, logrando así que la red converja hacia un estado que permita clasificar correctamente todos los patrones de entrenamiento (Chiñas-Sánchez, López-Juárez, & Vázquez-López, 2014).

2.2.6.2 Estructura

Las redes de retro propagación, son redes multicapa con una capa oculta. Las capas de salida (Y_k) y oculta (Z_j) pueden tener un sesgo. En la capa de salida el sesgo se denota por W_{0k} y en la capa oculta se denota por v_{0j} . Los términos de sesgo actúan como pesos en las conexiones de las capas cuya salida es siempre 1.

En la Figura 2.9 se muestra la estructura de una red de retro propagación, donde se puede ver la relación entre los pesos de salida de cada neurona participante en la misma.

Sólo la dirección del flujo de información para la fase de alimentación anticipada se muestra; durante la fase de entrenamiento, en este tipo de redes, las señales son enviadas en dirección inversa.




Figura 2.9: Estructura de una red de retro propagación con una capa oculta.

2.2.6.3 Algoritmo de entrenamiento

El entrenamiento de una red por retro propagación involucra 3 etapas: la alimentación del patrón de entrenamiento en la capa de entrada, la retro propagación del error asociado y el ajuste de los pesos. Durante la alimentación, cada capa de entrada (X_i) recibe una señal de entrada que transmite a cada capa oculta ($Z_1 \dots Z_j$), las cuales calculan su señal de activación y la transmiten a cada capa de salida (Y_k). En la capa de salida se calcula la señal de activación (Y_k) para calcular la respuesta de la red para el patrón dado (Fausett, 1993).

En el proceso de entrenamiento, cada capa compara la señal de activación (Y_k) con el valor objetivo (t_k) para determinar el valor del error asociado para el patrón con esa unidad, y se calcula el factor δ_k ; donde $k = 1, 2, \dots, m$; este factor es empleado para distribuir el error en la capa de salida (Y_k) regresando en todas las unidades de las capas previas; y es empleado de manera posterior en los pesos entre la capa de salida y la capa oculta. Para las capas ocultas (Z_j) no es necesario propagar el error hacia las capas de entrada, pero se calcula el factor δ_j para actualizar los pesos entre la capa de entrada y las capas ocultas (Fausett, 1993).

Finalmente, una vez que todos los factores δ han sido calculados, los pesos de todas las capas son ajustados simultáneamente; el ajuste a los pesos w_{jk} (de la capa oculta Z_j a la unidad de salida Y_k), se basa en el factor δ_k y la activación Z_j de la capa oculta en la unidad Z_j ; el ajuste v_{ik} (de la entrada X_i a la capa oculta Z_j) se basa en el factor δ_j y en la activación x_i de la unidad de entrada (Fausett, 1993).

2.2.6.4 Ventajas y Aplicaciones

El algoritmo de retro propagación constituye un modelo de aprendizaje de la red perceptron multicapa más empleado en la práctica, debido a su sencillez y eficacia para la resolución de problemas complejos (Flórez & Fernández, 2008).

Por la sencillez de las redes backpropagation y por la característica de emplear los errores para mejorar las salidas esperadas, estas redes han demostrado una amplia capacidad en la resolución de diversos problemas; alguna de las áreas en las cuales se han empleado son en la clasificación de imágenes, síntesis de voz, clasificación de ecos sonar, sistemas de base de conocimientos, codificación de información y en problemas de clasificación y percepción (Flórez & Fernández, 2008).

La principal ventaja de las redes backpropagation es su capacidad de mapeo de patrones, en otras palabras, la red es capaz de aprender una gran variedad de relaciones de mapeo de patrones; no requiere un conocimiento matemático de la función que relaciona los patrones de la entrada y salida, esta red solo necesita ejemplos de mapeo para aprender. La flexibilidad de esta red es aumentada con la posibilidad de elegir el número de capas, interconexiones, unidades procesadoras, constantes de aprendizaje y representación de datos (Haykin, 2016).

2.3 Algodón

El algodón es una de las fibras más estudiadas y empleadas en la industria textil, aproximadamente un 60% de la producción de esta fibra es usada en hilados e hilos en una amplia gama de ropa, así como en la producción de colchas, persianas, sábanas, toallas entre otras (Lockuán, 2012).

2.3.1 Principales características

El algodón es una fibra natural, se puede clasificar en 4 variedades: *Gossypium arboreum*, *Gossypium barbadense*, *Gossypium herbaceum* y *Gossypium hirsutum*. La estructura de esta fibra está formada por una cutícula, una pared primaria, una pared secundaria y el lumen; esta fibra crece casi a su longitud completa como un tubo hueco antes de que se comience a formar la pared secundaria, la cual está constituida por celulosa; el lúmenes el canal central a través del cual se transportan nutrientes durante el crecimiento de la planta (Lockuán, 2012).

La clasificación del algodón depende de su lugar de procedencia, variedad, longitud y grado; en la Tabla 2.2 se muestra la clasificación

Tabla 2.2: Clasificación por la longitud media de la fibra de algodón

Clasificación	Milímetros	Pulgadas
Cortos	Menos de 20.64	Menos de 13/16
Medianos	20.64 – 25.4	13/16 a 1
Medianamente largos	26.98 a 27.78	1 1/6 a 1 1/32
Largos	28.58 – 33.30	1 1/8 a 1 5/16
Extra largos	Más de 35.04	Más de 1 3/8

2.3.2 Teñido

El proceso de tinte hace mención a colorear de manera más o menos permanente, las fibras textiles u otras sustancias, mediante la saturación de las mismas con una solución de colorante. Existen diversos factores que afectan el proceso de teñido, dentro de estos factores se encuentran el tipo de fibra, los colorantes y el medio dentro del cual los dos se ponen en contacto. Existen tres formas o métodos de como los colorantes pueden ser retenidos por las

fibras (Shamin Reza, Haque, Azim, Hoque Azizul, & Mishuk Islam, 2014) (Rahman Bhuiyan, Mizanur Rahman, Shaid, & Khan, 2014):

- Absorción física: Se basa en la interacción de la fuerza con la que se atraen los colorantes y la fibra, supone que dicha fuerza es lo suficientemente grande para retener las moléculas de colorante y resistir los tratamientos posteriores de lavado.
- Absorción mecánica: Consiste en la formación de materiales y pigmentos insolubles libres de la solubilidad química con que fueron difundidos en la fibra.
- Reacción en fibra: aquí las moléculas de colorante no pierden todos sus grupos funcionales solubles después de ser difundidos dentro de la fibra y bajo las condiciones correctas reaccionan uniéndose a las moléculas largas de la fibra, formando nuevas derivaciones de color en las fibras.

2.3.2.1 Proceso de teñido.

Según Lockuán (2012) dentro de los métodos de teñido tradicional existen tres etapas, las cuales son:

- a) Absorción: En esta etapa el colorante no sufre ningún tipo de reacción, ya que se encuentra en un medio neutro y la difusión del colorante hacia el interior de la fibra se lleva a cabo por afinidad, este proceso se realiza hasta conseguir un punto de equilibrio entre el colorante en el medio y la fibra.
- b) Reacción: después del agotamiento a un pH neutro (absorción), se produce la reacción del colorante con la fibra y el agua. Para que se produzca dicha reacción es necesario dar un medio alcalino al baño con la adición de carbonato de sodio, hidróxido de sodio o algún álcali. Según sea el caso, para colores de baja intensidad el pH final deseado se encuentra en un rango de 10,4 a 10,8 y colores intensos en 10,8 a 11,2.
- c) Eliminación del colorante hidrolizado: consiste en eliminar el colorante hidrolizado que se encuentra en el baño y el absorbido por la fibra. En el primer caso, es suficiente

con el vaciado del baño y un enjuague en caliente, pero en el segundo caso es necesario realizar un jabonado a temperatura de ebullición durante 10 minutos.

2.3.2.2 Tipos de colorantes empleados

Dentro de la industria textil se emplean diversos colorantes en el proceso de teñido, la selección de los mismos depende del tipo de fibra que se desea teñir, en la

Tabla 2.3 se enlistan diversos colorantes empleados en las fibras más comunes dentro de la industria textil.

Tabla 2.3: Tipo de colorante empleado en diversas fibras

Fibra	Colorante
Celulósica (natural y artificial)	Directo, reactivo, a la tina, al azufre, naftol
Poliéster	Disperso, básico
Poliamida	Disperso, ácido, pre metalizado
Acetato	Disperso
Lana y seda	Ácido, pre metalizado
Acrílico	Disperso, básico

La selección del tipo de colorante depende del desempeño deseado, restricciones de producción y de los costos que el mercado puede soportar para el producto final (Lockuán, 2012)

- Colorantes ácidos: son los más empleados en el teñido de lana debido a que presentan una afinidad con las fibras proteicas; este tipo de colorantes se asemeja a los tintes de

clase directa, por lo cual son empleados para la tintura de fibras que contienen celulosa.

- Colorantes básicos: son hidrocarburos de sales o bases orgánicas. Son conocidos como tintes catiónicos; se emplean en el teñido de fibras acrílicas.
- Colorantes directos: son solubles en agua y se unen al algodón por atracción química. Existe afinidad del hidrógeno de la molécula del colorante a los grupos hidroxilo de la celulosa; después de que el colorante se disuelve en agua, se añade sal para controlar el porcentaje de absorción del colorante por la fibra. Su costo no es elevado y se encuentran en una amplia variedad de tonos.
- Colorantes reactivos: esta clase de colorantes se adhiere a la fibra de celulosa formando una fuerte liga química; fueron desarrollados para lograr una solidez al color aceptable en fibras celulósicas de manera más económica.
- Colorantes a la tina: son colorantes insolubles en agua. Se reducen en medios alcalinos y se transforman en compuestos leuco derivados hidrosolubles; este proceso es fundamental ya que genera una acción reductora del hidrógeno sobre el grupo carbonilo, transfiriéndolo al grupo alcohólico, en este estado es aplicado sobre el sustrato y luego se oxida para insolubilizarlo nuevamente, pero esta vez ya dentro de la fibra.
- Colorantes sulfurosos: su proceso es parecido a los colorantes a la tina; tiñen las fibras en estado reducido y se oxidan para volverse insolubles. Son colorantes insolubles en agua pero solubles en medio alcalino y en presencia de sulfuro de sodio como agente reductor.
- Colorantes naftoles: el proceso de teñido con estos colorantes consiste en tratar el sustrato con disoluciones alcalinas de las anilidas de ácidos fenol carboxílicos que han de actuar como un agente fijador a fin de que las fibras los fijen para ser transformados en el verdadero colorante mediante el tratamiento con una disolución de la sal de diazonio. Los colorantes naftoles están disponibles en colores brillantes, se emplean en el teñido de fibras celulósicas.
- Colorantes dispersos: se emplean para teñir el acetato; son suspensiones de compuestos orgánicos finamente divididos con muy baja solubilidad; el colorante

disperso se fija en la fibra mediante fuerza físicas (fuerzas de van der Waals) ya que poseen iones o cargas eléctricas.

- Colorantes pre metalizados: se emplean en el teñido directo de la lana, se aplican con mayor rapidez, son fáciles de combinar y en algunos colores tienen más brillo que los colorantes mordentables (Lockuán, 2012).

2.4 Diseño de experimentos

En todas las disciplinas científicas y de la ingeniería se realizan diversos experimentos los cuales son una parte importante en el aprendizaje de la forma en que trabaja un sistema o un proceso. Un experimento consiste en una o varias pruebas que permiten evaluar los efectos de diferentes factores que actúan en los sistemas o procesos a estudiar (Montgomery & Runger, 2012) (Breyfogle, 2003).

El diseño de experimento (DOE) tiene un papel importante en la solución eventual del problema que lo motivó. Estos diseños son modelos estadísticos clásicos cuyo objetivo es averiguar si unos determinados factores influyen en una variable de interés y si existe influencia de algún factor, así como cuantificar dicha influencia. Existen diferentes tipos de diseños de experimentos, dentro de los cuales se encuentran los diseños completamente aleatorizados, los diseños en bloques o con un factor de bloque, diseños con dos o más factores y el diseño de mezclas (Breyfogle, 2003).

2.4.1 Diseño de mezclas

Según Breyfogle (2003), el diseño experimental de mezclas se emplea en aquellas situaciones en las que diversos elementos son mezclados en diversas proporciones para obtener un producto determinado. En estos casos, si uno de los elementos de la mezcla incrementa su porcentaje en el producto final, la proporción de los otros elementos serán ajustados de manera proporcional. En el problema de la mezcla general, la respuesta medida depende solo de la proporción de los componentes presentes en la mezcla y no de la cantidad total de la mezcla deseada.

Existen diferentes tipos de diseños de mezclas los cuales son:

- Simplex-Lattice – este tipo de diseños aborda problemas donde no hay restricciones en los límites de los porcentajes de los compuestos que comprenden la composición total del 100%; en este caso el simplex es regularmente el lado de una figura con q vértices en $q - 1$ dimensiones.
- Simplex-Centroide: es un diseño que consiste en $2^q - 1$ corridas en todas las mezclas primarias, mezclas binarias, mezclas terciarias, etc., hasta el diseño centroide
- Vértices Extremos: este tipo de diseños pueden asumir la mayoría de las propiedades de los diseños de una matriz, consta de una corrida por cada vértice de la región factible.
- Especificado-Usuario: Las columnas son creadas en la base de datos para cada componente y la variable respuesta, pero el usuario debe definir las corridas a ser desarrolladas.

Una vez que se especifica el tipo de diseño de mezclas, se define el modelo a emplear; algunos de estos son (Montgomery & Runger, 2012):

- Lineal – El número de corridas en el diseño base si el modelo más complicado se ajusta a un modelo lineal. Un modelo lineal tiene la forma

$$Y = \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 \quad (2.16)$$

- Cuadrático – El número de corridas en el diseño base si el modelo más complicado se ajusta a un modelo cuadrático. Un modelo cuadrático tiene la forma

$$Y = \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_{12} x_1 x_2 + \beta_{13} x_1 x_3 + \beta_{23} x_2 x_3 \quad (2.17)$$

- Cúbico Especial – El número de corridas en el diseño base si el modelo más complicado se ajusta a un modelo cúbico. Un modelo cúbico tiene la forma

$$Y = \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_{12} x_1 x_2 + \beta_{13} x_1 x_3 + \beta_{23} x_2 x_3 + \beta_{123} x_1 x_2 x_3 \quad (2.18)$$

2.5 Análisis estadístico de datos

2.5.1 Análisis de varianza (ANOVA)

La prueba paramétrica más empleada que permite la verificación de si dos o más medidas muestrales proceden de la misma población es el análisis de varianza (ANOVA); este método puede ser extendido a más de dos muestras (Montgomery & Runger, 2012).

Según Guisande González et al. (2006), para la aplicación de un ANOVA, es necesario que se cumplan los siguientes puntos:

- Las muestras son aleatorias.
- Las muestras son independientes.
- La distribución de la población de donde fueron extraídos es normal.
- Sus varianzas son iguales.

El análisis ANOVA tiene su fundamento en cálculo de la variación de medias y la variación “natural” de la población, para posteriormente realizar la comparación entre ambas. La variación natural se mide por medio de la “variación del error”. Si las muestras a analizar son de una misma población, sus varianzas representarán la n-ésima parte de la varianza de la población. Algunos de los análisis de varianza son:

- Análisis de varianza uni-variante de un factor.
- Análisis de varianza uni-variante con varios factores.
- El análisis multi-variante, en este último también se pueden considerar varias variables dependientes

La elección del tipo de ANOVA a realizar depende de las características del trabajo a realizar, así como del número de variables que se quieren contrastar

2.6 Estado del arte

En la Tabla 2.4 se presenta una revisión de literatura correspondiente a las investigaciones relacionadas con el tema a desarrollar. Esta revisión bibliográfica se realizó examinando diferentes fuentes de información y revistas científicas, las cuales contiene un contenido académico parecido al tema de investigación del presente proyecto y que aportaron un panorama más claro respecto a la presente proyecto; él cual permitió comprender de manera más clara las necesidades de la investigación a desarrollar.

Así mismo, cada uno de los artículos que fue analizado, tiene algún aporte o similitud con el método o el objetivo de la presente investigación.

En esta tabla se indica el título de la investigación, los autores de dicho trabajo y finalmente un resumen de las aportaciones de cada uno a la presente investigación

Tabla 2.4: Revisión del estado del arte

Título de la investigación	Autores	Año	RNA BP	Teoría Kubelka-Munk	Técnica de teñido en algodón	Colorímetro
Instrument dependency of Kubelka-Munk in computer color matching	S.Gorji Kandi, F. Ameri and N. Khalili	2012		X		
Prediction of recipes for cotton cationisation and reactive dyeing to shade match conventionally dyed cotton	Matthew J Farrell, Mary A Ankeny and Peter J Hauser	2014			X	
A scanner based neural network technique for color matching of dyed cotton with reactive dye	Elham Sadat Yazdi Almodarresi; Javad Mokhtari; Seyed Mohammad Taghi Almodarresi; Mahdi Nouri and Ali Shams Nateri	2013	X	X		X
Application of improved back propagation algorithm in color difference detection of fabric	Li, Wang, & Jing	2015	X			X

Tabla 2.4 Revisión del estado del arte

Development of artificial neural network and nonlinear regression model of color fast finish process a textile case study	K.L. Jeyaraj, C; Muralidharan, T; Senthilvelan and S.G. Deshmukh	2013	X			
Recipe prediction of mélange yarn using modular artificial neural network	Yang, Ma, Yang, Zhang, & Shen	2018	X		X	
Development of a color matching algorithm for digital transfer textile printing using an artificial neural network and multiple regression.	Sungmin, Jong, & Chang	2015	X		X	
Spectrophotometric prediction of pre-colored fiber blends with a hybrid model based on artificial neural network and Stearns–Noechel model	Weiguo, Hui, Xiang, & Jiajia	2017	X			

Continuación...

En el artículo *“Instrument dependency of Kubelka- Munk in computer color matching”* publicado en 2012, comparan la teoría de Kubelka- Munk (técnica más empleada en la industria textil) para la predicción de la receta se basa en la teoría de Kubelka-Munk. Esta técnica describe la relación entre el factor reflectante, el área y grosor de la muestra y los coeficientes de absorción y dispersión de la luz de incidencia. Para la obtención de los valores de reflectancia (color de la muestra) se emplea un espectrofotómetro, en el cual se emplean dos geometrías, la $d / 8$ (medio de iluminación / ángulo de observación) y $45/0$ (ángulo de iluminación/ ángulo de incidencia) (Gorji Kandi, Ameri, & Khalili, 2012).

En el artículo titulado *“Prediction of recipes for cotton cationisation and reactive dyeing to shade match conventionally dyed cotton”* se desarrolló un método de teñido óptimo para el algodón mediante la técnica de cationización. Esta técnica permite teñir algodón con colorantes aniónicos sin necesidad de sal, y con un uso disminuido de tinte, agua y energía. Los niveles de cationización apropiados juegan un papel en las propiedades de teñido tales como la nivelación de la tela, en propiedades de solidez tales, exposición a la luz y en el coste total del tratamiento de cationización (Farrell, Ankeny, & Hauser, 2014).

El artículo llamado *“A scanner based neural network technique for color matching of dyed cotton with reactive dye”* empleo la teoría de Kubelka- Munk para determinar la correspondencia de colores en una formulación, debido a que esta teoría presenta fallas en algunas situaciones, se empleó una RNA con el fin de aprender el comportamiento de este sistema complejo y producir predicciones de color más precisas. Las muestras teñidas fueron escaneadas y en base a los resultados obtenidos en este proceso se elaboró el histograma de los valores $L * a * b *$. Con estos resultados la RNA seleccionada fue entrenada, una vez realizado este proceso se predijeron los colorantes y su concentración obteniendo un error cuadrático medio (MSE) inferior a 10^{-5} para aproximadamente el 80% de los datos de prueba (Almodarresi, Mokhtari, Mohammad Taghi Almodarresi, Nouri, & Shams Nateri, 2013).

En el artículo “*Application of improved back propagation algorithm in color difference detection of fabric*” Por medio del algoritmo optimizado de retro propagación (BP) de Levenberg-Marquardt empleado para extraer los valores de las características de color de las imágenes del tejido se determina la diferencia de color de las telas. Se determinaron los valores RGB, los cuales son tres entradas de la red neural BP, y los valores L , a^* , b^* medidos por espectrofotómetro son tres salidas. Con estos valores la RNA es entrenada; concluida esta etapa la red entrenada es capaz de obtener convenientemente los valores L , a^* , b^* correspondientes (Li, Wang, & Jing, 2015).

En el artículo “*Development of artificial neural network and nonlinear regression model of color fast finish process a textile case study*” se empleó la metodología de superficie de respuesta para el desarrollo de una aproximación adecuada en relación de la concentración de colorante empleado y color final obtenido. A continuación, se utilizó una red neuronal de retro propagación con una técnica de optimización numérica, a saber, un algoritmo de aprendizaje (Log-sig). La arquitectura de la RNA utilizada en este trabajo es 4-13-1. También se demostró que los modelos de respuesta de acabado de color rápido están bien adecuados para los modelos cuadráticos de esta manera, la técnica de regresión proporcionó mejores resultados (Jeyaraj, Muralidharan, Senthilvelan, & Deshmunkh, 2013).

El artículo titulado “*Recipe prediction of mélange yarn using modular artificial neural network*” se empleó el concepto red neuronal (MANN) a partir de espectros de reflectancia como método para predecir recetas de color de manera más eficaz que el método tradicional. Ésta se aplicó en el proceso de fabricación del hilo de mélange. La MANN generada mostró una clara superioridad en el coeficiente de correlación en comparación con una RNA simple, el tiempo de ejecución del entrenamiento, así como el error de raíz cuadrático medio de la receta (Yang, Ma, Yang, Zhang, & Shen, 2018).

En el trabajo titulado “*Development of a color matching algorithm for digital transfer textile printing using an artificial neural network and multiple regression*”, se generó un algoritmo

que busca resolver los problemas de coincidencia de colores durante el proceso de impresión textil de transferencia digital; este algoritmo emplea los valores RGB y CIE, donde los primeros fueron obtenidos mediante el uso de un espectrofotómetro y empleados como valores de entrada y salida para formar redes neuronales artificiales y ecuaciones de regresión múltiple. Ambos métodos generados mostraron una buena correlación entre los valores de entrada y salida (Sungmin, Jong, & Chang, 2015).

En el artículo titulado “*Spectrophotometric prediction of pre-colored fiber blends with a hybrid model based on artificial neural network and Stearns–Noechel model*”, se propuso el desarrollo de un modelo híbrido, llamado modelo Stearns-Noechel (S-N) -ANN, que combina el modelo S-N con el modelo de una red neuronal artificial (ANN). El modelo S-N fue empleado para construir la relación aproximada entre la receta y la respuesta espectrofotométrica de las mezclas de colores, este proceso fue seguido por la optimización con la ANN para lograr una mayor precisión de predicción. La diferencia de color promedio del espectro predicho obtenido con el modelo SN-ANN fue de 0.86, que fue mucho menor que la obtenida con el modelo ANN (2.21) o con el modelo tradicional S-N (1.66).

3 Marco metodológico

El objetivo del presente trabajo fue entrenar una red neuronal artificial (RNA) de retro propagación (BP), la cual sea capaz de generar formulaciones de color que cumplan con los estándares especificados para la industria textil. Para lograr dicho objetivo se desarrolló un método de trabajo consistente con el mismo.

El método empleado para este fin consistió en 3 etapas, las cuales son: Etapa 1. Recopilación de información, Etapa 2. Desarrollo de la experimentación y Etapa 3 Análisis e interpretación de los resultados de la experimentación; las tres etapas se muestran en la Figura 3.1

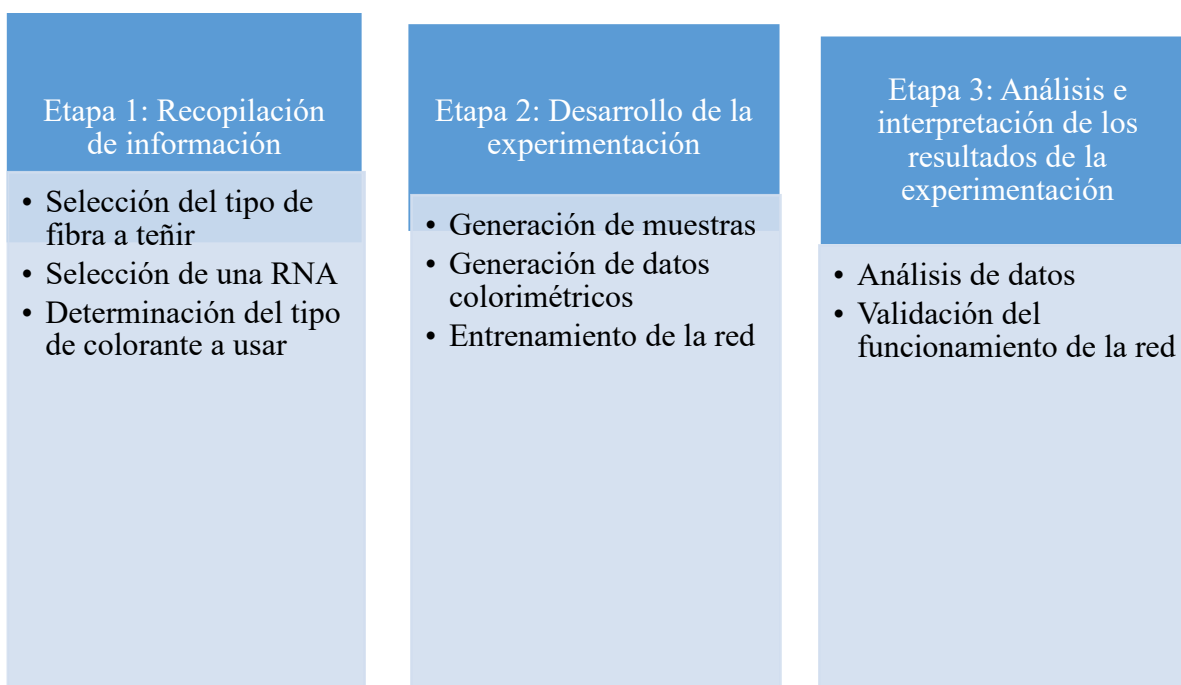


Figura 3.1: Etapas del método

A continuación, se realizará una descripción de cada etapa del proceso señalado.

3.1 Etapa 1. Recopilación de información

Esta etapa tuvo como objetivo determinar y conocer las características de la fibra empleada y de los colorantes utilizados para el desarrollo de este proyecto; así mismo se estableció el tipo de red más adecuado para el fin del mismo. Esta etapa constó de 3 actividades base, las cuales son descritas a continuación:

3.1.1 Selección del tipo de fibra a teñir

Se realizó una revisión bibliográfica que permitió conocer las características de las diversas fibras empleadas en los productos textiles; para la selección de la fibra, se consideraron los siguientes factores:

- Grado de uso en el sector textil
- Facilidad en la absorción del colorante en medio acuoso

Con base a esta revisión se seleccionó el algodón como el tipo de fibra a teñir, esto debido a su elevado uso dentro de la industria textil, así como por su facilidad de absorción de colorantes en medio acuoso.

3.1.2 Selección de una RNA

Se recopiló información, la cual permitió conocer los diferentes tipos de RNAs, los tipos de aprendizajes de las mismas, así como sus más comunes campos de aplicación en la industria.

Para el propósito de esta investigación algunas de las características más importantes que se tomaron en consideración para la selección de la red fueron las siguientes:

- Red con tipo de aprendizaje supervisado
- Facilidad para realizar cambios en los pesos de conexión
- Rápida convergencia hacia el valor esperado

Tomando en cuenta dichas características se optó por el uso de una red de retro propagación (BP), la cual ha demostrado tener un buen desempeño en la resolución de problemas que involucran trabajar con la variación presente en los datos de un proceso y que, al mismo tiempo, permiten llegar a un objetivo; en este caso; generar formulaciones de color. Este tipo de red ya ha sido empleado para la obtención de recetas de color en la industria textil, ejemplo de estos son los trabajos presentados en el punto 2.6 de Almodarresi, Mokhtari, Mohammad Taghi Almodarresi, Nouri, & Shams Nateri (2013) y Jeyaraj, Muralidharan, Senthilvelan, & Deshmunkh (2013) quienes emplearon redes neuronales BP para la obtención de recetas de color.

3.1.3 Determinación del tipo de colorante a usar

Para la elección de los colorantes utilizados, se consideró su afinidad con las características propias del tipo de fibra seleccionada, por lo cual se emplearon colorantes tipo “reactivo”, los cuales presentan una amplia afinidad a este tipo de fibra. Finalmente la técnica de teñido empleada en estos productos será el teñido tradicional, el cual fue descrito anteriormente en el punto 2.3.2.1.

3.2 Etapa 2. Desarrollo de la experimentación

Se realizó la experimentación necesaria para la generación y análisis de los datos colorimétricos que fueron empleados en las fases de desarrollo, entrenamiento y validación de la red neuronal artificial BP empleada. Para el inicio del presente proyecto se seleccionaron 2 colorantes los cuales fueron color amarillo y azul cielo.

En la Figura 3.2, se muestran las actividades que fueron necesarias para este fin.

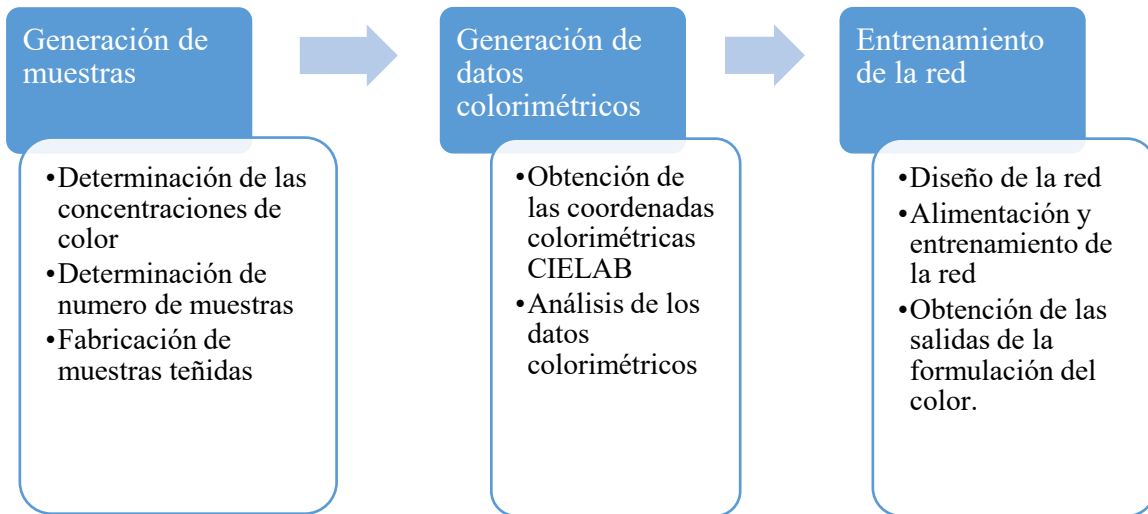


Figura 3.2: Desarrollo de la experimentación

A continuación, se describen las actividades realizadas en esta etapa.

3.2.1 Generación de muestras

En este punto se fabricaron las muestras colorimétricas empleadas, para esta actividad fueron necesarias 3 sub actividades, las cuales son:

- Determinación de las concentraciones de color

Se realizó un diseño de mezclas de modelo simplex grado 2, para los dos colorantes empleados (amarillo y azul cielo). Debido a que la tela a teñir en el presente trabajo es un tejido elaborado a base de algodón, los colorantes utilizados son denominados colorantes tipo

reactivo, los cuales son afines al tipo de tela y tratamiento de tinción a seguir. El diseño descrito se realizó de manera aleatoria. Los resultados de éste se muestran en la Tabla 3.1; en la cual se presentan los mililitros por pigmento a emplear para cada formulación propuesta.

Tabla 3.1: Propuesta de concentración en mL de pigmento a emplear

Azul cielo	Amarillo	Total
12	0	12
6	6	12
0	12	12
9	3	12
3	9	12

- Determinación de número de muestras

Cada una de las 5 formulaciones indicadas en la Tabla 3.1; se replicaron 4 veces, denominando a cada replica como una muestra de la formulación; obteniendo así un total de 20 unidades experimentales, a las cuales se les realizó la medición de sus valores correspondientes a los vectores L , a^* , b^* . El instrumento de medición empleado para la obtención de estos datos, fue un colorímetro (marca “Precise Color Reader”, modelo WR-10). Este proceso se realizó en dos bloques (bloque 1: medición y bloque 2: repetición de la medición). Estos datos se emplearán para generar la base de datos de entrenamiento para la RNA.

- Fabricación de muestras teñidas

Siguiendo el proceso de teñido especificado por el fabricante de los pigmentos empleados, primeramente, se procedió a diluir cada uno en agua caliente (a una temperatura de 90°C), generando así un tinte. Posteriormente la cantidad especificada del tinte generado se vació

en un recipiente con 500 mL de agua a una temperatura de 90°C, generada esta nueva mezcla se procedió a depositar la tela a teñir.

La determinación de la cantidad de tinte a usar dependió del peso de la tela a teñir. La cantidad total de tinte empleado fue de 12 mililitros por cada 20 gramos de tela a teñir. Cada muestra de tela teñida consistió en un cuadrado de 12cm de lado, con un peso de 5 gramos.

La tela en proceso de teñido se mantuvo en el recipiente con el tinte durante 25 minutos, esto se realizó siguiendo la recomendación del fabricante, el cual también indica que la tela debe moverse constantemente dentro del recipiente (para garantizar la agitación y temperatura constante se empleó un agitador magnético y una placa de calentamiento con agitación), esto con la finalidad de que se obtenga una coloración uniforme. Posteriormente la tela fue enjuagada con agua pura hasta que ya no presentó residuos del tinte, por último, la tela se dejó secar a la sombra.

Con el propósito de realizar un proceso de teñido adecuado, dicha experimentación se realizó bajo condiciones controladas en las instalaciones del laboratorio de química orgánica del Tecnológico Nacional de México en Celaya, del cual se emplearon diversos instrumentos como son: termómetro de mercurio (graduación de -10 a 150 °C), agitador magnético, placa de calentamiento con agitación, vasos de precipitado (marca pyrex) y balanza analítica. El proceso descrito anteriormente es ilustrado en la Figura 3.3.




Figura 3.3: Método de tinción de muestras

3.2.2 Generación de datos colorimétricos.

La medición de los datos colorimétricos de las muestras fabricadas, se llevó a cabo mediante un colorímetro (marca “Precise Color Reader”, modelo WR-10), como se resaltó anteriormente, este aparato brinda 3 lecturas, las cuales son correspondientes a los vectores L , a^* y b^* correspondientes a los vectores del espacio de color CIELAB. En la Figura 3.4 se muestran los vectores correspondientes a este espacio de color.




Figura 3.4: Vectores de color

- Obtención de las coordenadas colorimétricas CIELAB

Se tomaron lecturas en diferentes puntos de las muestras producidas anteriormente; en la Figura 3.5 se señalan los puntos donde se tomaron las mediciones. El margen que se observa en los extremos se estableció para minimizar los errores de coloración que se pueden generar en los extremos de la muestra durante el proceso de teñido.




Figura 3.5: Diagrama para la toma de datos colorimétricos

El número de puntos donde se tomaron las mediciones se determina por la fórmula 3.1; donde Z_{α} es el nivel de confianza; p , probabilidad de éxito o proporción esperada; q , probabilidad de fracaso y d , es la precisión o error máximo admisible; dando como resultado un total de 21 puntos por muestra.

$$n = \frac{Z_{\alpha}^2 * p * q}{d^2} \quad (3.1)$$

- Análisis de los datos colorimétricos

Una vez que se determinó el número de puntos a analizar se prosiguió a realizar la medición de las muestras generadas anteriormente; estas mediciones se realizaron por duplicado con el propósito de validar los datos obtenidos; una vez realizadas las mediciones se creó una base de datos.

Para el análisis de los datos colorimétricos se empleó la técnica de análisis de varianza (ANOVA) descrito anteriormente (punto 2.5.1); para el presente estudio se analizaron como factores a la muestra (el cual hace referencia a la réplica de la formulación analizada) y el

bloque (referente a la medición y a su respectiva replica), esto se realizó para verificar si existen diferencias significativas tanto en las réplicas de la misma formulación, así como para las mediciones de la misma muestra.

Concluida la generación de muestras colorimétricas con 2 pigmentos (Tabla 3.1), se desarrolló una nueva propuesta, en ésta se emplearon 3 pigmentos (azul, amarillo y rojo).

- Determinación de las concentraciones de color (3 pigmentos)

Para determinar las concentraciones de colorante en este caso de estudio, se empleó un diseño de mezclas de modelo simplex grado 3; el diseño descrito se realizó; igual que en el caso anterior; de manera aleatoria. Los resultados de este nuevo diseño se contienen en la Tabla 3.2, donde se muestran los mililitros por pigmento a emplear para cada formulación propuesta.

Tabla 3.2: Propuesta de concentración en mL de los 3 pigmento a emplear

Azul cielo	Amarillo	Rojo	Total
12	0	0	12
0	12	0	12
0	0	12	12
6	6	0	12
6	0	6	12
0	6	6	12
4	4	4	12
8	2	2	12
2	8	2	12
2	2	8	12

- Determinación de número de muestras

Cada una de las 10 formulaciones indicadas en la Tabla 3.2, fueron replicadas 4 veces, denominando a cada replica como una muestra de la formulación; obteniendo así un total de 40 unidades experimentales, a las cuales, al igual que en el caso anterior, se les realizó la medición de sus valores correspondientes a los vectores L , a^* , b^* . Este proceso se realizó en dos bloques (bloque 1: medición y bloque 2: repetición de la medición). Estos datos se emplearán para generar la base de datos de entrenamiento para una segunda RNA.

- Fabricación de muestras teñidas

El proceso de fabricación y obtención de los valores de los vectores de color (L , a^* , b^*) de las muestras teñidas con las formulaciones indicadas en la Tabla 3.2, siguieron el mismo método de fabricación que en el caso anterior (página 52).

- Obtención de las coordenadas colorimétricas CIELAB y análisis de datos colorimétricos

Concluido el proceso de fabricación de las muestras teñidas, se empleó la misma metodología para determinar el número de puntos de medición para obtener los datos correspondientes a los vectores de color.

Una vez conseguidos los valores L , a^* , b^* se prosiguió con el análisis de los datos colorimétricos, al igual que en el caso anterior, se empleó la técnica de análisis de varianza (ANOVA), en el cual se analizaron como factores a la muestra (el cual hace referencia a la réplica de la formulación analizada) y el bloque (referente a la medición y a su respectiva replica), esto se realizó para verificar si existen diferencias significativas tanto en las réplicas de la misma formulación, así como para las mediciones de la misma muestra.

3.2.3 Entrenamiento de la red

Esta etapa de la metodología propuesta, consistió de 3 sub actividades para su desarrollo, éstas son:

- Diseño de la red

Concluido el análisis de los datos colorimétricos, se entrenó una red neuronal artificial de retro propagación (RNA BP) en el software MATLAB 2016, del cual se empleó la herramienta NNTOOL para el diseño de la misma. En la Figura 3.6 se presenta el diseño de la red de retro propagación construida, la cual constó, para la primera formulación propuesta (Tabla 3.1), de un total de 3 entradas (correspondientes a los valores L , a^* y b^*), 2 salidas (correspondientes al número de colorantes empleados en la formulación de las muestras colorimétricas). Para la segunda formulación propuesta (Tabla 3.2); ésta consto de un total de 3 entradas (correspondientes a los valores L , a^* y b^*), 3 salidas (referentes al número de colorantes empleados en la formulación). Ambas estructuras incluyen 1 capa oculta y 1 capa de salida.




Figura 3.6: Estructura de una RNA

Para el diseño de la RNA BP, para cada uno de los casos propuestos en este trabajo, se analizaron diferentes arquitecturas de la misma, cada una con un total de 5, 10, 15 y 20 neuronas para la capa oculta.

- Alimentación y entrenamiento de la red

La alimentación de la red se realizó; con un total de 420 datos colorimétricos, los cuales corresponden a los valores de los vectores L , a^* y b^* , de las muestras colorimétricas fabricadas con la formulación propuesta en la Tabla 3.1 (2 pigmentos) y con 840 datos colorimétricos de los generados por las formulaciones propuestas en la Tabla 3.2 (3 pigmentos). El entrenamiento de la misma, para ambos casos, se realizó hasta que los valores R arrojados por el software fueron lo más próximo a 1; este valor garantizará el mejor desempeño en la predicción de la formulación obtenidas por medio de la red.

- Obtención de las salidas de la formulación del color.

Concluida la fase de entrenamiento de las diferentes estructuras propuestas, se comparó el valor R (que es el porcentaje de variación de la variable de respuesta que el modelo explica por medio de la relación con una o más variable) de cada una. Este valor permitió identificar la estructura de la red neuronal diseñada que obtuvo un mejor desempeño para cada uno de los casos analizados.

De la red seleccionada; en cada caso de estudio, se obtuvieron los valores de error de cada una de las formulaciones evaluadas (Tabla 3.1 y Tabla 3.2); estos valores representan los mililitros de color que abra de diferencia entre las formulaciones generadas por la red neuronal y los valores base.

3.3 Etapa 3 Análisis e interpretación de los resultados de la experimentación

- Análisis de datos

Se llevó a cabo un análisis estadístico que permitió verificar el comportamiento de los datos colorimétricos generados. Como se ha señalado anteriormente, este análisis permitió comprobar si existe diferencia significativa entre las muestras generadas y las mediciones realizadas.

- Validación del funcionamiento de la red

Este punto tuvo como finalidad verificar si la red neuronal diseñada es capaz de generar formulaciones de color adecuadas para el tipo de tejido empleado, para comprobar dicho objetivo se comparó la diferencia de color entre los datos de validación y las formulaciones base que se muestran en la Tabla 3.1 y Tabla 3.2. Para determinar la diferencia de color de las diferentes formulaciones se empleó el estadístico ΔE_{CMC} ; éste se emplea como estándar internacional para la evaluación del color en la industria textil.

Finalmente para asegurar que la red genere formulaciones adecuadas se definió que la diferencia entre los valores base y los de validación deberán tener una diferencia

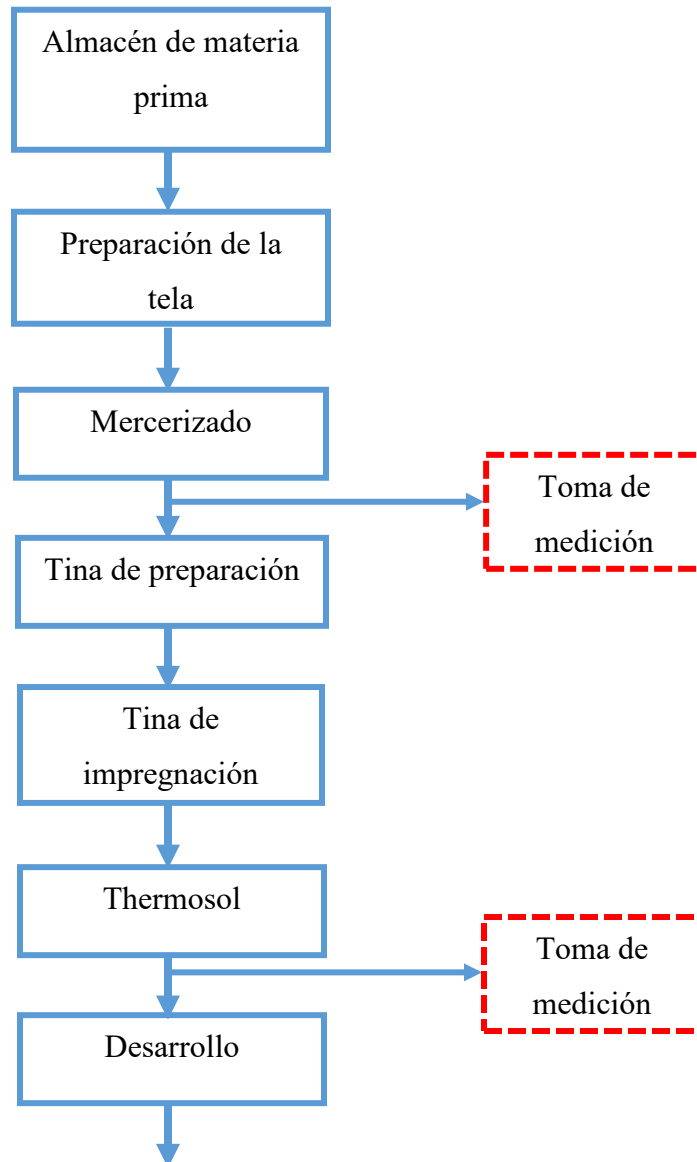
$$\Delta E_{CMC} = 0.5$$

3.4 Caso de aplicación.

Como parte de la aplicación del presente trabajo, se gestionó el desarrollo práctico del mismo en una empresa dedicada a la producción de productos textiles, la cual está ubicada en la ciudad de Salvatierra Guanajuato. El proceso de producción de esta empresa se describe en

el anexo 2. Este proceso de producción consta de 4 etapas principales, las cuales son la preparación de la tela, el mercerizado, teñido y el pad steam(o acabado).

Se realizaron las mediciones colorimétricas de la tela sin teñir y de la tela teñida en las etapas de mercerizado y teñido (fuera del thermosol) del proceso de producción de la empresa, esto con el fin de generar una base de datos propia de la empresa similar a la del método de la tesis desarrollado, que a su vez permitirá entrenar una red neuronal artificial BP. En la Figura 3.7 se señalan las etapas del proceso en las cuales se llevarán a cabo las mediciones de las coordenadas colorimétricas.



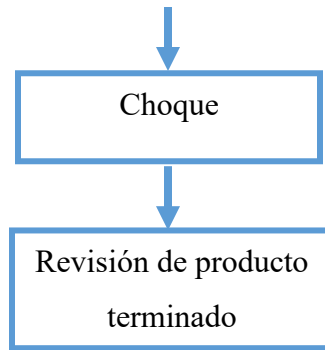


Figura 3.7: Proceso de producción de la empresa Carolina performance

Las formulaciones de color para el entrenamiento de la red neuronal, fueron proporcionadas por parte de la empresa.

Los puntos donde se realizó la toma de mediciones se seleccionaron en base al impacto que generan en el producto final. Ya que una apropiada generación de color en este punto permitirá minimizar las inconformidades en la evaluación del producto final. Así mismo fueron proporcionadas las formulaciones de color empleadas por parte de la empresa

4 Resultados.

A continuación, se muestran los resultados obtenidos mediante el método descrito en el capítulo anterior, el cual tuvo como finalidad desarrollar y entrenar una red neuronal artificial capaz de disminuir el error de formulación en la industria textil.

4.1 Resultados de la etapa 2: Desarrollo de la experimentación

4.1.1 Generación de muestras

Para la fabricación de las muestras colorimétricas, se generaron los licores de color que fueron empleados para los procesos de teñido. En la Figura 4.1 se muestran los licores básicos (azul, amarillo y rojo) que fueron empleados para cada una de las formulaciones propuestas en los casos de estudio propuestos (2 pigmentos y 3 pigmentos base).




Figura 4.1: Licores de teñido

Generados los licores, se prosiguió con el teñido de las muestras colorimétricas siguiendo las formulaciones propuestas en la Tabla 3.1 y en la Tabla 3.2; así como el proceso de teñido descrito anteriormente en el punto 2.3.2.1. En la Figura 4.2 se presentan algunas de las muestras colorimétricas generadas tras este proceso.




Figura 4.2: Muestras teñidas

Concluido el proceso de teñido, las 20 unidades experimentales generadas bajo la propuesta señalada en la Tabla 3.1 fueron etiquetadas; mismo procedimiento que se llevó a cabo con las 40 unidades experimentales generadas bajo la propuesta de formulación de la Tabla 3.2. La Tabla 4.1 muestra la formulación base empleada en cada caso, correspondiente a las

formulaciones propuestas en la Tabla 3.1, así como la nueva etiqueta de cada una de las 20 unidades experimental correspondiente a la misma.

Tabla 4.1: N° de muestras por formulación, 2 pigmentos

Formulación	N° de muestras correspondientes
0 / 12 mL	17, 13, 8, 3
12 / 0 mL	16, 11, 6, 1
6 / 6 mL	18, 12, 7, 2
9 / 3 mL	19, 14, 9, 4
3 / 9 mL	20, 15, 10, 5

En la Tabla 4.2 se muestra la formulación base empleada para el segundo caso de estudio (Tabla 3.2), así como la etiqueta correspondiente a cada una de las 40 unidades experimentales obtenidas por formulación.

Tabla 4.2: N° de muestras por formulación, 3 pigmentos

Formulación	N° de muestras correspondientes
12 / 0 / 0 mL	31, 21, 11, 1
0 / 12 / 0 mL	32, 22, 12, 2
0 / 0 / 12 mL	33, 23, 13, 3
6 / 6 / 0 mL	34, 24, 14, 4
6 / 0 / 6 mL	35, 25, 15, 5
0 / 6 / 6 mL	36, 26, 16, 6
4 / 4 / 4 mL	37, 27, 17, 7
8 / 2 / 2 mL	38, 28, 18, 8
2 / 8 / 2 mL	39, 29, 19, 9
2 / 2 / 8 mL	40, 30, 20, 10

4.1.2 Generación de datos colorimétricos

- Obtención de las coordenadas colorimétricas CIELAB (2 pigmentos)

A cada una de las 20 unidades experimentales desarrolladas con las formulaciones propuestas en la Tabla 3.1 se les realizó la medición de los vectores del espacio de color L , a^* , b^* ; para esto se siguió la metodología descrita anteriormente, donde, de manera general, se tomó lectura de color en 21 puntos de cada una de las muestras generadas como se señaló en la Figura 3.5, esta medición se realizó de manera consecutiva para cada una de las formulaciones base propuestas; posterior a esto, los datos fueron almacenados en una base de datos para su posterior análisis.

En la Tabla 4.3 se muestra un ejemplo de los resultados obtenidos para las formulaciones en las que se emplearon 2 pigmentos (Azul y amarillo) como base, donde cada columna contiene los valores correspondientes a los vectores L , a^* , b^* propios de cada muestra generadas por formulación.

Tabla 4.3: Valores L, a*, b* para la formulación 0/12 mL. 2 pigmentos

Muestra 17			Muestra 13			Muestra 8			Muestra 3		
L	a*	b*	L	a*	b*	L	a*	b*	L	a*	b*
78.62	-0.2	61.82	77.96	0.93	64.28	78.28	0.1	62.57	78.71	0.1	62.04
77.69	0.38	62.92	78.14	0.61	63.45	78.04	0.49	64.04	78.42	0.28	61.21
78.58	-0.04	62.47	77.9	1.12	64.17	78.58	0.09	61.57	78.83	0.12	61.29
78.63	0.25	62.74	77.64	1.28	62.85	78.87	0.03	62.08	78.94	0.1	61.91
78.24	0.4	63.32	78.17	0.95	63.76	78.8	0.26	62.72	78.68	-0.21	61.62
77.92	0.93	63.84	78.01	1.04	63.06	78.49	0.54	63.54	79.02	-0.04	61.49
78.21	0.54	62.36	77.24	1.68	63.78	78.27	0.36	62.99	78.78	-0.23	61.24
78.84	-0.35	61.42	77.91	1.07	64.03	78.62	0.01	62.48	78.8	0.26	61.82
78.68	-0.29	62.05	78.35	0.43	62.72	78.64	0.2	62.84	78.59	0.44	62.31
78.03	0.83	64.23	78.32	0.54	63.38	77.19	0.75	62.24	78.41	0.48	63.35
78.41	0.35	62.87	78.3	0.8	63.67	78.45	0.34	62.19	79.05	-0.18	61.62
78.94	-0.21	62.05	76.27	1.41	61.98	78.36	0.62	63.25	78.71	0.21	62.91
78.63	-0.02	62.75	77.85	0.98	62.86	78.57	0.24	62.81	78.98	-0.05	62.58
78.38	0.32	62.57	77.36	0.7	61.63	77.94	0.7	62.4	78.45	0.24	62.7
78.4	-0.15	62.18	78	1.01	63.26	79	-0.19	61.99	78.88	0.31	62.78
78.41	0.38	62.21	77.71	1.12	63.27	78.6	0.32	62.73	79.13	-0.02	61.59
78.07	0.86	62.7	78.77	0.17	62.32	78.17	0.7	63.2	78.56	0.15	62.54
78.26	0.71	64.01	78.32	0.68	63.42	78.14	0.18	62.44	78.66	-0.07	61.71
78.52	0.56	63.68	78.15	0.86	63.35	77.99	0.52	62.58	78.74	0.31	62.22
78.19	-0.1	62.53	77.48	0.8	62.52	78.87	0.15	63.15	78.27	0.15	62.05
77.76	0.34	63.06	77.78	0.76	62.69	78.6	0.45	63.03	78.52	0.08	62.92

- Obtención de las coordenadas colorimétricas CIELAB (3pigmentos)

Así mismo, este procedimiento se le practico a las 40 unidades experimentales generadas a partir de las formulaciones propuestas en la Tabla 3.2, para esto, al igual que en el caso anterior, se realizó la lectura de color en 21 puntos de cada una de las muestras generadas, tal y como se señaló en la Figura 3.5, esta medición se realizó de manera consecutiva para cada una de las formulaciones base propuestas; posterior a esto, los datos fueron almacenados en una base de datos para su posterior análisis.

En la Tabla 4.4 se muestra un ejemplo de los resultados obtenidos en este caso de estudio. Donde cada columna contiene los valores L , a^* , b^* de dichas unidades experimentales generadas.

Tabla 4.4: Valores L, a*, b* para la formulación 0 / 0 / 12 mL. 3 pigmentos

Muestra 3			Muestra 13			Muestra 23			Muestra 33		
L	a*	b*	L	a*	b*	L	a*	b*	L	a*	b*
59.65	34.35	12.59	58.97	34.94	12.59	58.4	35.19	13.3	58.31	35.59	13.42
59	34.69	12.59	57.74	35.82	13.48	58.16	35.04	12.85	57.82	35.6	13.27
59.34	34.45	12.46	58.84	34.73	12.5	58.36	35.15	12.95	59.05	34.75	12.59
58.81	35.04	12.62	59.07	34.8	12.76	58.57	35.1	13.08	58.53	35.36	12.95
58.47	35.44	13.12	57.85	35.28	13.23	57.5	35.85	13.46	58.7	35.36	13.09
58.73	34.93	12.91	58.71	35.07	13.12	58.09	34.78	12.78	59.68	34.79	12.56
59.54	34.39	12.47	58.53	34.7	12.81	58.33	35.65	13.44	59.27	34.08	12.39
58.98	33.81	12.24	59.08	34.92	12.67	58.57	34.75	12.97	59	34.72	12.6
58.75	35.21	13	58.52	35.26	12.87	58.74	34.63	12.95	58.27	35.52	13.28
59.8	34.16	12.37	58.3	35.15	13.27	58.39	35.34	13.22	58.4	35.76	13.38
59.7	34.38	12.29	59.07	34.54	12.55	59.14	34.66	12.73	59.07	35.23	12.88
60.44	33.82	12.16	58.56	35.25	13.04	57.99	35.82	13.7	59.19	34.61	12.77
59.4	34.46	12.89	58.57	35.32	13.1	58.44	35.05	13.21	58.78	35.08	12.74
59.56	34.34	12.33	58.41	35.14	12.89	58.71	34.64	12.49	58.73	35.04	12.77
59.45	34.11	12.26	59.31	33.88	12.38	58.5	35.1	13.31	58.56	35.13	13.12
59.44	34.45	12.61	58.6	35.17	13.15	58.48	34.86	13.01	59.14	34.45	12.58
58.68	34.89	12.71	58.23	34.94	12.9	58.35	35.03	12.85	58.4	35.02	12.81
58.76	34.64	12.7	58.65	35.26	13.33	58.35	34.82	12.78	58.78	35.27	12.94
59.19	34.67	12.3	58.84	35.11	12.95	58.39	35.41	13.18	58.73	35.27	13.19
60.32	33.64	12.06	58.31	34.96	12.89	58.59	35.34	13.17	59.1	34.49	12.63
59.28	34.24	12.37	58.71	34.94	12.75	58.45	34.66	13.03	59.23	34.45	12.55

- Análisis de los datos colorimétricos (2 pigmentos)

A los resultados obtenidos para el espacio de color *CIELAB* correspondientes a los vectores L , a^* , b^* por cada una de las 20 unidades experimentales generadas (Tabla 4.1), así como por cada bloque de medición se les realizó un análisis de varianza de 2 factores; en éste se tomó como factor 1 la muestra analizada (correspondiente a la cada una de las formulaciones propuestas en la Tabla 3.1) y como factor 2 al bloque de medición (correspondiente a la medición realizada y a la réplica de la misma).

En la Tabla 4.5 se muestra un ejemplo de los ANOVA's obtenidos para las 20 unidades experimentales correspondientes a las formulaciones contenidas en la Tabla 3.1, donde, cada sección, corresponde al análisis ANOVA de cada vector de color (L , a^* , b^*) obtenido por formulación analizada.

En los cuales, de manera general se obtuvo como conclusión que el factor muestra es significativo ya que este presentó un valor P menor a 0.05, mientras que el factor bloque de medición no lo es.

Tabla 4.5: ANOVA de los vectores colorimétricos. 2 pigmentos

Análisis de varianza L					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	8.166	2.7221	4.33	0.006
Bloque	1	2.167	2.1669	3.45	0.065
Error	163	102.456	0.6286		
Falta de ajuste	3	1.085	0.3616	0.57	0.635
Error puro	160	101.371	0.6336		
Total	167	112.789			
Análisis de varianza a*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	1.5677	0.52257	3.22	0.024
Bloque	1	0.2530	0.25304	1.56	0.213
Error	163	26.4251	0.16212		
Falta de ajuste	3	0.1212	0.04040	0.25	0.864
Error puro	160	26.3039	0.16440		
Total	167	28.2459			
Análisis de varianza b*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	25.346	8.4486	8.83	0.000
Bloque	1	4.808	4.8077	5.02	0.026
Error	163	156.044	0.9573		
Falta de ajuste	3	0.977	0.3257	0.34	0.799
Error puro	160	155.067	0.9692		
Total	167	186.198			

- Análisis de los datos colorimétricos (3 pigmentos)

De mismo modo, este procedimiento fue implementado para las 40 unidades experimentales correspondientes a las formulaciones de la Tabla 3.2. Para las cuales se realizó un análisis de varianza de 2 factores; en el cual se tomó como factor 1 la muestra analizada y como factor 2 al bloque de medición.

Así mismo en la Tabla 4.6 se presenta un ejemplo de los ANOVA's obtenidos para estas 40 unidades experimentales (Tabla 3.2). Donde, al igual que en el caso anterior, se obtuvo como conclusión que el factor muestra es significativo ya que este presentó un valor P menor a 0.05, mientras que la medición de la variación no lo es.

Los ANOVA's generados para todas las muestras desarrolladas en cada caso de estudio se muestran en el anexo 0.

Tabla 4.6: ANOVA de los vectores colorimétricos. 3 pigmentos


Análisis de varianza L					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	21.5399	7.17998	36.46	0.000
Bloque	1	0.0003	0.00031	0.00	0.968
Error	163	32.1033	0.19695		
Falta de ajuste	3	0.2277	0.07588	0.38	0.767
Error puro	160	31.8757	0.19922		
Total	167	53.6436			
Análisis de varianza a*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	10.3956	3.46518	18.4	0.000
Bloque	1	0.5952	0.59524	3.16	0.077
Error	163	30.6941	0.18831		
Falta de ajuste	3	0.0271	0.00904	0.05	0.986
Error puro	160	30.667	0.19167		
Total	167	41.6849			
Análisis de varianza b*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	7.2166	2.40554	26.58	0.000
Bloque	1	3.29	3.29	36.35	0.000
Error	163	14.7546	0.09052		
Falta de ajuste	3	0.0343	0.01144	0.12	0.946
Error puro	160	14.7202	0.092		
Total	167	25.2612			

Como se puede observar, los valores P para los vectores L , a^* , b^* correspondientes al factor muestra, en ambos casos, es significativo, esto indica posibles cambios en la coloración obtenida, que pueden ser originados durante el proceso de teñido.


A continuación se muestran las gráficas de intervalos para cada una de las muestras analizadas, donde cada fila de gráficas representan los valores L , a^* , b^* para cada replica realizada en cada una de las 5 formulaciones propuestas en la Tabla 3.1.

En estas gráficas, cada barra representa cada una de las muestras, mientras que en la parte superior de cada una de éstas se indica la receta de color empleada para generar dichas muestras (Figura 4.3).


0 mL azul / 12 mL amarillo



12 mL azul / 0 mL amarillo



6 mL azul / 6 mL amarillo



3 mL azul / 9 mL amarillo





Figura 4.3: Gráfica de intervalos para los valores L , a^* , b^*


En la Figura 4.4 se presentan las gráficas de intervalos para cada una de las muestras analizadas, donde, al igual que en el caso anterior, cada fila de gráficas representan los valores L , a^* , b^* para cada replica realizada en cada una de las 5 formulaciones propuestas en la Tabla 3.2.

De igual manera, en estas gráficas, cada barra representa cada una de las muestras, mientras que en la parte superior de cada una de éstas se indica la receta de color empleada para generar dichas muestras.

12 mL azul / 0 mL amarillo / 0 mL Rojo



0 mL azul / 12 mL rojo / 0 mL Rojo



0 mL azul / 0 mL amarillo / 12 mL Rojo




Figura 4.4: Graficas de intervalos para los valores L , a^* , b^* . 3 pigmentos

Como se puede observar en la figura anterior, se logra apreciar cómo el valor correspondiente a la variable muestra (nombre de la variable asignada a las 4 muestras colorimétricas obtenidas de las 5 formulaciones propuestas en la Tabla 3.1 y a las 4 muestras obtenidas mediante las 10 formulaciones señaladas en la Tabla 3.2) es significativo.

4.1.3 Entrenamiento de la red

- Diseño de la red

En la Figura 4.5 se presenta el diseño de una de las redes de retro propagación construidas en el software MATLAB 2016, las cuales, en el primer caso analizado (2 pigmentos empleados), consta de un total de 3 entradas (correspondientes a los valores L , a^* y b^*), 2 salidas, 1 capa oculta y 1 capa de salida. Mientras que, para el segundo caso propuesto (3 pigmentos empleados), la estructura de la red fue: 3 entradas (correspondientes a los valores L , a^* y b^*), 3 salidas, 1 capa oculta y 1 capa de salida.

Los números en la parte inferior de cada capa indica la cantidad de neuronas presentes en las mismas. Para el caso ilustrado se cuentan con 3 neuronas en la entrada de la red, 5 en la capa oculta, 2 en la capa de salida y 2 en la salida.




Figura 4.5: RNA de retro propagación con 5 neuronas en la capa oculta

Siguiendo la metodología propuesta, se analizaron, para cada uno de los casos de estudio (2 pigmentos base o 3 pigmentos base), las 4 estructuras propuestas en la metodología, las cuales variaban en el número de neuronas en la capa oculta; estas estructuras correspondieron a un total de 5, 10, 15 y 20 neuronas en dicha capa.

En la Tabla 4.7 se muestran las estructuras de la RNA BP para las formulaciones de 2 pigmentos base (Tabla 3.1).

Tabla 4.7: Cantidad de neuronas presentes en cada capa. 2 pigmentos

N° de arquitectura	Entrada	Capa oculta	Capa de salida	Salida
1	3	5	2	2
2	3	10	2	2
3	3	15	2	2
4	3	20	2	2

Por otra parte, en la Tabla 4.8 se presenta la estructura de la RNA BP para las formulaciones de 3 pigmentos, correspondientes a las contenidas en la Tabla 3.2 (3 pigmentos base).

Tabla 4.8: Cantidad de neuronas presentes en cada capa. 3 pigmentos

N° de arquitectura	Entrada	Capa oculta	Capa de salida	Salida
1	3	5	2	3
2	3	10	2	3
3	3	15	2	3
4	3	20	2	3

Como se puede observar, el número de entradas a la red; en cada uno de los casos de estudio; corresponden a los vectores de color L , a^* , b^* del espacio de color CIELAB. Mientras que

el número de las salidas corresponde a la cantidad de pigmentos empleados en cada caso analizado.

- Alimentación y entrenamiento de la red

De los 840 datos colorimétricos obtenidos en el primer caso de estudio (2 pigmentos), 420 fueron introducidos en forma de una matriz inversa al software MATLAB 2016. Como salida de la red se introdujo la matriz inversa de las formulaciones iniciales propuestas en la Tabla 3.1 para cada caso. Este proceso se realizó para cada una de las arquitecturas señaladas en la Tabla 4.7.

En la Figura 4.6 se presenta un ejemplo de la ventana de entrenamiento del programa MATLAB 2016, para una red neuronal artificial BP con 5 neuronas en la capa oculta. En esta imagen, se presenta la arquitectura de la red, así como el número de ciclos necesarios para completar una corrida de entrenamiento.

Éste proceso se realizó hasta que el valor R arrojado por el software fue lo más cercano posible a 1.

Por otra parte en la Tabla 4.9 se muestra un resumen de las corridas necesarias en cada caso de estudio para obtener un valor R de entrenamiento lo más cercano 1. Valor que asegurara el correcto funcionamiento de la red.

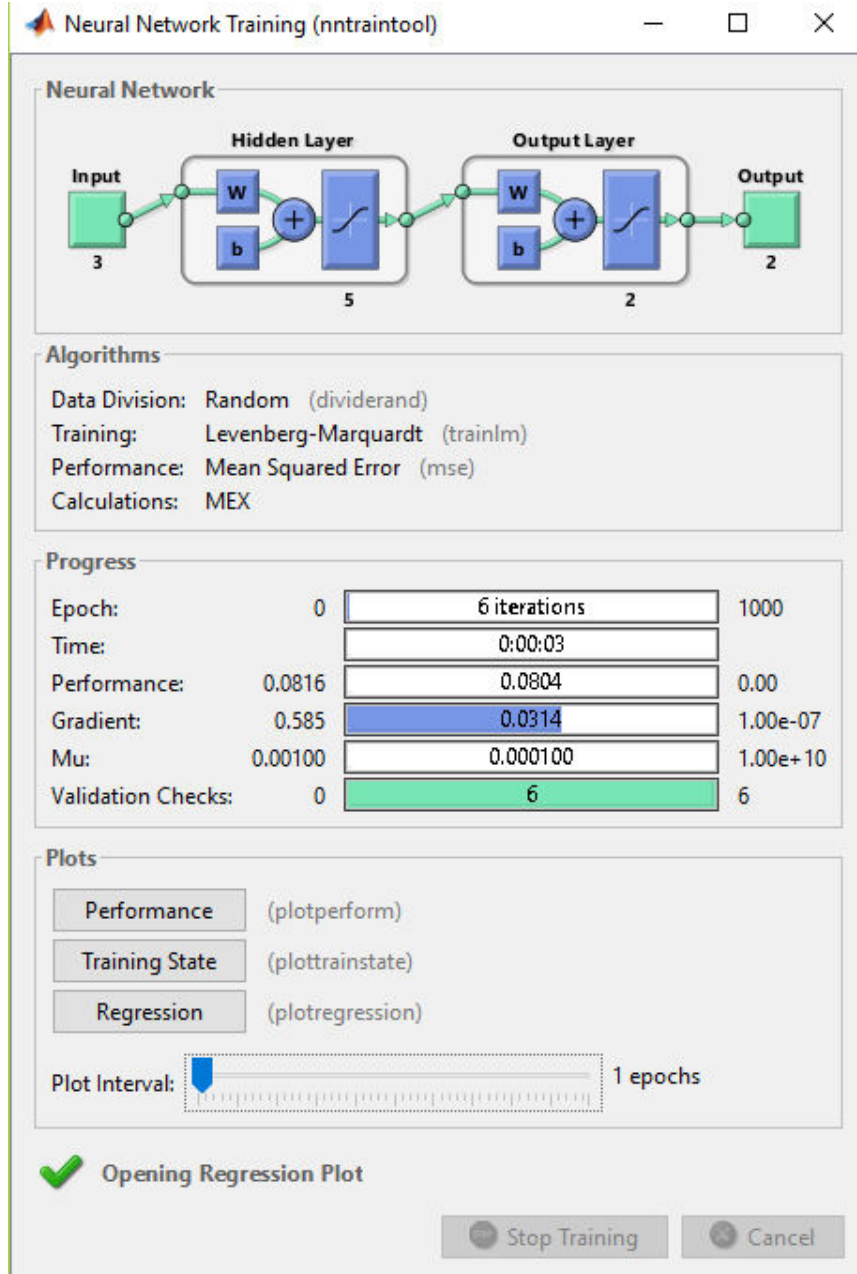


Figura 4.6: Ventana de entrenamiento MATLAB. 2 pigmentos

Tabla 4.9: Cantidad de corridas de entrenamiento

Numero de neuronas en la capa oculta	R de entrenamiento	Corridas de entrenamiento
5	0.99770	2
10	0.99837	5
15	0.99926	2
20	0.99999	5

Para las formulaciones propuestas en la Tabla 3.2 (3 pigmentos base), de los 1680 datos generados, se introdujeron 840 dato en forma de una matriz inversa al software MATLAB 2016; como salida de la red, en este caso, se introdujo la matriz inversa de las formulaciones iniciales propuestas en la Tabla 3.2; de la misma manera, se analizaron las 4 estructuras propuestas en la Tabla 4.8.

En la Figura 4.7 se muestra una ventana de entrenamiento para este caso de estudio, en ésta se puede apreciar el número de ciclos necesarios para el entrenamiento de la red, así como la arquitectura de la misma.

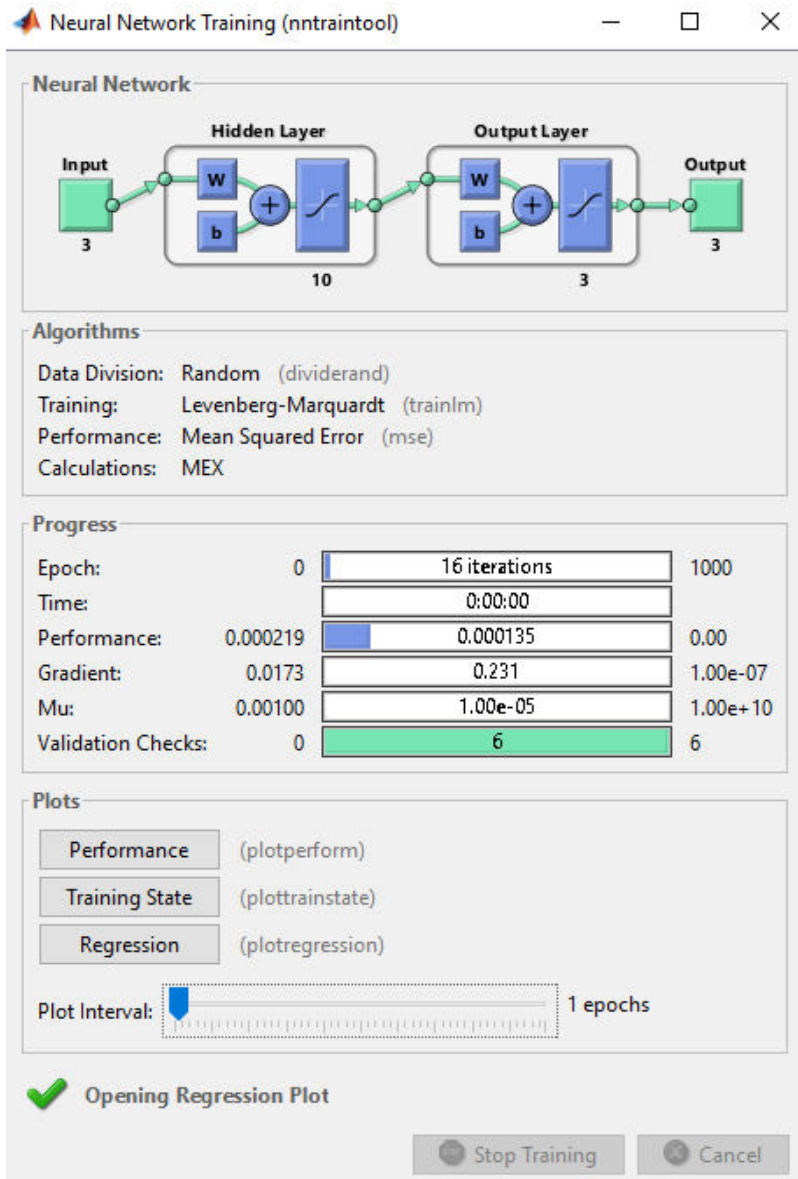


Figura 4.7: Ventana de entrenamiento de MATLAB. 3 pigmentos

El proceso de entrenamiento de las RNA BP para las formulaciones indicadas en la Tabla 3.2 se realizó hasta que el valor R arrojado por el software fue lo más cercano posible a 1.

En la Tabla 4.10 se muestra un resumen de las corridas necesarias para cada una de las estructuras analizadas, para cada caso, el proceso de entrenamiento se realizó hasta obtener un valor R de entrenamiento lo más cercano a 1.

Tabla 4.10: Cantidad de corridas de entrenamiento. 3 pigmentos

Numero de neuronas en la capa oculta	R de entrenamiento	Corridas de entrenamiento
5	0.9976	10
10	1	10
15	0.99559	20
20	0.99906	15

- Obtención de las salidas de la formulación del color.

En la Tabla 4.11 se presentan los valores de R obtenidos para cada una de las estructuras analizadas para las formulaciones propuestas en la Tabla 3.1

Tabla 4.11: Valores R del entrenamiento de la RNA

Número de neuronas en la capa oculta	R de Entrenamiento	R de Validación	R de Prueba	R de Todo
5	0.99770	0.99832	0.99747	0.99776
10	0.99837	0.99860	0.99828	0.99836
15	0.99926	0.99950	0.99866	0.99923
20	0.99999	0.99969	0.99838	0.99968

Los resultados anteriores muestran que a partir de un diseño con 5 neuronas se obtiene un buen desempeño para el tipo de datos empleados, así como para el problema analizado; ya que los valores de R obtenidos después del entrenamiento de la red son aceptables. A pesar de que el resto de estructuras propuestas muestran un desempeño aceptable para este

problema, el uso de un elevado número de neuronas podría generar un sobre ajuste en la RNA, por lo cual se optó por emplear la primer propuesta (5 neuronas en la capa oculta).

En la Tabla 4.12 se muestran los valores R obtenidos para cada una de las estructuras analizadas empleando las formulaciones indicadas en Tabla 3.2

Tabla 4.12: Valores R del entrenamiento de la RNA. 3 pigmentos

Número de neuronas en la capa oculta	R de Entrenamiento	R de Validación	R de Prueba	R de Todo
5	0.9976	0.9982	0.9975	0.99767
10	1	1	0.99999	1
15	0.99559	0.99536	0.99656	0.99568
20	0.99906	0.99981	0.99985	0.9993

Como se puede apreciar, un diseño con 10 neuronas en su capa oculta brinda un buen desempeño para el tipo de datos empleados, así como para el problema analizado; ya que los valores R obtenidos después del entrenamiento de la red son aceptables.

- Validación del funcionamiento de la RNA BP. (2 pigmentos)

Finalizada la etapa de entrenamiento de la red neuronal artificial con arquitectura 3-1-2 y con 5 neuronas en la capa oculta; estructura seleccionad para el primer caso de estudio (Tabla 3.1, 2 pigmentos base); se obtuvieron los valores de las formulaciones desarrolladas por la misma; estos valores, fueron comparados con las formulaciones base (señalados en la Tabla 3.1), finalmente se calculó el error presente para este caso.

Antes de realizar dicho procedimiento, se generó un intervalo de confianza para cada una de las formulaciones obtenidas por la RNA BP, estos intervalos se obtuvieron con el propósito

de determinar un rango de valores que valido que las formulaciones generadas contuvieran la formulación deseada en cada caso. En la Tabla 4.13 se muestran los intervalos para cada formulación. En la parte superior de la misma se indican la formulación base, así como el valor de la media correspondiente a cada una, finalmente se indica el valor de intervalo de confianza al 95% para cada formulación.

Tabla 4.13: Intervalos de confianza. 2 pigmentos

Formulación base	Medias de la formulación desarrollada		IC. De 95%	
	Azul	Amarillo	Azul	Amarillo
0 / 12 mL	0.000095	12	(0.000091, 0.000100)	(12.0000, 12.0000)
12 / 0 mL	11.9967	0.003289	(11.9954, 11.9980)	(0.002003, 0.004575)
6/ 6 mL	5.7607	6.2392	(5.6337, 5.8877)	(6.1122, 6.3663)
9 / 3 mL	9.2803	2.7197	(9.2302, 9.3305)	(2.6696, 2.7698)
3 / 9 mL	4.336	7.664	(4.109, 4.563)	(7.437, 7.891)

Como se puede apreciar en la tabla anterior los valores deseados para cada formulación pertenecen a su intervalo de confianza correspondiente.

Finalizado este análisis, se prosiguió a calcular el error presente para este caso. La

Tabla 4.14 contiene las formulaciones generadas por la RNA, así como el valor del error correspondiente; éste indica los mililitros de diferencia para cada formulación (donde un valor negativo indicara mL adicionales al valor original). En esta tabla, en las primeras dos columnas se señalan la cantidad en mililitros de cada pigmento empleado por formulación

base analizada a continuación, se muestran los mililitros propuestos por la RNA BP para cada formulación y finalmente la diferencia entre ambos.

Tabla 4.14: Comparación de formulaciones

Formulación base en mL		Formulación propuesta en mL		Error en mL	
Azul	Amarillo	Azul	Amarillo	Azul	Amarillo
0	12	0.015	11.956	-0.015	0.044
12	0	11.950	0.051	0.050	-0.051
6	6	5.959	6.040	0.041	-0.040
9	3	8.992	3.002	0.008	-0.002
3	9	3.062	8.939	-0.062	0.061

En la tabla anterior se puede apreciar como las formulaciones generadas por la red neuronal artificial BP desarrollada sufren un cambio en cada formulación propuesta anteriormente.

- Validación del funcionamiento de la RNA BP. (3 pigmentos)

Este procedimiento fue repetido en el caso 2 de estudio; correspondiente a 3 pigmentos base; donde la arquitectura de la RNA BP seleccionada fue 3-1-3, con 10 neuronas en su capa oculta, del mismo modo, al concluir el entrenamiento de la red, se obtuvieron los valores de las formulaciones desarrolladas por la misma; éstos fueron comparados con las formulaciones base (Tabla 3.2), finalmente se calculó el error presente para este caso.

De manera similar, antes del cálculo del error, se generaron los intervalos de confianza para cada formulación propuesta en este caso de estudio. Estos valores se muestran en la Tabla 4.15 se presentas los resultados correspondientes a cada formulación.

Tabla 4.15: Intervalo de confianza. 3 pigmentos

Formulación base	Medias			IC. De 95%		
	Azul	Amarillo	Rojo	Azul	Amarillo	Rojo
12/0/0 mL	11.985	0	0.00001	(11.9853, 11.9855)	(0.0000, 0.0000)	(0.000017, 0.000017)
0/12/0 mL	0.0009	12	0	(0.000832, 0.001073)	(12.0000, 12.0000)	(0.00000, 0.000000)
0/ 0/12 mL	0.0000 5	0	11.999	(-0.000022, 0.000141)	(0.0000, 0.000001)	(11.9995, 12.0000)
6/ 6/0 mL	5.9971 1	6.0021	0.00015	(5.99655, 5.99767)	(6.00175, 6.00254)	(0.000151, 0.000151)
6/ 0/6 mL	6.0057 6	0	6.0013	(5.99957, 6.01196)	(0.00000, 0.00000)	(5.99792, 6.00476)
0/6/6 mL	0.0060 2	6.0006	5.9996	(0.005998, 0.006051)	(5.99858, 6.00269)	(5.99759, 6.00178)
4/4/4 mL	4.0113	3.9873	3.9915	(4.00213, 4.02054)	(3.98031, 3.99430)	(3.98685, 3.99628)
8/2/2 mL	8.0106	2.0038	1.9959	(8.00283, 8.01849)	(2.00028, 2.00747)	(1.99271, 1.99925)
2/8/2 mL	2.0002	7.9994	1.9999	(2.00014, 2.00037)	(7.99926, 7.99969)	(1.99986, 2.00000)
2/2/8 mL	2.0036	1.9966	7.9968	(2.00177, 2.00544)	(1.99297, 2.00034)	(7.99497, 7.99879)

Concluido el análisis anterior se prosiguió con el cálculo del error para cada formulación. La Tabla 4.16 contiene las formulaciones generadas por esta RNA, así como el valor del error correspondiente a cada formulación, éste indica; al igual que en el caso anterior; los mililitros de diferencia para cada formulación (donde un valor negativo indicara mL adicionales al valor original).

En esta tabla, en las primeras dos columnas se señalan la cantidad en mililitros de cada pigmento empleado por formulación base analizada a continuación, se muestras los mililitros propuestos por la RNA BP para cada formulación y final mente la diferencia entre ambos.

Tabla 4.16: Comparación de formulaciones

Formulación objetivo en mL			Formulación obtenida por la RNA en mL			Error en mL		
Azul	Amarillo	Rojo	Azul	Amarillo	Rojo	Azul	Amarillo	Rojo
12	0	0	11.9854038	1.4767E-09	1.6856E-05	0.014596206	-1.4767E-09	-1.6856E-05
0	12	0	0.00095255	11.9999989	6.4096E-08	-0.00095255	1.1363E-06	-6.4096E-08
0	0	12	5.9129E-05	4.4727E-07	11.9997676	-5.9129E-05	-4.4727E-07	0.00023235
6	6	0	5.99711287	6.0021472	0.00015126	0.002887127	-0.0021472	-0.00015126
6	0	6	6.00576496	2.4421E-08	6.00134247	-0.00576496	-2.4421E-08	-0.00134247
0	6	6	0.00602482	6.00063459	5.99968567	-0.00602482	-0.00063459	0.00031433
4	4	4	4.01133983	3.98730712	3.9915654	-0.01133983	0.01269288	0.0084346
8	2	2	8.01065837	2.00387707	1.99597681	-0.01065837	-0.00387707	0.00402319
2	8	2	2.00025565	7.99947336	1.99993071	-0.00025565	0.00052664	6.9292E-05
2	2	8	2.00360455	1.99665246	7.99688006	-0.00360455	0.00334754	0.00311994

Finalmente, para cada uno de los casos de estudio (2 y 3 pigmentos base), se calculó el MSE, esto con el fin de determinar el error generado por cada formulación desarrollada correspondiente a cada red. En la Tabla 4.17 se presenta el valor del MSE para las formulaciones propuestas en la Tabla 3.1; en ésta, podemos observar las formulaciones generadas por la RNA con estructura 3-1-2 con 5 neuronas en la capa oculta, contienen un nivel de error bajo con respecto a las formulaciones objetivo, con el cual se calculó el error medio cuadrático (MSE) de 0.384147837 en el colorante azul y 0.384147837 para el colorante amarillo, en ambos casos en mililitros al cuadrado, lo cual es un valor bastante pequeño con respecto al contenido total de la formulación de color de 12 mililitros por formulación

Tabla 4.17: Cálculo del MSE. 2 pigmentos

Formulación objetivo en mL		Formulación obtenida por la RNA en mL		Error en mL		Error cuadrado en mL	
Azul	Amarillo	Azul	Amarillo	Azul	Amarillo	Azul	Amarillo
0	12	9.5339E-05	11.9999914	-9.53389E-05	8.60894E-06	9.08951E-09	7.4114E-11
12	0	11.9967118	0.00328877	0.003288207	-0.00328877	1.08123E-05	1.0816E-05
6	6	5.76073346	6.23924779	0.239266537	-0.23924779	0.057248476	0.0572395
9	3	9.28032845	2.71970674	-0.280328446	0.280293258	0.078584038	0.07856431
3	9	4.33599994	7.66408735	-1.335999944	1.335912648	1.784895849	1.7846626

Total	1.920739184	1.92047723
MSE	0.384147837	0.38409545

En la Tabla 4.18 se presenta el valor del error medio cuadrático para el 2do caso de estudio analizado (3 pigmentos base), para éste, la red seleccionada presenta una estructura 3-1-3, con 10 neuronas en su capa oculta.

Como se puede observar, el valor del MSE obtenido es de 3×10^{-5} en el colorante azul, 5.013×10^{-7} en el colorante amarillo y 1.99×10^{-7} para el colorante rojo. Al igual que el primer caso analizado, el valor obtenido para cada colorante es un valor bastante pequeño con respecto al contenido total de cada formulación, valor correspondiente a 12 mL.

Tabla 4.18: Cálculo del MSE. 3 pigmento

Formulación objetivo en mL			Formulación obtenida por la RNA en mL			Error en mL			Error cuadrado en mL		
Azul	Amarillo	Rojo	Azul	Amarillo	Rojo	Azul	Amarillo	Rojo	Azul	Amarillo	Rojo
12	0	0	11.9854	1.47E-09	1.7E-05	0.0146	-1.48E-09	-1.7E-05	0.0002	2.18E-18	2.84E-10
0	12	0	0.0009	11.9999	6.41E-08	-0.0009	1.14E-06	-6.41E-08	9.07E-07	1.29E-12	4.11E-15
0	0	12	5.9E-05	4.47E-07	11.9997	-5.91E-05	-4.48E-07	0.0002	3.5E-09	2.01E-13	5.4E-08
6	6	0	5.9971	6.0021	0.0002	0.0029	-0.0021	-0.0002	8.34E-06	4.61E-06	2.3E-08
6	0	6	6.0057	2.44E-08	6.0013	-0.0058	-2.44E-08	-0.0013	3.33E-05	5.96E-16	1.8E-06
0	6	6	0.0060	6.0006	5.9997	-0.0060	-0.0006	0.0003	3.63E-05	4.03E-07	9.9E-08
4	4	4	4.01134	3.9873	3.9916	-0.01134	0.0127	0.0084	0.0001	0.0002	7.11E-05
8	2	2	8.01066	2.0038	1.9959	-0.01065	-0.0039	0.0040	0.0001	1.5E-05	1.62E-05
2	8	2	2.0002	7.9994	1.9999	-0.00025	0.0005	6.93E-05	6.53E-08	2.77E-07	4.8E-09
2	2	8	2.00360	1.9966	7.9968	-0.00360	0.0033	0.0032	1.29E-05	1.12E-05	9.73E-06

Total	0.0003	5.013E-06	1.99E-06
MSE	3 E-05	5.013E-07	1.99E-07

Con el fin de verificar, de una manera más precisa, que se obtuvo una mejora en el desarrollo de las formulaciones de color en productos textiles, se determinó la diferencia de color de las diferentes formulaciones propuestas para los casos de estudio (Tabla 3.1 y Tabla 3.2). Para esto se empleó el estadístico ΔE_{CMC} ; éste se emplea como estándar internacional para la evaluación de la diferencia de color en la industria textil.

Para este cálculo se utilizaron los promedios de los vectores de color L , a^* , b^* de los datos de color empleados tanto para el desarrollo, como para la validación de las RNA's BP seleccionadas de cada uno de los casos de estudio

Los resultados obtenidos tras el cálculo del ΔE_{CMC} ; para el primer caso estudiado (2 pigmentos base) se muestran en la Tabla 4.19. En la cual, la primer columna se muestran los mililitros de pigmentos empleados en cada formulación, así como los valores de los vectores L , a^* , b^* para el estándar y las muestras generadas por las formulaciones obtenidas por la

red, denominadas como lote. En la última columna se presentan los valores obtenidos para el ΔE_{CMC} para cada formulación generada para este caso de estudio.

Tabla 4.19: ΔE_{cmc} para 2 pigmentos

Formulación base	Estándar			Lote			ΔE_{cmc}
	L	a*	b*	L	a*	b*	
0 / 12 mL	78.3409524	0.40142857	62.6782143	78.2920238	0.43511905	62.9747619	0.11001838
12 / 0 mL	71.8020238	-6.03583333	-12.0922619	71.2740476	-6.08809524	-12.3020238	1.03396675
6 / 6 mL	70.9128571	-15.2920238	34.2828571	70.6857143	-15.3696429	34.6211905	0.44895172
9 / 3 mL	70.3777381	-13.8772619	25.7885714	69.4697619	-12.8316667	24.3395238	1.80623337
3 / 9 mL	71.2470238	-14.872381	43.9704762	69.9289286	-13.6890476	42.3436905	2.60516992

Por otra parte en la Tabla 4.20 se muestran los resultados del ΔE_{CMC} obtenidos para el segundo caso de estudio (3 pigmentos base). En la primer columna de esta se muestran los mililitros de pigmentos empleados en cada formulación, así como los valores de los vectores L , a^* , b^* para el estándar y las muestras generadas por las formulaciones obtenidas por la red, denominadas como lote. En la última columna se presentan los valores obtenidos para el ΔE_{CMC} para cada formulación generada para este caso de estudio.

Tabla 4.20: ΔE_{cmc} para 3 pigmentos

Formulación base	Estándar			Lote			ΔE_{cmc}
	L	a*	b*	L	a*	b*	
12 / 0 / 0 mL	79.5242857	-9.08571429	-4.36190476	79.7144048	-9.03630952	-4.34047619	0.37218136
0 / 12 / 0 mL	81.3007143	-3.98059524	42.1492857	81.0903571	-4.01130952	42.5364286	0.41765195
0 / 0 / 12 mL	58.7785714	34.9015476	12.8482143	58.7758333	34.7825	12.5683333	0.05548829

6 / 6 / 0 mL	79.2172619	-9.98261905	25.8155952	79.3247619	-10.2178571	26.1378571	0.22249448
6 / 0 / 6 mL	65.6995238	22.432619	6.37107143	65.8872619	22.4991667	6.3797619	0.36759552
0 / 6 / 6 mL	64.412619	27.0005952	20.6038095	64.5725	27.0121429	20.6177619	0.31289585
4 / 4 / 4 mL	66.8428571	18.8103571	15.560119	66.4917857	18.919881	15.5841667	0.68732988
8 / 2 / 2 mL	70.3136905	11.2790476	8.39702381	69.9120238	11.4233333	8.41988095	0.78648821
2 / 8 / 2 mL	69.7771429	17.6205952	26.1829762	69.3936905	17.7386905	26.3004762	0.75100531
2 / 2 / 8 mL	61.3825	30.0133333	14.687381	60.9778571	30.1665476	14.6475	0.79238637

Como se puede apreciar en las tablas anteriores, se consiguió un valor ΔE_{CMC} menor a 0.5 en la mayoría de las formulaciones obtenidas por la RNA. Los cálculos completos para este factor se muestran en el anexo 1.

4.2 Resultados del caso de aplicación

- *Generación y análisis de los datos colorimétricos*

Las mediciones realizadas en la empresa, se llevaron a cabo en 3 zonas del rollo de tela a analizar, el cual, en ambos casos, presento un total de 170 cm de ancho; en la Figura 4.8 se presenta el diagrama para la toma de dichos vectores de color; donde, la zona 1 correspondió al lado izquierdo de la tela, la zona 2 al centro y la zona 3 al lado derecho de la misma.

El procedimiento de medición se realizó a lo largo de la tela, en total, se tomaron 20 mediciones en espacios irregulares, obteniendo un total de 60 mediciones por tela analizada.

	1	2	3	
	L	L	L	1
	a^*	a^*	a^*	
	b^*	b^*	b^*	
	L	L	L	2
	a^*	a^*	a^*	
	b^*	b^*	b^*	

	L	L	L	21
	a^*	a^*	a^*	
	b^*	b^*	b^*	

|----- 170 cm -----|

Figura 4.8: Toma de muestras colorimétricas

En la Tabla 4.21 se muestra un ejemplo de la base de datos generada con las mediciones colorimétricas de la tela sin el proceso de teñido. En esta tabla podemos observar el valor medio y la desviación estándar de las mediciones, así como los valores máximos y mínimos correspondientes a cada uno de los vectores L , a^* , b^* de la misma.

En la parte superior de esta tabla, se indican el código correspondiente al rollo analizado para la tela blanca, por otra parte, los encabezados de cada columna indican el valor de la medición correspondiente a cada uno de los vectores de color, mientras que en la columna izquierda de la misma se señala el número de mediciones realizadas, así como la zona correspondiente a la toman de la misma.

Tabla 4.21: Resultado de las mediciones de la tela sin teñir

	Tela	Código		Código			Código		
	Teñido	914		914			914		
Número de muestra y zona de medición	L	a*	b*	L	a*	b*	L	a*	b*
1 Iz	92.9	-0.89	5.49	92.74	-1.07	6.62	92.23	-0.99	5.61
C	92.9	-0.89	5.56	92.27	-0.97	6.32	92.82	-0.97	5.62
D	90.78	-0.85	5.47	92.04	-1.04	6.12	92.73	-0.97	5.75
2 Iz	93	-0.9	5.48	92.51	-0.99	6.35	92.7	-0.94	5.55
C	92.87	-0.84	5.68	92.54	-1	6.55	92.81	-0.98	5.55
D	91.12	-0.88	5.7	92.21	-0.94	6.03	92.61	-0.97	5.67
3 Iz	92.68	-0.91	5.45	92.6	-1.02	6.58	92.94	-0.97	5.47
C	91.87	-0.94	5.48	92.66	-1.03	6.52	92.95	-0.98	5.58
D	90.54	-0.86	5.48	92.91	-1.06	5.99	92.72	-1	5.89
4 Iz	92.64	-0.93	5.78	92.56	-1.04	6.5	92.91	-0.97	5.51
C	90.98	-0.85	5.75	92.4	-1	6.35	92.9	-1	5.59
D	92.9	-0.88	5.65	92.91	-1.03	5.85	92.83	-1.01	5.77

Tabla 4.21: Resultado de las mediciones de la tela sin teñir

5 Iz	92	-0.92	5.69	92.41	-1.05	6.6	92.57	-1	5.51
C	92.64	-0.93	5.78	92.34	-1.04	6.23	93.05	-1.01	5.65
D	92.24	-0.91	5.79	93.07	-1.04	5.74	92.94	-1.01	5.7
6 Iz	91.9	-0.96	5.79	92.71	-1.05	6.56	92.55	-1	5.6
C	90.28	-0.87	5.74	92.73	-1.02	6.55	93.04	-1.01	5.52
D	92.91	-0.91	5.78	91.89	-1	5.78	92.96	-1.01	5.84
7 Iz	92.4	-0.93	5.54	92.68	-1.03	6.36	93.08	-1.04	5.58
C	91.2	-0.78	5.57	92.72	-1.03	6.49	93.14	-1.02	5.66
D	92.27	-0.87	5.67	92.52	-1.01	5.91	92.99	-1.02	5.83
8 Iz	91.91	-0.94	5.92	92.9	-1.05	6.34	92.16	-0.84	5.26
C	92.48	-0.92	5.87	92.78	-1.06	6.61	93.09	-1.01	5.73
D	92.98	-0.88	5.81	93.12	-1.06	6.04	92.91	-1.03	5.82
9 Iz	92.51	-0.96	5.94	92.71	-1.06	6.7	93.15	-1.02	5.65
C	92.3	-0.99	5.87	92.86	-1.03	6.24	93.14	-1.04	5.54
D	92.64	-0.99	6.1	92.94	-1.04	5.92	92.42	-0.92	5.55
10 Iz	91.68	-1	5.84	92.82	-1.08	6.52	93.14	-1.05	5.95
C	92.88	-0.97	5.99	92.9	-1.03	6.26	92.95	-1	5.55
D	92.69	-0.98	5.98	93.32	-1.07	5.77	92.92	-1.03	5.83

Continuación...

Tabla 4.21: Resultado de las mediciones de la tela sin teñir

11 Iz	93.22	-1.06	5.67	91.51	-1.93	6.49	91.71	-0.81	4.89
C	91.41	-1.83	6.39	92.62	-1	5.97	91.78	-0.76	4.78
D	92.52	-1	5.87	92.87	-1.08	5.74	90.65	-0.75	4.17
12 Iz	92.77	-1.06	5.7	92.41	-0.98	6.3	91.63	-0.75	4.83
C	92.31	-0.96	6.2	92.44	-0.9	6.55	91.45	-0.71	4.72
D	92.34	-0.8	6.45	92.11	-0.93	6.03	91.66	-0.73	4.69
13 Iz	92.01	-0.83	6	92.6	-1.02	6.58	91.62	-0.7	4.9
C	92.4	-1	6.48	92.66	-1.03	6.52	91.56	-0.66	4.74
D	92.56	-0.99	6.32	92.91	-1.06	5.99	91.72	-0.64	4.64
14 Iz	92.1	-1.1	5.89	92.56	-1.04	6.5	91.61	-0.63	4.92
C	92.46	-1.14	6.55	92.4	-1	6.35	91.25	-0.63	4.71
D	91.99	-1	6.25	92.91	-1.03	5.85	91.83	-0.44	5.15
15 Iz	92.81	-1.3	5.75	92.41	-1.05	6.6	92.52	-0.56	4.91
C	92.31	-1.1	6.4	92.34	-1.04	6.23	91.37	-0.5	4.78
D	91.99	-1.03	6.11	93.07	-1.04	5.74	90.66	-0.36	4.79
16 Iz	93	-1.04	5.64	92.71	-1.05	6.56	92.13	-0.33	4.68
C	92.61	-1	6.56	92.73	-1.02	6.55	91.99	-0.4	4.98
D	92.53	-0.99	6.45	91.89	-1	5.78	92	-0.35	4.58

Continuación...

Tabla 4.21: Resultado de las mediciones de la tela sin teñir

17 Iz	91.79	-1	5.68	92.68	-1.03	6.36	93.2	-0.3	4.5
C	97.5	-0.96	5.47	92.72	-1.03	6.49	92.58	-0.45	4.9
D	96.99	-0.99	5.54	92.52	-1.01	5.91	93	-0.48	4.87
18 Iz	97	-1	5.55	92.9	-1.05	6.34	91.99	-0.5	4.8
C	96.9	-0.98	5.34	92.78	-1.06	6.61	92	-0.48	4.44
D	96.57	-0.97	5.67	93.12	-1.06	6.04	91.97	-0.5	4.35
19 Iz	91.51	-1.93	6.49	92.71	-1.06	6.7	92.5	-0.45	4.35
C	92.62	-1	5.97	92.86	-1.03	6.24	93	-0.34	4.47
D	92.87	-1.08	5.74	92.94	-1.04	5.92	92.67	-0.56	5
20 Iz	92.87	-0.99	6.01	92.82	-1.08	6.52	92.9	-0.56	4.48
C	93	1	5.99	92.9	-1.03	6.26	93.45	-0.57	4.45
D	92.57	-1.19	5.98	93.32	-1.07	5.77	92.87	-0.3	4.36
Min	90.28	-1.93	5.34	91.51	-1.93	5.74	90.65	-1.05	4.17
Max	97.5	914	6.56	914	-0.9	6.7	914	-0.3	5.95
μ	92.6732759	14.51762712	5.85827586	106.558814	-1.04465517	6.27344828	106.344068	-0.77827586	5.19568966
Σ	1.48623437	119.1217921	0.32255633	106.932802	0.12340513	0.29881375	106.962724	0.24922433	0.50497216

Continuación...

Por otra parte en la

Tabla 4.22 se presentan los resultados de los vectores L , a^* , b^* correspondientes a la tela a

	Tela	Código/variante		Código/variante			Código/v
	Teñido	914	565	914	936		914
Número de muestra y zona de medición	L	a^*	b^*	L	a^*	b^*	L
1 Iz	63.54	1.33	4.05	46.67	1.57	-0.14	65.6
C	62.13	1.44	4.07	46.47	1.64	-0.19	65.12
D	63.51	1.29	4.07	46.48	1.52	-0.15	65.53
2 Iz	63.28	1.29	4.13	46.28	1.59	-0.1	65.13
C	62.31	1.39	4.04	46.25	1.68	-0.14	64.95
D	63.67	1.36	4.04	46.65	1.51	-0.1	65.29
3 Iz	63.27	1.42	4.05	45.94	1.58	-0.17	66
C	62.19	1.57	3.92	46.64	1.64	-0.21	65.82
D	63.26	1.49	3.93	46.53	1.54	-0.14	65.66
4 Iz	63.69	1.29	4.11	46.71	1.55	-0.16	65.96
C	62.29	1.33	4	46.61	1.54	-0.2	65.34
D	62.59	1.35	3.99	46.65	1.42	-0.13	65.38

la que se le aplicó el proceso de teñido. En esta tabla podemos observar el valor medio y la desviación estándar de las mediciones, así como los valores máximos y mínimos correspondientes a cada uno de los vectores L , a^* , b^* de la tela analizada.

Las mediciones fueron realizadas siguiendo el esquema señalado en la Figura 4.8. De manera similar al caso anterior, esta tela fue dividida en 3 zonas, donde la zona 1 correspondió al lado izquierdo, la zona 2 al centro y la zona 3 al lado derecho de dicha tela. El procedimiento de medición se realizó a lo largo de la tela, en intervalos irregulares, generando un total de 20 mediciones a lo largo de la tela analizada, obteniendo un total de 60 mediciones.

De mismo modo, en la parte superior de esta tabla, se indican el código correspondiente al rollo analizado para la tela teñida, así como la variante de color formulada para el proceso de teñido (código propio de la empresa), por otra parte los encabezados de cada columna indican

el valor de la medición correspondiente a cada uno de los vectores de color, mientras que en la columna izquierda de la misma se señala el número de mediciones realizadas, así como la zona correspondiente a la toman de la misma.

Tabla 4.22: Resultados de las mediciones de la tela teñida

	Tela	Código/variante		Código/variante			Código/variante		
	Teñido	914	565	914	936		914	936	
Número de muestra y zona de medición	L	a*	b*	L	a*	b*	L	a*	b*
1 Iz	63.54	1.33	4.05	46.67	1.57	-0.14	65.6	3.54	11.26
C	62.13	1.44	4.07	46.47	1.64	-0.19	65.12	3.55	11.27
D	63.51	1.29	4.07	46.48	1.52	-0.15	65.53	3.46	11.33
2 Iz	63.28	1.29	4.13	46.28	1.59	-0.1	65.13	3.58	11.37
C	62.31	1.39	4.04	46.25	1.68	-0.14	64.95	3.49	11.59
D	63.67	1.36	4.04	46.65	1.51	-0.1	65.29	3.5	11.48
3 Iz	63.27	1.42	4.05	45.94	1.58	-0.17	66	3.33	11.13
C	62.19	1.57	3.92	46.64	1.64	-0.21	65.82	3.3	11.12
D	63.26	1.49	3.93	46.53	1.54	-0.14	65.66	3.33	11.2
4 Iz	63.69	1.29	4.11	46.71	1.55	-0.16	65.96	3.28	11.12
C	62.29	1.33	4	46.61	1.54	-0.2	65.34	3.33	11.22
D	62.59	1.35	3.99	46.65	1.42	-0.13	65.38	3.36	11.28

Tabla 4.22: Resultados de las mediciones de la tela teñida

5 Iz	63.67	1.26	4.03	46.12	1.49	-0.22	66.02	3.27	11.23
C	62.65	1.36	3.99	45.68	1.51	-0.24	65.95	3.2	11.11
D	63.4	1.22	3.93	46.67	1.35	-0.18	65.74	3.21	11.16
6 Iz	60.6	1.39	3.94	46.49	1.46	-0.2	66.4	3.22	11.17
C	60.94	1.43	3.85	46.69	1.54	-0.24	65.87	3.24	11.13
D	60	1.52	4.06	46.94	1.44	-0.24	65.98	3.21	11.06
7 Iz	63.62	1.42	4.18	46.39	1.36	-0.2	66.37	3.22	11.12
C	62.73	1.48	4.04	46.52	1.53	-0.22	65.9	3.22	11.06
D	63.69	1.34	4.12	46.27	1.52	-0.25	65.55	3.21	11.06
8 Iz	63.95	1.29	4.15	47.12	1.41	-0.22	66.12	3.26	11.08
C	63	1.36	4.16	46.11	1.58	-0.3	66.18	3.23	11.06
D	63.85	1.27	4.21	46.64	1.5	-0.26	65.7	3.22	11.17
9 Iz	63.61	1.24	4.15	46.18	1.39	-0.32	65.97	3.23	11.02
C	62.49	1.32	4.13	46.57	1.53	-0.33	65.41	3.2	11.18
D	63.9	1.17	4.11	46.66	1.4	-0.2	65.93	3.19	11.17
10 Iz	64.1	1.25	4.14	46.73	1.46	-0.24	66.15	3.16	11.09
C	62.59	1.45	3.95	46.67	1.54	-0.29	65.84	3.1	11.12
D	63.37	1.25	4.64	46.97	1.38	-0.28	66.15	3.14	11.13

Continuación...

Tabla 4.22: Resultados de las mediciones de la tela teñida

11 Iz	63.5	1.23	4.16	46.46	1.44	-0.29	66	3.3	10.85
C	63.12	1.26	4.28	47.66	1.38	-0.3	65.99	3.27	10.79
D	62.99	1.19	4.11	46.17	1.49	-0.33	66.36	3.18	10.93
12 Iz	63.63	1.21	4.26	46.75	1.4	-0.26	66.65	3.15	10.8
C	63.31	1.24	4.29	46.62	1.56	-0.36	66.42	3.12	10.97
D	63.47	1.2	4.22	46.8	1.44	-0.27	66.53	3.13	11.01
13 Iz	62.93	1.18	4.22	46.73	1.45	-0.27	66.83	3.13	10.87
C	62.07	1.28	4.28	46.3	1.54	-0.32	66.08	3.2	10.94
D	63.29	1.19	4.16	46.9	1.42	-0.29	66.84	3.16	10.84
14 Iz	63.51	1.13	4.21	47.36	1.52	-0.19	66.76	3.12	10.85
C	63.17	1.15	4.28	46.29	1.48	-0.27	66.59	3.17	10.86
D	63.25	1.08	4.21	47.4	1.36	-0.2	66.76	3.2	10.92
15 Iz	62.62	1.11	4.24	46.78	1.49	-0.28	66.63	3.17	10.93
C	62.1	1.06	4.34	46.46	1.59	-0.3	66.43	3.18	10.92
D	62.43	1.23	4.2	46.91	1.38	-0.23	66.73	3.14	10.82
16 Iz	63.34	1.23	4.19	46.91	1.38	-0.23	67.1	3.13	10.76
C	63.29	1.25	4.22	47.36	1.46	-0.26	66.57	3.14	10.89
D	63.53	1.22	4.27	46.51	1.56	-0.31	66.45	3.11	10.85

Continuación...

Tabla 4.22: Resultados de las mediciones de la tela teñida

17 Iz	63.56	1.19	4.22	48.51	1.72	-0.26	66.87	3.1	10.83
C	63.45	1.12	4.18	46.76	1.61	-0.28	66.43	3.18	10.94
D	63.5	1.22	4.27	47.32	1.65	-0.35	66.59	3.18	10.95
18 Iz	63.27	1.11	4.25	47.69	1.63	-0.34	65.99	3.42	11.08
C	63	1.3	4.21	46.51	1.57	-0.38	67.08	3.37	11.09
D	62.99	1.19	4.18	47.98	1.59	-0.3	67.38	3.2	10.89
19 Iz	63.32	1.23	4.25	46.65	1.3	-0.29	66.21	3.44	10.92
C	62.9	1.33	3.98	46.52	1.46	-0.3	66.8	3.33	10.9
D	63.08	1.25	4.12	46.7	1.34	-0.33	67.05	3.38	11.01
20 Iz	62.99	1.24	4.25	46.68	1.39	-0.2	66.88	3.41	10.83
C	63.05	1.33	4.12	46.37	1.49	-0.27	66.65	3.29	10.93
D	63	1.29	4.22	46.8	1.6	-0.2	66.93	3.42	10.9
Min	60	1.06	3.85	45.68	1.3	-0.38	64.95	3.1	10.76
Max	64.1	1.57	4.64	48.51	1.72	-0.1	67.38	3.58	11.59
μ	63.0258621	1.279137931	4.14189655	46.7026667	1.49766667	-0.245333333	66.1931667	3.258333333	11.0426667
Σ	0.77765287	0.111674409	0.13167553	0.4776172	0.093833	0.06603714	0.55819167	0.12363378	0.17633622

Continuación...

- *Diseño y entrenamiento de la RNA BP*

Obtenidos los valores de los vectores L , a^* , b^* correspondiente a la tela teñida se prosiguió con el diseño y entrenamiento de una RNA BP. Para esto se siguieron los pasos señalados anteriormente.

En la Figura 4.9 se muestra la estructura de la red diseñada para el caso de aplicación, la cual consistió en 3 entradas (correspondientes a los vectores L , a^* , b^*), una capa oculta y 3 salidas (correspondientes a la formulación de la tela teñida analizada).




Figura 4.9: Estructura RNA BP. Caso de aplicación

Una vez diseñada la red se prosiguió con su proceso de entrenamiento, para el cual, se introdujo, en la aplicación NNTOOL del programa MATLAB, una matriz inversa de 121×3 , la cual corresponde a los vectores colorimétricos del espacio de color *CELAB*; y como salida una matriz inversa de 121×3 , correspondientes a los mililitros de pigmentos empleados para dicha tela teñida.

La capa oculta de la RNA BP desarrollada contiene 10 neuronas en la misma. En la Figura 4.10 se pueden observar las interacciones necesarias para el entrenamiento de la red, las cuales fueron un total de 7.

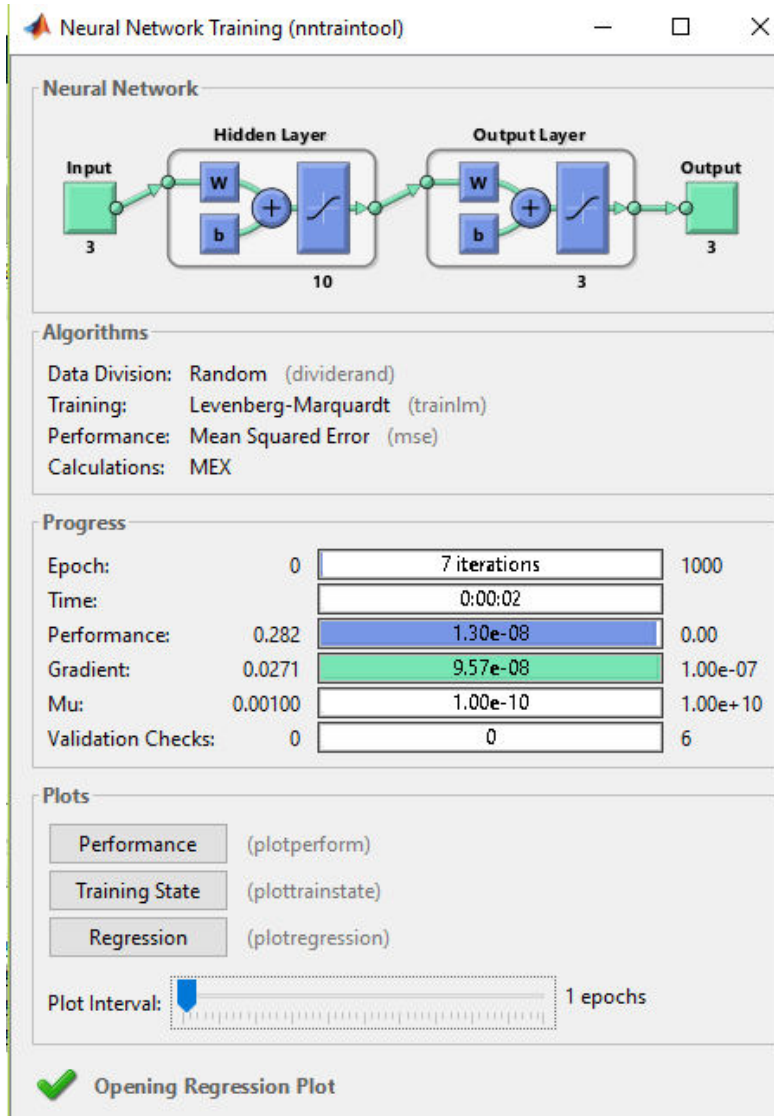


Figura 4.10: Ventana de entrenamiento RNA BP. Caso de aplicación

Los valores R generados al concluir el proceso de entrenamiento de dicha red fueron de 1; lo cual indica que ésta es capaz de cumplir con la función prevista.

5 Conclusiones

Los resultados obtenidos con el desarrollo del presente proyecto, se obtuvieron para telas fabricadas al cien por ciento a base de algodón, las cuales fueron teñidas con pigmentos tipo “reactivo”, los cuales son recomendados para este tipo de tela.

Con el presente trabajo, se consiguió probar que mediante la implementación de una red neuronal artificial de retro propagación es posible minimizar los errores de igualación de color en la industria textil. Lo anterior, mediante las estructuras analizadas para cada caso de estudio, se logró determinar la estructura de la red más conveniente. Para el caso de 2 pigmentos base en la formulación de color (caso de estudio 1) las cuatro estructuras analizadas emplearon entre 2 y 5 corridas de entrenamiento, obteniendo valores de R de 0.99776 a 0.99968; los cuales indican que la red se desempeña de una manera adecuada con cualquiera de las estructuras propuestas.

Para el segundo caso de estudios (3 pigmentos base) se emplearon de 10 a 20 corridas de entrenamiento para las cuatro estructuras de la RNA BP analizadas, obteniendo así valores de R de 0.99568 a 1; estos valores, al igual que en el caso anterior indican que la red se desempeña de manera adecuada para el problema analizado.

Las estructuras seleccionadas fueron, para el primer caso de estudio (2 pigmentos base), una RNA BP de arquitectura 3- 1 -2 con 5 neuronas en la capa oculta, mientras que para el segundo caso (3 pigmentos base), la RNA BP presentó una arquitectura 3 – 1- 3 con 10 neuronas en su capa oculta. La selección de estas estructuras correspondió al valor R más alto para cada una de las estructuras analizadas en los 2 casos de estudio.

Los resultados obtenidos, que validan el diseño elegido de las RNA's BP seleccionadas en el presente trabajo, muestran que los valores del ΔE_{CMC} para cada caso de estudio fue menores a 0.5 en la mayoría de las formulaciones obtenidas por cada RNA BP. Por otra parte, se puede observar que el número de pigmentos base empleado en cada uno de los casos de estudio genera un aumento en el grado de precisión de las formulaciones obtenidas, en el primer caso de estudio (2 pigmentos base; azul y amarillo), el 40 % de las formulaciones obtenidas

presentaron un valor de ΔE_{CMC} menor a 0.5; mientras que en el segundo caso de estudio, al aumentar un pigmento base (azul, amarillo y rojo) el porcentaje de formulaciones generadas por la RNA con valores de ΔE_{CMC} menores a 0.5 fue del 60%.

Como se puede observar, con un aumento en el número de pigmentos empleados en el proceso de teñido, la red presentó un mejor desempeño; por lo cual es recomendable analizar el comportamiento de las RNA's BP desarrolladas para otros tipos de telas fabricadas con concentraciones de fibras de algodón diferentes, así como para otro tipo de colorantes. Esto con el propósito de observar el comportamiento de la red bajo diferentes condiciones, y verificar si las redes son capaces de aumentar el porcentaje de formulaciones desarrolladas que presenten un valor ΔE_{CMC} menor a 0.5.

6 Anexos

Anexo 1. Portada del artículo publicado



N° 21, Vol. 10 (2), 2018. ISSN 2007 – 0705, pp.: 78 – 96
doi.org/10.21640/ns.v10i21.1507

Generación de la formulación de color en un producto textil mediante redes neuronales artificiales

Generation of color formulation in a textile product through Artificial Neural Networks

Laura Delia de Jesús Zavala Ortiz¹, José Antonio Vázquez López², Paloma Teresita Gutiérrez Rosas¹ y Moisés Tapia Esquivas¹

Palabras clave: color; proporción de color; redes neuronales; red de retro propagación; receta de color
Keywords: color; color proportion; neural networks; back propagation neural network; color recipe

Recepción: 21-05-2018 / Aceptación 19-07-2018

Resumen

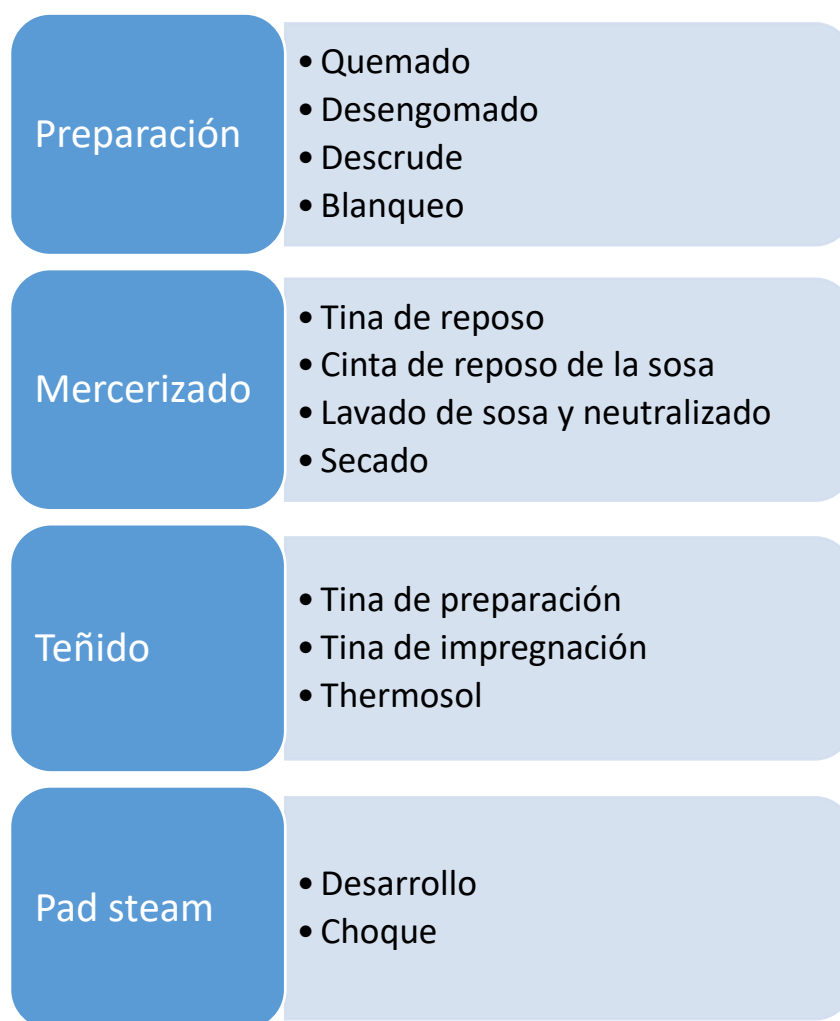
El color es una característica indispensable en la calidad de diversos productos, para lograr una apropiada coloración es necesario determinar la proporción de colorantes requeridos para conseguir una exacta coincidencia del color que se desea. En la industria textil, el desarrollo de una apropiada coloración es un estándar de calidad indispensable, ya que genera un impacto directo en el nivel de agrado de un producto. Actualmente en la industria textil, el desarrollo de la formulación de color depende de un maestro colorista, por lo que este proceso es altamente subjetivo, pues depende de la experiencia del colorista para lograr una coincidencia de color en función de su apreciación. A su vez, la evaluación visual del color depende de factores ambientales como: tipo de iluminación, la incidencia de la luz y el color de fondo empleado. Debido a la subjetividad y poca estandarización de la formulación del color en la industria textil, es necesario el desarrollo de nuevas técnicas que permitan generar formulaciones de color más exactas. Las redes neuronales artificiales (RNA) son herramientas inteligentes que pueden ser entrenadas para imitar la forma de trabajo de los coloristas, permitiendo así la minimización del error entre el color a desarrollar y un color objetivo. Con una RNA es posible generar recetas de color óptimas, de una manera más rápida y continua dentro de un proceso de fabricación. Para eliminar la subjetividad de la evaluación visual del color, la RNA puede ser alimentada con datos colorimétricos precisos del objeto bajo estudio. En el presente trabajo se presenta el uso de una RNA de retro propagación de 3 capas, que genera formulaciones de color para productos textiles a partir de coordenadas de color L , a^* , b^* proporcionadas por un colorímetro. El coeficiente de determinación R total obtenido por la RNA propuesta fue de 0.99776 obteniendo un medio cuadrado del error de 0.0016 y 0.0019 en mililitros respectivamente para los colorantes empleados.

¹ Departamento de Ingeniería Industrial, Tecnológico Nacional de México en Celaya, Celaya Guanajuato. E-mail: lauradelia.zavala.ortiz@gmail.com.mx

² Subdirección académica, Tecnológico Nacional de México en Celaya, Celaya Guanajuato.
© Universidad De La Salle Bajío (México)

Anexo 2. Proceso de producción del caso de aplicación

A continuación, se muestran las partes fundamentales del proceso de producción de la empresa en la cual se llevó acabo el caso de aplicación; este proceso consta de 4 fases.



Proceso de producción

La etapa de preparación de la tela, tiene como objetivo fundamental brindarle a la tela la capacidad de absorción de agua, la cual es indispensable en el proceso de teñido; esta etapa

requiere de 4 estaciones de trabajo, las cuales son el quemado, desengomado, descrude y blanqueo.

La siguiente etapa del proceso es el mercerizado; ésta tiene por objetivo el alineado de las líneas del tejido (denominadas como pie y trama), este proceso se hace con sosa; en esta etapa la fibra tiene un proceso de hinchamiento, esto se genera con el fin de fijar las dimensiones del tejido.

El proceso de mercerizado se lleva a cabo en 4 estaciones, las cuales son la tina de impregnación de sosa, cinta de reposo, lavado de sosa y neutralizado y finalmente el secado de la tela.

La tercer etapa del proceso de producción es el teñido de la tela, en esta etapa se distinguen 2 tipos de teñido, el teñido normal, el cual se emplea en tela 100% algodón, y el teñido Termo fijado, el cual se emplea en telas que son el producto de mezclas de diferentes fibras. Ambos tipos de teñido se realizan en 3 estaciones de trabajo, las cuales son tina de preparación, tina de impregnación y el thermosol.

La última etapa del proceso de producción se denomina “Pad Steam”, esta tiene como objetivo brindar el acabado final a la tela teñida. Dependiendo del tipo de colorante empleado en el proceso de teñido, se da el acabado final al matiz de la tela, este acabado se puede dar por medio de un tratamiento de desarrollo; para telas teñidas con colorantes reactivos y dispersos; o por un proceso de choque; empleado para modificar la intensidad y el matiz de la tela teñida por colorantes tipo cubas.

Anexo 2. Tablas ANOVA y Graficas de los análisis de los casos de estudio.

En este anexo se muestran los ANOVA's y graficas de intervalos generados para cada uno de los casos de estudio del presente trabajo

ANOVA's y graficas de intervalos para 2 pigmentos

A continuación se muestran los ANOVA's generados para cada formulación propuesta en la Tabla 3.1, correspondientes al primer caso de estudio, así como las gráficas de intervalos correspondientes a cada formulación. En este caso, los análisis ANOVA's permiten ver una diferencia significativa en el factor muestra para cada formulación generada.

Muestras: 1, 6, 11, 16. 2 pigmentos

Análisis de varianza L					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	23.544	7.8481	9.86	0.000
Bloque	1	11.708	11.7079	14.71	0.000
Error	163	129.758	0.7961		
Falta de ajuste	3	7.236	2.4121	3.15	0.027
Error puro	160	122.521	0.7658		
Total	167	165.010			
Análisis de varianza a*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	40.7862	13.5954	53.03	0.000
Bloque	1	0.1147	0.1147	0.45	0.504
Error	163	41.7887	0.2564		
Falta de ajuste	3	1.7651	0.5884	2.35	0.074
Error puro	160	40.0236	0.2501		
Total	167	82.6897			
Análisis de varianza b*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	54.752	18.2506	33.33	0.000
Bloque	1	1.848	1.8480	3.37	0.068
Error	163	89.258	0.5476		
Falta de ajuste	3	3.568	1.1894	2.22	0.088
Error puro	160	85.689	0.5356		
Total	167	145.857			

Muestras: 2, 7, 12, 18. 2 pigmentos

Análisis de varianza L					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	8.166	2.7221	4.33	0.006
Bloque	1	2.167	2.1669	3.45	0.065
Error	163	102.456	0.6286		
Falta de ajuste	3	1.085	0.3616	0.57	0.635
Error puro	160	101.371	0.6336		
Total	167	112.789			
Análisis de varianza a*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	1.5677	0.5226	3.22	0.024
Bloque	1	0.2530	0.2530	1.56	0.213
Error	163	26.4251	0.1621		
Falta de ajuste	3	0.1212	0.0404	0.25	0.864
Error puro	160	26.3039	0.1644		
Total	167	28.2459			
Análisis de varianza b*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	25.346	8.4486	8.83	0.000
Bloque	1	4.808	4.8077	5.02	0.026
Error	163	156.044	0.9573		
Falta de ajuste	3	0.977	0.3257	0.34	0.799
Error puro	160	155.067	0.9692		
Total	167	186.198			

Muestra: 3, 8, 13, 17. 2 pigmentos

Análisis de varianza L					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	9.4444	9.4444	16.00	0.000
Bloque	1	0.1005	0.1005	0.51	0.476
Error	163	32.0645	0.1967		
Falta de ajuste	3	1.8312	0.6104	3.23	0.024
Error puro	160	30.2333	0.1890		
Total	167	41.6094			
Análisis de varianza a*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	12.4744	4.15815	42.36	0.000
Bloque	1	0.0477	0.047 67	0.49	0.487
Error	163	15.9991	0.09815		
Falta de ajuste	3	0.4747	0.15825	1.63	0.184
Error puro	160	15.5243	0.09703		
Total	167	28.5212			
Análisis de varianza b*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	8.162	7.7207	3.86	0.011
Bloque	1	3.694	3.6935	5.24	0.023
Error	163	1114.799	0.7043		
Falta de ajuste	3	8.671	2.8904	4.36	0.006
Error puro	160	106.128	0.6633		
Total	167	126.655			


Muestra 4, 9, 14, 19. 2 pigmentos

Análisis de varianza L					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	141.675	47.2255	42.67	0.000
Bloque	1	34.626	34.6257	31.28	0.000
Error	163	180.412	1.1068		
Falta de ajuste	3	2.081	0.9336	0.84	0.473
Error puro	160	177.611	1.1101		
Total	167	356.713			
Análisis de varianza a*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	7.399	2.4662	6.76	0.000
Bloque	1	45.917	45.9173	125.94	0.000
Error	163	59.430	0.3646		
Falta de ajuste	3	0.313	0.1043	0.28	0.838
Error puro	160	59.117	0.3695		
Total	167	112.746			
Análisis de varianza b*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	98.479	32.8263	33.00	0.000
Bloque	1	88.189	88.189	88.67	0.000
Error	163	162.125	0.9946		
Falta de ajuste	3	1.430	0.4765	0.47	0.701
Error puro	160	160.695	1.0043		
Total	167	348.793			


Muestra 5, 10, 15, 20. 2 pigmentos

Análisis de varianza L					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	22.330	7.4434	9.73	0.000
Bloque	1	72.970	72.9698	95.35	0.000
Error	163	124.740	0.7653		
Falta de ajuste	3	0.486	0.1619	0.21	0.890
Error puro	160	124.254	0.7766		
Total	167	220.040			
Análisis de varianza a*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	4.384	1.4615	2.67	0.049
Bloque	1	58.812	58.8117	107.49	0.000
Error	163	89.181	0.5471		
Falta de ajuste	3	0.309	0.1030	0.19	0.906
Error puro	160	88.872	0.5555		
Total	167	152.378			
Análisis de varianza b*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	8.634	2.878	1.30	0.275
Bloque	1	111.150	111.150	50.35	0.000
Error	163	359.849	2.08		
Falta de ajuste	3	2.409	0.803	0.36	0.782
Error puro	160	357.440	2.234		
Total	167	479.633			


12 mL azul / 0 mL amarillo




0 mL azul / 12 mL amarillo




6 mL azul / 6 mL amarillo



9 mL azul / 3 mL amarillo



3 mL azul / 9 mL amarillo



ANOVA's y gráficas para las formulaciones de 3 pigmentos.

Así mismo, a continuación, se muestran los ANOVA's generados para cada formulación propuesta en la Tabla 3.2, correspondientes al segundo caso de estudio, así como las gráficas de intervalos correspondientes a cada formulación.

En los análisis ANOVA's se puede observar la presencia de una diferencia significativa en la variable muestra para cada una de las muestras generadas en los vectores L , a^* y b^* en las muestras generadas. Con excepción de las muestras 4, 14, 24, 34; donde solo se aprecian estas diferencias significativas en los vectores L y b^* y en las muestras 6, 16, 26, 36, donde solo se presenta esta diferencia en los vectores L y a^*

Muestras 1, 11, 21, 31. 3 pigmentos

Análisis de varianza L					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	12.4515	4.1505	41.31	0.000
Bloque	1	1.5181	1.5181	15.11	0.000
Error	163	16.3782	0.10048		
Falta de ajuste	3	0.226	0.07535	0.75	0.526
Error puro	160	16.1522	0.10095		
Total	167	30.3478			
Análisis de varianza a*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	3.2648	1.08828	17.37	0.000
Bloque	1	0.1025	0.10251	1.64	0.203
Error	163	10.2108	0.06264		
Falta de ajuste	3	0.0332	0.01108	0.17	0.914
Error puro	160	10.1775	0.06361		
Total	167	13.5781			
Análisis de varianza b*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	2.9962	0.99872	5.25	0.002
Bloque	1	0.0193	0.01929	0.1	0.751
Error	163	31.0193	0.1903		
Falta de ajuste	3	0.2034	0.0678	0.35	0.788
Error puro	160	30.8159	0.1926		
Total	167	34.0348			

Muestras 2, 12, 22, 32. 3 pigmentos.

Análisis de varianza L					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	7.9193	2.63978	28.07	0.000
Bloque	1	1.8585	1.85851	19.76	0.000
Error	163	15.3279	0.09404		
Falta de ajuste	3	0.0638	0.02127	0.22	0.88
Error puro	160	15.2641	0.0954		
Total	167	25.1058			
Análisis de varianza a*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	0.82846	0.27615	9.17	0.000
Bloque	1	0.03962	0.03962	1.32	0.253
Error	163	4.90916	0.03012		
Falta de ajuste	3	0.16941	0.05647	1.91	0.131
Error puro	160	4.73975	0.02962		
Total	167	5.7725			
Análisis de varianza b*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	74.223	24.7411	34.44	0.000
Bloque	1	6.2949	6.2949	8.76	0.004
Error	163	117.107	0.7184		
Falta de ajuste	3	2.54	0.8467	1.18	0.318
Error puro	160	114.567	0.716		
Total	167	197.625			

Muestras: 3, 13, 23, 33. 3 pigmentos.

Análisis de varianza L					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	21.5399	7.17998	36.46	0.000
Bloque	1	0.0003	0.00031	0.00	0.968
Error	163	32.1033	0.19695		
Falta de ajuste	3	0.2277	0.07588	0.38	0.767
Error puro	160	31.8757	0.19922		
Total	167	53.6436			
Análisis de varianza a*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	10.3956	3.46518	18.4	0.000
Bloque	1	0.5952	0.59524	3.16	0.077
Error	163	30.6941	0.18831		
Falta de ajuste	3	0.0271	0.00904	0.05	0.986
Error puro	160	30.667	0.19167		
Total	167	41.6849			
Análisis de varianza b*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	7.2166	2.40554	26.58	0.000
Bloque	1	3.29	3.29	36.35	0.000
Error	163	14.7546	0.09052		
Falta de ajuste	3	0.0343	0.01144	0.12	0.946
Error puro	160	14.7202	0.092		
Total	167	25.2612			

Muestras: 4, 14, 24, 34. 3 pigmentos

Análisis de varianza L					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	8.733	2.911	32.45	0.000
Bloque	1	0.4854	0.48536	5.41	0.021
Error	163	14.6236	0.08972		
Falta de ajuste	3	0.0709	0.02363	0.26	0.854
Error puro	160	14.5527	0.09095		
Total	167	23.8419			
Análisis de varianza a*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	0.731	0.2438	0.09	0.967
Bloque	1	2.324	2.3242	0.83	0.363
Error	163	455.642	2.7953		
Falta de ajuste	3	8.741	2.9138	1.04	0.375
Error puro	160	446.9	2.7931		
Total	167	458.697			
Análisis de varianza b*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	16.3874	5.46247	31.15	0.000
Bloque	1	4.3618	4.36181	24.88	0.000
Error	163	28.5815	0.1735		
Falta de ajuste	3	0.137	0.04566	0.26	0.856
Error puro	160	28.4445	0.17778		
Total	167	49.3307			

Muestras: 5, 15, 25, 35. 3 pigmentos.

Análisis de varianza L					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	12.7719	4.2573	11.22	0.000
Bloque	1	1.4803	1.4803	3.9	0.05
Error	163	61.8594	0.3795		
Falta de ajuste	3	0.832	0.2773	0.73	0.537
Error puro	160	61.0274	0.3814		
Total	167	76.1116			
Análisis de varianza a*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	20.7372	6.91241	17.12	0.000
Bloque	1	0.186	0.186	0.46	0.498
Error	163	65.8318	0.40388		
Falta de ajuste	3	0.1771	0.05903	0.14	0.933
Error puro	160	65.6548	0.41034		
Total	167	86.7551			
Análisis de varianza b*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	3.1453	1.04843	13.09	0.000
Bloque	1	0.0032	0.00317	0.04	0.842
Error	163	13.0529	0.08008		
Falta de ajuste	3	0.9984	0.33281	4.42	0.005
Error puro	160	12.0545	0.07534		
Total	167	16.2014			

Muestras: 6, 16, 26, 36. 3 pigmentos.

Análisis de varianza L					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	10.2278	3.40927	18.05	0.000
Bloque	1	1.0736	1.0736	5.68	0.018
Error	163	30.7878	0.18888		
Falta de ajuste	3	0.2457	0.08192	0.43	0.732
Error puro	160	30.542	0.19089		
Total	167	42.0892			
Análisis de varianza a*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	5.0698	1.68994	5.48	0.001
Bloque	1	0.0056	0.0056	0.02	0.893
Error	163	50.2641	0.30837		
Falta de ajuste	3	0.1542	0.05139	0.16	0.92
Error puro	160	50.1099	0.31319		
Total	167	55.3395			
Análisis de varianza b*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	0.8199	0.2732	1.87	0.137
Bloque	1	0.0082	0.0081	0.06	0.813
Error	163	23.8534	0.1463		
Falta de ajuste	3	0.774	0.2579	1.79	0.151
Error puro	160	23.0794	0.144246		
Total	167	24.6814			

Muestras: 7, 17, 27, 37. 3 pigmentos

Análisis de varianza L					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	30.644	10.2148	55.43	0.000
Bloque	1	5.177	5.1765	28.09	0.000
Error	163	30.037	0.1843		
Falta de ajuste	3	4.189	1.3963	8.64	0.000
Error puro	160	25.849	0.1616		
Total	167	65.858			
Análisis de varianza a*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	24.1525	8.0508	45.51	0.000
Bloque	1	0.5038	0.5038	2.85	0.093
Error	163	28.8323	0.1768		
Falta de ajuste	3	0.1552	0.0517	0.29	0.834
Error puro	160	28.6771	0.1729		
Total	167	53.4886			
Análisis de varianza b*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	23.5589	7.8529	46.71	0.000
Bloque	1	0.0243	0.0242	0.14	0.704
Error	163	27.4067	0.1681		
Falta de ajuste	3	0.1546	0.0515	0.3	0.823
Error puro	160	27.252	0.1703		
Total	167	50.9898			

Muestras: 8, 18, 28, 38. 3 pigmentos.

Análisis de varianza L					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	20.8653	6.9551	33.01	0.000
Bloque	1	6.7761	6.7761	31.16	0.000
Error	163	34.3446	0.2107		
Falta de ajuste	3	0.0072	0.0023	0.01	0.998
Error puro	160	34.3375	0.2146		
Total	167	61.986			
Análisis de varianza a*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	23.1023	7.7007	32.39	0.000
Bloque	1	0.8744	0.8743	3.68	0.057
Error	163	38.7498	0.2377		
Falta de ajuste	3	0.1068	0.0356	0.15	0.931
Error puro	160	38.643	0.2415		
Total	167	62.7266			
Análisis de varianza b*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	5.3478	1.7825	10.23	0.000
Bloque	1	0.0219	0.0219	0.13	0.723
Error	163	28.4151	0.1743		
Falta de ajuste	3	0.006	0.002	0.01	0.998
Error puro	160	28.409	0.1775		
Total	167	33.7848			


Muestras: 9, 19, 29, 39. 3 pigmentos

Análisis de varianza L					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	3.476	1.1586	9.66	0.000
Bloque	1	6.1755	6.1755	51.5	0.000
Error	163	19.5454	0.1199		
Falta de ajuste	3	0.1917	0.0639	0.53	0.663
Error puro	160	19.3537	0.1209		
Total	167	29.197			
Análisis de varianza a*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	17.7587	5.9195	38.48	0.000
Bloque	1	0.5858	0.5875	3.81	0.053
Error	163	25.0776	0.1538		
Falta de ajuste	3	0.0582	0.0193	0.12	0.946
Error puro	160	25.0195	0.1563		
Total	167	43.422			
Análisis de varianza b*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	48.865	16.2882	46.8	0.000
Bloque	1	0.58	0.5799	1.67	0.199
Error	163	56.731	0.348		
Falta de ajuste	3	0.55	0.1834	0.52	0.668
Error puro	160	56.181	0.3511		
Total	167	106.175			


Muestras: 10, 20, 30, 40. 3 pigmentos

Análisis de varianza L					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	31.8163	10.605	92.05	0.000
Bloque	1	6.8769	6.8769	59.69	0.000
Error	163	18.7789	0.1152		
Falta de ajuste	3	0.0829	0.0276	0.24	0.871
Error puro	160	18.696	0.1169		
Total	167	57.4721			
Análisis de varianza a*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	17.6293	5.8764	58.68	0.000
Bloque	1	0.9859	0.9859	9.85	0.002
Error	163	16.3221	0.1001		
Falta de ajuste	3	0.0109	0.0036	0.04	0.991
Error puro	160	16.3112	0.1019		
Total	167	34.9373			
Análisis de varianza b*					
Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Muestra	3	26.5777	8.8592	38.18	0.000
Bloque	1	0.0668	0.0668	0.29	0.592
Error	163	37.8195	0.232		
Falta de ajuste	3	0.0136	0.0045	0.02	0.996
Error puro	160	37.8058	0.2362		
Total	167	64.464			


12 mL azul / 0 mL amarillo / 0 mL rojo.




0 mL azul / 12 mL amarillo / 0 mL rojo.




0 mL azul / 0 mL amarillo / 12 mL rojo.




6 mL azul / 6 mL amarillo / 0 mL rojo.




6 mL azul / 0 mL amarillo / 6 mL rojo.




0 mL azul / 6 mL amarillo / 6 mL rojo.




4 mL azul / 4 mL amarillo / 4 mL rojo.




8 mL azul / 2 mL amarillo / 2 mL rojo.



2 mL azul / 8 mL amarillo / 2 mL rojo.



2 mL azul / 2 mL amarillo / 8 mL rojo.



Anexo 3: Cálculos del ΔE_{CMC} para ambos casos de estudio

A continuación se presentan los cálculos realizados para la obtención del ΔE_{CMC} para los casos de estudio; en la primera tabla se muestran los resultados obtenidos para las formulaciones propuestas en la Tabla 3.1; mientras que en la siguiente tabla se muestran los resultados correspondientes a las formulaciones presentadas en la Tabla 3.2.

Cálculos ΔE_{cmc} . 2 pigmentos

Formulación	Estándar			Lote				ΔL	Δa^*	Δb^*	$\Sigma \Delta 2$	
0 / 12 mL	78.3 409	0.40 14	62.67 82	78.29 20	0.435 1	62.974 7		- 0.048 9	0.033 6	0.296 5	0.09 14	
12 / 0 mL	71.8 020	- 6.03 58	- 12.09 22	71.27 40	- 6.088 0	- 12.302 0		- 0.527 9	- 0.052 2	- 0.209 7	0.32 54	
6 / 6 mL	70.9 128	- 15.2 920	34.28 28	70.68 57	- 15.36 96	34.621 1		- 0.227 1	- 0.077 6	0.338 3	0.17 20	
9 / 3 mL	70.3 777	- 13.8 772	25.78 85	69.46 97	- 12.83 16	24.339 5		- 0.907 9	1.045 5	- 1.449 0	4.01 74	
3 / 9 mL	71.2 470	- 14.8 723	43.97 04	69.92 89	- 13.68 90	42.343 6		- 1.318 0	1.183 3	- 1.626 7	5.78 40	
ΔE_{cmc}	ΔH^*	ΔE_{ab}^*	ΔC^*	SL	Sc	C*	SH	F	T	h'	Kl	Kc
0.1100	0.03 17	0.30 24	0.296 7	0.511	5.508 2	62.679 4	5.50 76	0.000 2	0.579 3	1.564 13942	1	1
1.0339	0.04 65	0.57 05	0.211 1	0.511	5.508 2	13.514 9	5.49 54	0.005 1	0.551 9	1.109 5	1	1
0.4489	0.06 66	0.41 48	0.340 6	0.511	5.508 22	37.538 7	5.50 50	0.000 7	0.191 6	- 1.152 1	1	1
1.8062	0.24 15	2.00 43	- 1.770 5	0.511	5.508 22	29.285 3	5.50 30	0.001 1	0.196 9	- 1.081 3	1	1
2.6051	0.61 25	2.40 50	- 1.916 1	0.511	5.508 22	46.417 5	5.50 61	0.000 4	0.185 9	- 1.251 3	1	1

Cálculos ΔE_{cm} . 3 pigmentos

Formulación	Estándar			Lote				ΔL	Δa^*	Δb^*	$\Sigma \Delta 2$	
12 / 0 / 0 mL	79.52 42	- 9.085 7	- 4.361 9	79.71 44	- 9.036 3	- 4.3404		0.190 1	0.049 4	0.021 4	0.0390	
0 / 12 / 0 mL	81.30 07	- 3.980 5	42.14 92	81.09 03	- 4.011 3	42.536 4		- 0.210 3	- 0.030 7	0.387 1	0.1950	
0 / 0 / 12 mL	58.77 85	34.90 15	12.84 82	58.77 58	34.78 25	12.568 3		- 0.002 7	- 0.119 0	- 0.279 8	0.0925	
6 / 6 / 0 mL	79.21 72	- 9.982 6	25.81 55	79.32 47	- 10.21 78	26.137 8		0.107 5	- 0.235 2	0.322 2	0.1707	
6 / 0 / 6 mL	65.69 95	22.43 26	6.371 0	65.88 72	22.49 91	6.3797		0.187 7	0.066 5	0.008 6	0.0397	
0 / 6 / 6 mL	64.41 26	27.00 05	20.60 38	64.57 25	27.01 21	20.617 7		0.159 8	0.011 5	0.013 9	0.0258	
4 / 4 / 4 mL	66.84 28	18.81 03	15.56 01	66.49 17	18.91 98	15.584 1		- 0.351 0	0.109 5	0.024 0	0.1358	
8 / 2 / 2 mL	70.31 36	11.27 90	8.397 0	69.91 20	11.42 33	8.4198		- 0.401 6	0.144 2	0.022 8	0.1826	
2 / 8 / 2 mL	69.77 71	17.62 05	26.18 29	69.39 36	17.73 86	26.300 4		- 0.383 4	0.118 0	0.117 5	0.1747	
2 / 2 / 8 mL	61.38 25	30.01 33	14.68 73	60.97 78	30.16 65	14.647 5		- 0.404 6	0.153 2	- 0.039 8	0.1888	
ΔE_{cm} c	ΔH^*	ΔE_{ab} *	ΔC^*	SL	Sc	C*	SH	F	T	h'	Kl	Kc
0.3721	0.002 0	0.197 5	- 0.053 8	0.511	5.508 2	10.078 5	5.48 31	0.008 3	0.452 7	0.447 6	1	1
0.4176	0.005 7	0.441 6	0.388 3	0.511	5.508 2	42.336 8	5.50 57	0.000 5	0.180 0	- 1.476 7	1	1
0.0554	0.222 1	0.304 1	- 0.207 7	0.511	5.508 2	37.191 3	5.50 59	0.000 7	0.434 2	0.349 7	1	1
0.2224	0.102 4	0.413 2	0.385 6	0.511	5.508 2	27.678 4	5.50 24	0.001 3	0.188 6	- 1.199 9	1	1
0.3675	0.009 8	0.199 3	0.066 3	0.511	5.508 2	23.319 7	5.50 23	0.001 8	0.419 9	0.276 5	1	1
0.3128	0.004 0	0.160 9	0.017 6	0.511	5.508 2	33.963 9	5.50 57	0.000 8	0.489 0	0.651 8	1	1
0.6873	0.051 1	0.368 5	0.099 7	0.511	5.508 2	24.412 0	5.50 35	0.001 6	0.495 3	0.690 0	1	1
0.7864	0.067 5	0.427 4	0.129 5	0.511	5.508 2	14.061 5	5.49 45	0.004 8	0.486 6	0.637 5	1	1

0.7510	0.032 2	0.418 0	0.163 4	0.511	5.508 2	31.560 0	5.50 56	0.001 0	0.537 0	0.977 9	1	1
0.7923	0.102 9	0.434 5	0.120 2	0.511	5.508 2	33.414 3	5.50 55	0.000 8	0.453 8	0.453 5	1	1

7 Bibliografía

- Aldabe, S., Bonazzola, C., Aramendía, P., & Lacreu, L. (2004). *Química 2, química en acción*. Argentina: Ediciones Colihue.
- Almodarresi, E. S., Mokhtari, J., Mohammad Taghi Almodarresi, S., Nouri, M., & Shams Nateri, A. (2013). A scanner based neural network technique for color matching of dyed cotton with reactive dye. *Fibers and polymers*, 14(7), 1196-1202.
- Amirshahi, S. H., Latifi, M., & Shams Nateri, A. (2002). Color matching of blends prepared from black and white fibers by neural networks. *International Journal of Engineering-Transactions B: Applications*, 15(1), 105-108.
- Artigas, J. (2002). *Fundamentos de colorimetría*. Valencia, España: Universitat Valencia.
- Artigas, J. M., Capilla, P. P., & Pujol, R. J. (2002). *Tecnología del color*. Valencia, España: Universitat de valencia servivio de publicaciones.
- Berns, R. S. (2000). *Billmeyer and Saltman's Principales of color technology* (3ra ed.). New York, USA: John Wiley & Sons.
- Bishop, J. M., Bushnell, M. J., & Westland, S. (1991). Application of neural network to computer recipe prediction. *Color research and application*, 16(1), 3-9.
- Breyfogle, F. W. (2003). *Implementing six sigma* (Vol. 2). Austin, Texas, USA: Wiley.
- Chiñas-Sánchez, P., López-Juárez, I., & Vázquez-López, J. A. (2014). Reconocimiento de variables multivariantes empleando el estadístico T^2 Hotelling y MEWMA mediante RNA'S. *Ingeniería Investigación y Tecnología*, 15(1), 125- 138.
- Farrell, M. J., Ankeny, M. A., & Hauser, P. J. (2014). Prediction of recipes for cotton cationisation and reactive dyeing to shade match conventionally dyed cotton. *Coloration Technology, society of dyers and colourists*, 130(5), 363- 367.
- Fausett, L. (1993). *Fundamentals of neural networks, architectures, algorithms and applications*. New jersey, USA: Prentice- Hall.

- Flórez, L. R., & Fernández, F. J. (2008). *Las redes neuronales artificiales: fundamentos teoricos y aplicaciones practicas*. La Coruña, Oleiros, España: Netbiblo.
- Furferi, R., & Carfagni, M. (2010). An as short as possible mathematical assessment of spectrophotometric color matching. *Journal of Applied Sciences*, 10(18), 2108-2114.
- Gorji Kandi, S., Ameri, F., & Khalili, N. (2012). Instrument dependency of Kubelka- Munk theory in computer color matching. *Progress in color, colorants and coatings*, 5(2), 85-90.
- Guisande González, C., Barreiro Felpeto, A., Manerio Estraviz, I., Rivero Alarcón, I., Vergara Castaño, A. R., & Vaamonde Liste, A. (2007). *Tratamiento de datos*. España: Diaz de Santos.
- Gutiérrez-Rosas, P. T., Vázquez-López, J. A., Yáñez Mendiola, J., & López-Juárez, I. (2015). Color's measurement and discrimination, of a cosmetic product by an artificial vision system. *2015 CHILEAN Conference on Electrical, Electronics Engineering, Information and Communication Technologies*, 803-808.
- Hagan, M. T., Demuth, H. B., & Beale, M. H. (2016). *Neural network desing*. Boston, Massachusetts: PWS Publishing Company.
- Haykin, S. S. (2016). *Neural Networks and learning machines* (3ra ed.). Hamilton, Ontario, Canada: Pearson.
- Jeyaraj, K., Muralidharan, C., Senthilvelan, T., & Deshmunkh, S. G. (2013). Development of artificial neural network and non linear regression model of color fast finish process a textile case study. *European journal of scientific research*, 102(1), 94-111.
- Kandi, G. S., Armeri, F., & Khalili, N. (2012). Instrument Dependency of Kubelka- Munk theory in computer color matching. *Progress in color, colorants and coatings*, 5(2), 85-90.
- Lee, W., & Sato, M. (2001). Visual perception of texture of textiles. *Color Research and Application*, 26(6), 469-477.

- Li, P. F., Wang, J., & Jing, J.-f. (2015). Application of improved back propagation algorithm in color difference detection of fabric. *Color Research and Application*, 40(3), 311-317.
- Lockuán, L. F. (2012). *La industria textil y su control de calidad tintorería*. España.
- Mangine, H., Jakes, K., & Noel, C. (2005). A preliminary comparison of CIE color differences to textile color acceptability using average observers. *Color research and application*, 30(4), 288-294.
- Martínez, M. S., & Celemín V, A. y. (Septiembre de 2012). Estudio sobre la fiabilidad de medición del espectrofotómetro dental Vita Easysshade Compact (Vita-Zahnfabrik).
- Montgomery, D. C., & Runger, G. C. (2012). *Probabilidad y Estadística aplicadas a la ingeniería*. Mexico DF, Mexico: Limusa Wiley.
- Olsen, E. D. (2003). *Métodos ópticos de análisis*. Barcelona: Reverté.
- Pérez-Alvarez, J., Fernández-López, J., & Rosmini, M. (2004). Chapter 13 Chemical and Physical Aspects of Color in frozen Muscle- Based foods. En Y. Hui, G. I. Legarretta, M. H. LIM, K. Murrell, & W. K. Nid, *Handbook of frozen foods* (Vol. 133). New York: Marcel Dekker Inc.
- Pino, D. R., Gómez, G. A., & de Abajo Martínez, N. (2001). *Introducción a la inteligencia artificial, sistemas expertos redes neuronales artificiales y computación evolutiva*. Oviedo, Asturias, España: Servicio de publicaciones, Universidad de Oviedo.
- Rahman Bhuiyan, M., Mizanur Rahman, M., Shaid, A., & Khan, M. (2014). Application of gamma irradiated textile wastewater for the pretreatment of cotton fabric. *Environmenta and ecology research*, 2(3), 149- 152.
- Rautenberg, S., & Todesco, J. L. (2006). Color recipe specification in textile print shop using radial basis function networks. *Engineering Applications of Bio-Inspired Artificial Neural Networks. IWANN 1999. Lecture Notes in Computer Science*, 1607, 884-892.
- Shamin Reza, M., Haque, A., Azim, A., Hoque Azizul, S., & Mishuk Islam, A. (2014). Color Build up on jute fabric with reactive dye after bleaching and mercerizing.

International Journal of Advanced Engineering Research and Science (IJAERS),
1(2), 58-62.

Sungmin, K., Jong, P. H., & Chang, K. P. (2015). Development of a color matching algorithm for digital transfer textile printing using an artificial neural network and multiple regression. *Textile Research Journal*, 85(10), 1076-1082.

Westland, S., Ivone, L., & Bishop, J. M. (2002). Kubelka- Munk or neural networks for computer colorant formulation? *9th Congress of the international color association proceedings of SPI*, 4421(1), 745-748.

Yang, Y., Ma, H., Yang, Q., Zhang, C., & Shen, J. (2018). Recipe prediction of mélange yarn using modular artificial neural network. *Journal of the Textile Institute*, 109(5), 629-635.