

CARACTERIZACIÓN CROMÁTICA DE UN
ESCÁNER POR MEDIO DE REGRESIÓN
POLINOMIAL MÚLTIPLE Y REDES NEURONALES ARTIFICIALES

Juan Carlos Quijano Rojas

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE CIENCIAS
ESCUELA DE FÍSICA
BUCARAMANGA
2011

CARACTERIZACIÓN CROMÁTICA DE UN
ESCÁNER POR MEDIO DE REGRESIÓN
POLINOMIAL MÚLTIPLE Y REDES NEURONALES ARTIFICIALES



Trabajo de grado como requisito para optar al título de Físico

Juan Carlos Quijano Rojas

Director:
Dr. Jáder Guerrero Bermúdez
Escuela de Física
Universidad Industrial de Santander

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE CIENCIAS
ESCUELA DE FÍSICA
BUCARAMANGA
2011

AGRADECIMIENTOS

Agradezco a mi Padre celestial por darme el privilegio de cumplir mis sueños y acercarme al fascinante mundo de la ciencia, donde he podido comprender parte de los principios que gobiernan el universo que Él, tan apasionadamente, diseñó.

Asimismo, existen muchas otras personas que han aportado su grano de arena para ayudarme a culminar este ciclo; entre ellas están: mi amada esposa Viviana, quien con su ternura y apoyo incondicional siempre ha estado a mi lado; mis padres quienes me dieron todo su amor y quienes junto a toda mi familia me han hecho sentir su orgullo y alegría por este logro y por los que vendrán.

También quiero agradecer al profesor Jáder Guerrero, a César, Viviana, los Danis, William y cada persona que participó de este agradable proceso.

Contenido

Tabla de figuras.....	9
Lista de tablas	10
Glosario	11
Introducción.....	14
1. Teoría	15
1.1. Conceptos básicos del color.....	15
1.2. Caracterización de Dispositivos	17
1.2.1. Escáner plano.....	18
1.2.2. Estándares de la <i>CIE</i>	19
1.3. El <i>Natural Color System (NCS)</i>	20
1.4. Técnicas Computacionales.....	22
1.4.1. Regresión Polinomial Múltiple. RPM.....	22
1.4.2. Redes Neuronales Artificiales. RNA	23
2. Metodología.....	25
2.1. Toma de espectros de reflectancia.....	25
2.2. Registro de las muestras mediante el escáner	27
2.3. Métodos de caracterización.....	28
2.3.1. Caracterización por medio de Regresión Polinomial Múltiple	28
2.3.2. Caracterización por medio de Redes Neuronales Artificiales.....	28
3. Resultados y Discusiones	30
3.1. Resultados del método RPM.....	30
3.2. Resultados del método RNA	35
4. Conclusiones	41
Bibliografía	42
Apéndice A.....	44

Tabla de figuras

Figura 1. Partes esenciales del ojo. (Fuente: Física para ciencias e ingeniería. Serway. 7ª edición.)	15
Figura 3. Absorción de conos y bastones en el espectro visible. (Fuente: Textbook of Medical Physiology. Guyton & Hall. 11ª Edición)	16
Figura 2. El espectro electromagnético. El espectro visible. (Fuente: agaudi.wordpress.com. Diciembre 2010).....	16
Figura 4. Proceso de digitalización de imágenes por medio del escáner. (Fuente: digitalización.unam.mx)	18
Figura 5. Espacio de color del NCS. (Fuente: NCS sitio oficial).....	20
Figura 6. Círculo de color del NCS. (Fuente: NCS sitio oficial).....	20
Figura 7. Triángulo de color del NCS. (Fuente: NCS sitio oficial).....	21
Figura 8. Modelo de una red neuronal artificial.	23
Figura 9. Funciones de transferencia.	24
Figura 10. Espectro de reflectancia correspondiente a la muestra 0090-Y60R del atlas de color del NCS.	25
Figura 11. Montaje del espectrofotómetro y esfera integradora.....	26
Figura 12. Hoja escaneada No. 2 y la hoja B (a la derecha), del atlas del NCS.....	27
Figura 13. Histogramas método RPM. De 3 a 5 términos.....	32
Figura 14. Histogramas método RPM. Con 10, 20 y 35 términos	33
Figura 15. Diferencia de color máxima vs. Número.....	34
Figura 16. Diferencia de color promedio vs. Número.....	34
Figura 17. Diferencia de color promedio y desviación.....	34
Figura 18. Diferencia de color promedio y desviación.....	34
Figura 19. Histogramas método RNA, Gradiente Descendente.	36
Figura 20. Error de desempeño de la red vs. Número de épocas. Gradiente descendente.....	37
Figura 21. Correlación entre los valores triestímulo deseados y los obtenidos por la red con el algoritmo propio.	37
Figura 22. Histogramas para 3, 8 y 30 neuronas en la capa oculta con la función <i>newff</i>	39
Figura 23. Error de desempeño de la red vs. Número de épocas. Usando la <i>newff</i>	40
Figura 24. Correlación entre los valores triestímulo deseados y los obtenidos por la red, usando <i>newff</i>	40

Lista de tablas

Tabla 1. Funciones de transferencia	24
Tabla 2. Grupos de hojas del atlas de color del <i>NCS</i>	30
Tabla 3. Estructura de los polinomios empleados en el método de RPM.	31
Tabla 4. Resultados del método de RPM.	31
Tabla 5. Resultados del método de RNA. Algoritmo propio.	35

Glosario

Bias: sesgo o umbral, es una entrada constante asociada con el valor de 1. Se conoce también como una neurona siempre activa que facilita la tarea de entrenamiento.

Esfera integradora: instrumento utilizado en óptica para sumar todo el flujo radiante reflejado o radiado por una muestra. En este caso, la radiación reflejada por la muestra cromática al ser iluminada.

Espectrofotómetro: instrumento que toma un haz de luz y tiene la capacidad de separarlo para facilitar la identificación, calificación y cuantificación de su energía.

Natural Color System NCS: es un sistema que permite describir el color exactamente de la manera en que los vemos. Este sistema presenta una notación precisa para definir cualquier color.

Observador estándar: El observador estándar CIE es el resultado de experimentos en los que se pidió a los sujetos del mismo que establecieran una igualdad entre longitudes de onda monocromáticas con mezclas de los tres primarios aditivos.

Pseudoinversa: la pseudoinversa de S se obtiene haciendo: $S^T[S^T S]^{-1}$ y se usa para resolver sistemas con más ecuaciones que incógnitas, cuando no es posible determinar la inversa de S .

Perceptrón: es un tipo de red neuronal artificial desarrollado por Frank Rosenblatt. Usa una matriz para representar las redes neuronales y es un discriminador lineal; a cada valor de entrada le asigna un único valor (binario) de salida.

Sinapsis: región de contacto entre dos neuronas. Es una unión intercelular especializada. En esos contactos se lleva a cabo la transmisión de impulsos eléctricos. Se aplica análogamente a las neuronas artificiales.

Triestímulo: son las cantidades de tres primarios que especifican un estímulo de color. Los valores triestímulo de CIE 1931 se llaman X , Y y Z .

TÍTULO: CARACTERIZACIÓN CROMÁTICA DE UN ESCÁNER POR MEDIO DE REGRESIÓN POLINOMIAL MÚLTIPLE Y REDES NEURONALES ARTIFICIALES¹

AUTOR: Juan Carlos Quijano Rojas²

PALABRAS CLAVES: perceptron, triestímulo, caracterización.

RESUMEN: El registro, la reproducción y el despliegue de imágenes a color con alta calidad y fidelidad, mediante un escáner plano, requiere la caracterización cromática del equipo. Este proceso consiste en relacionar espacios de color dependientes del sistema de adquisición de imagen, tales como *RGB (Red, Green, Blue)*, con espacios estandarizados e independientes del dispositivo, entre los que se encuentran los valores triestímulo *CIEXYZ*.

En este trabajo se adoptan dos enfoques para la caracterización cromática de un escáner plano de uso comercial. El primero se relaciona con el análisis de regresión polinomial entre los espacios de color dependientes e independientes del dispositivo; planteando una relación a través de polinomios de diversos grados y diversa cantidad de términos, con el objetivo de determinar una matriz de coeficientes o de transformación. El segundo enfoque, consiste en la puesta a punto de una red neuronal artificial tipo *perceptron* multicapa, utilizando el algoritmo de retro propagación de errores (*back-propagation*), por medio de la cual se pretende ejecutar el mapeo entre los espacios de color. Para este segundo enfoque se tienen en cuenta dos algoritmos de entrenamiento de las redes: uno que se programa para el presente proyecto, conocido como gradiente descendente, y el otro que es propio del entorno de programación *MATLAB™*, conocido como el algoritmo Levenberg-Marquardt.

¹ Trabajo de grado

² Facultad de Ciencias. Escuela de Física. Director: Jáder Enrique Guerrero Bermúdez.

TITLE: CHROMATIC CHARACTERIZATION OF SCANNER BY MEANS OF MULTIPLE POLYNOMIAL REGRESSION AND ARTIFICIAL NEURAL NETWORKS.³

AUTHOR: Juan Carlos Quijano Rojas⁴

ABSTRACT: The record, playback and display of color images with high quality and fidelity, with a flatbed scanner, require color device characterization. This process involves linking of device-dependent color spaces, such as RGB (Red, Green, Blue), with standard and device-independent color spaces, among which are the tristimulus values CIEXYZ.

In this work were adopted two approaches for color characterization of a commercial flatbed scanner. The first one relates to the polynomial regression analysis between dependent and independent-device spaces; suggesting a relationship through polynomials of different grades and different amount of terms, with the aim of determining a transformation or coefficients matrix. The second approach involves the development of a multilayer perceptron artificial neural network, using the error back-propagation algorithm. Through which it intends to execute the mapping between color spaces. For this second approach takes into account two algorithms for training networks: one that is programmed for this project, known as descending gradient, and one that is characteristic of the *MATLAB*TM programming environment, known as Levenberg-Marquardt algorithm.

KEY WORDS: perceptron, tristimulus, characterization.

³ Work Degree

⁴ Faculty of Sciences. School of Physics. Directress: Jáder Enrique Guerrero Bermúdez.

Introducción

El estudio y manejo del color ha sido durante largo tiempo materia de interés para la humanidad. Desde los pensamientos de Aristóteles y las formulaciones de Leonardo Da Vinci sobre la mezcla de colores, pasando por el valioso aporte de Sir Isaac Newton de la descomposición de la luz blanca en el espectro visible, hasta los estudios y avances tecnológicos más recientes, la ciencia ha permitido desarrollar mecanismos de adquisición y despliegue de imágenes cromáticas cada vez más confiables.

Uno de los dispositivos que ha sido de gran utilidad a la sociedad es el escáner plano, mediante el cual es posible registrar, explorar y reproducir imágenes cromáticas de objetos de forma bidimensional. Sin embargo, en el proceso de tratamiento de imágenes el escáner no está solo, una amplia gama de equipos como monitores e impresoras, son empleados junto con él. Ahora bien, para lograr un buen despliegue y comunicación entre estos dispositivos, es de gran importancia llevar a cabo el proceso de caracterización cromática, con el cual se busca obtener imágenes en un espacio de color estándar e independiente del dispositivo partiendo de las coordenadas: rojo, verde y azul de la imagen.

En la búsqueda de ejecutar la caracterización cromática del escáner surgen diversos métodos y técnicas entre las cuales sobresalen, y en el presente trabajo se escogen dos, que son de gran importancia: la regresión polinomial múltiple y las redes neuronales artificiales. A través de estas herramientas se lleva a cabo un mapeo entre los espacios de color que representan muestras de color estándar, y se busca comparar los resultados con métricas establecidas, además de justificar la elección de la mejor técnica de caracterización.

Sucesos como el advenimiento de la televisión digital a nuestro país justifica esta clase de trabajos en los cuales se adquiere un vocabulario y cultura característicos del tratamiento de imágenes y se aplican conocimientos de diversas ciencias.

1. Teoría

1.1. Conceptos básicos del color

La percepción del color es el resultado de la interacción entre estímulos físicos y receptores en el ojo humano. El estímulo físico del color es la radiación en la región visible del espectro electromagnético. En el espacio libre, esta región se especifica por el contenido espectral en el intervalo de longitudes de onda desde $\lambda_{\min} = 380 \text{ nm}$ hasta $\lambda_{\max} = 780 \text{ nm}$ aproximadamente⁵.

En su recorrido para formar una imagen, la luz entra al ojo por la córnea, pasa a través del cristalino y se detecta en los foto-receptores en la retina. Esta última es la parte sensible a la luz, la cual está formada por los conos y bastones. Los primeros son los responsables de la visión a color y los segundos de la visión en blanco y negro además de la visión en la oscuridad. La excitación de estos elementos genera una señal transmitida a través de neuronas en la retina y posteriormente en fibras del nervio óptico hasta la corteza cerebral, con el fin de producir una imagen visual.

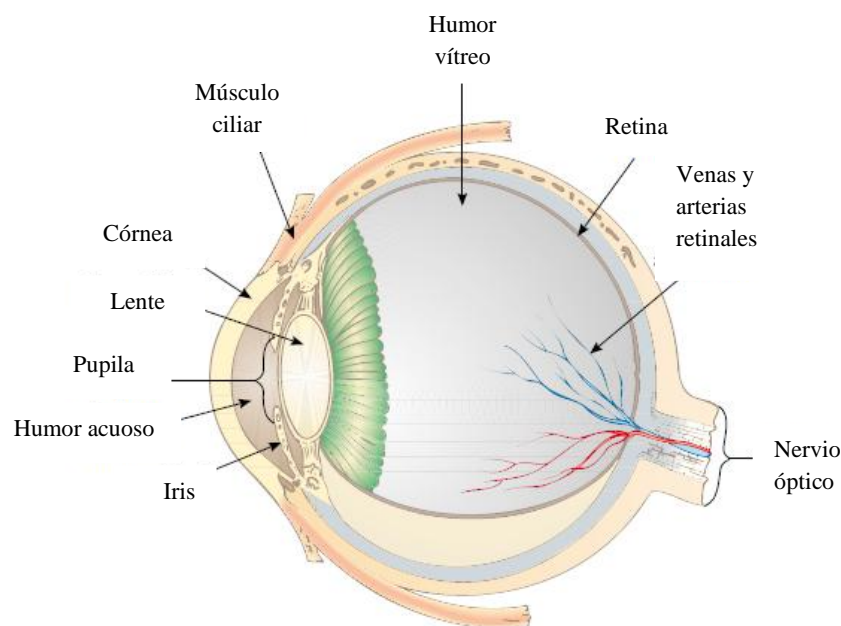


Figura 1. Partes esenciales del ojo. (Fuente: Física para ciencias e ingeniería. Serway. 7ª edición.)

La luz incidente en el ojo puede ser originada de diferentes maneras: a partir de objetos iluminados por una fuente externa, como la luz solar o una lámpara, o generada por el propio cuerpo. Si la luz reflejada o emitida por el objeto tiene un amplio contenido espectral se habla

⁵ Guyton, A., Hall, J. *Textbook of Medical Physiology*. Eleventh edition, Elsevier Saunders. 1116 p. 2006

de un objeto cromático. Las diferentes sensaciones de color se producen por mezclas aditivas y sustractivas de color. La mezcla aditiva se basa en la adición de luz de diferentes longitudes de onda, siendo los colores primarios (rojo, verde y azul) mezclados para producir cualquier otro color.




Figura 2. El espectro electromagnético. El espectro visible.

A comienzos del siglo XIX, Thomas Young mostró que era posible generar una amplia gama de colores mezclando tres haces de luz, siempre que sus frecuencias estuvieran a una distancia considerable. Cuando estos tres haces de luz se combinan para producir la luz blanca, reciben el nombre de colores primarios. El rojo, el verde y el azul son los más comúnmente utilizados como primarios; tales son los tres componentes que generan toda la gama de tonalidades en un aparato de televisión en color o en un escáner. Así bien, si se suma la luz roja a la azul aparece el magenta, la luz azul sumada con la luz verde se percibe como cian, y la luz roja sumada a la verde se percibe como amarillo.

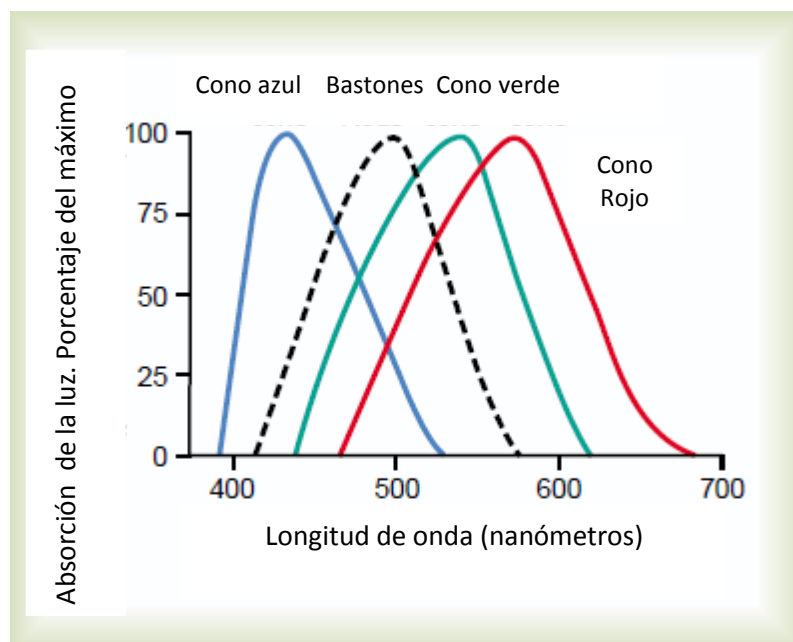


Figura 3. Absorción de conos y bastones en el espectro visible. (Fuente: Textbook of Medical Physiology. Guyton & Hall. 11ª Edición)

Ahora bien, en los dispositivos de registro de imagen tales como una cámara o un escáner, la retina se emula mediante un elemento que sensa la luz; generalmente es una matriz o línea de fotodiodos tipo *CCD* (*Charge-Coupled Device*) o *CMOS* (*Complementary Metal Oxide Semiconductor*). El funcionamiento de tales mecanismos se basa en el efecto fotoeléctrico, y principalmente se encargan de registrar la luz incidente, transformarla en un voltaje análogo y posteriormente convertirla a una señal digital que luego podrá ser desplegada. Para el registro de imágenes de objetos cromáticos, la matriz de fotodiodos cuenta con sensores con respuesta para las bandas espectrales en el rojo, verde y azul, que originan la respuesta *RGB* (*Red, Green, Blue*) de estos dispositivos. Por este motivo, las coordenadas cromáticas *RGB* de una imagen registrada por un equipo en particular, se encuentran vinculadas a la respuesta espectral de éste y se dice que son dependientes del dispositivo⁶.

Con el propósito de comunicar y reproducir fielmente una imagen cromática entre varios mecanismos de registro y despliegue, se hace necesario recurrir al uso de espacios estandarizados e independientes de la respuesta particular del equipo.

1.2. Caracterización de Dispositivos

Existen dos procedimientos indispensables en la implementación del manejo de color con un dispositivo electrónico, éstos son: calibración y caracterización.

La calibración es un proceso altamente subjetivo, mediante el cual se pretende ajustar los parámetros del dispositivo para el registro e interpretación de datos, con la intención que la respuesta del equipo ostente atributos muy cercanos a la escena real.

Por otro lado, en el proceso de caracterización cromática se busca la relación entre las coordenadas de color del dispositivo y unas coordenadas estándar, independientes del equipo. La función de caracterización se puede definir en dos direcciones: la transformación hacia adelante, define la respuesta del equipo a una entrada conocida, y describe sus características cromáticas, mientras que la transformación inversa determina la entrada necesaria para obtener una respuesta deseada.

Con el objeto de establecer una relación entre los espacios dependientes e independientes del dispositivo, es posible plantear la siguiente expresión:

$$C_i = K_i \int S(\lambda) c_i(\lambda) d\lambda, \quad i = 1, 2, 3 \quad (1.1)$$

⁶ Lukav, R., Plataniotis, K N. *Color Image Processing*. CRC Press, Taylor and Francis Group. 575 p. 2007.

Donde C_i son las señales cromáticas, K_i son constantes de normalización y $c_i(\lambda)$ las correspondientes funciones de color (RGB , en este caso). La radiancia espectral está relacionada con las señales cromáticas (que pueden ser los valores triestímulo).

La luz incidente sobre el detector, puede ser expresada como:

$$S(\lambda) = I_s(\lambda)R(\lambda) \quad (1.2)$$

donde $R(\lambda)$ es la función de reflectancia o transmitancia espectral del estímulo de entrada, $I_s(\lambda)$ corresponde al iluminante del escáner.

Con las ecuaciones anteriores se puede establecer una relación entre las coordenadas dependientes e independientes del dispositivo⁷.

1.2.1. Escáner plano

Un escáner es un dispositivo utilizado para convertir un documento (soportado en papel, lona o algún otro material) en una imagen digital, transformando datos analógicos (físicos, reales, de precisión infinita) en digitales (un conjunto finito y de precisión determinada de unidades lógicas, denominadas bits).

Al adquirir una imagen, el escáner emplea un módulo CCD , por medio del cual sensa y convierte la luz en un voltaje análogo. Mientras la luz del escáner recorre la imagen, líneas individuales de ésta se sensan mediante el arreglo CCD , el cual transmite los voltajes proporcionales a la intensidad de la luz de entrada. Posteriormente, el convertidor análogo-digital DAC (*Digital-Analog Converter*) se usa para cuantizar la señal análoga de voltaje a una señal digital representada en 8 o 16 bits por cada canal R, G, B . Estos valores digitales son usualmente lineales con respecto a la luminancia del estímulo escaneado⁸.

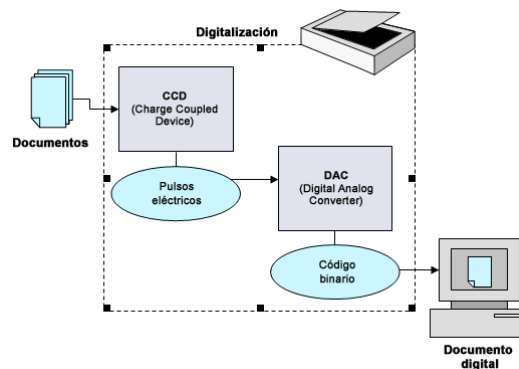


Figura 4. Proceso de digitalización de imágenes por medio del escáner. (Fuente: UNAM)

⁷ Pratt, W. *Digital Image Processing*. John Wiley and sons, inc. 735 p. 2001.

⁸ Sharma, G. *Digital Color Imaging Handbook*. Xerox Corporation, Webster, New York. 2003.

1.2.2. Estándares de la CIE

La Comisión Internacional en Iluminación (*Commission Internationale de l'Eclairage, CIE*) es la principal organización responsable de la estandarización de las medidas de color y la terminología. En 1931 la *CIE* definió un estándar colorimétrico que continúa siendo base de la colorimetría moderna. Se definió un **observador estándar**, proporcionando dos grupos de diferentes pero equivalentes funciones de color⁹.

En la mayoría de aplicaciones e investigaciones acerca de imágenes de color se emplea el espacio *CIEXYZ*. Donde X, Y, Z se conocen como los valores triestímulo.

Para obtener estos valores de una muestra cromática, se tienen las siguientes relaciones:

$$\begin{aligned} X &= k \sum_{i=1}^{N-1} \bar{x}(\lambda_i) l(\lambda_i) r(\lambda_i) \\ Y &= k \sum_{i=1}^{N-1} \bar{y}(\lambda_i) l(\lambda_i) r(\lambda_i) \\ Z &= k \sum_{i=1}^{N-1} \bar{z}(\lambda_i) l(\lambda_i) r(\lambda_i) \end{aligned} \quad (1.3)$$

Donde el factor de normalización está dado por:

$$k = \frac{100}{\sum_{i=1}^{N-1} \bar{y}(\lambda_i) l(\lambda_i)} \quad (1.4)$$

En las ecuaciones (1.3), $\bar{x}(\lambda_i)$, $\bar{y}(\lambda_i)$ y $\bar{z}(\lambda_i)$ son las funciones de adaptación del observador estándar de la *CIE*. El valor **triestímulo** Y es usualmente conocido como la luminosidad y está relacionada con la brillantez percibida del espectro radiante.

⁹ Sharma, G. Digital Color Imaging Handbook. Xerox Corporation, Webster, New York. 2003

1.3. El *Natural Color System (NCS)*

El NCS es un sistema de notación del color basado en la forma como el ser humano ve los colores. Cualquiera de los millones de colores existentes puede ser definido por medio de este sistema [3]. Este sistema de colores se basa en seis elementos, los cuales el ser humano percibe como puros. Cuatro elementos cromáticos: el amarillo (*Y*), rojo (*R*), azul (*B*) y verde (*G*), y dos no-cromáticos: el blanco (*W*) y el negro (*S*). Los colores se representan con letras mayúsculas que indican sus iniciales en inglés (excepto para el negro, para evitar repetir la *B*). Todos los demás colores se pueden describir en términos de su semejanza con los colores elementales. Todos los colores se pueden ubicar y tienen una notación en el espacio tridimensional de color del NCS, figura 5. Sin embargo, para facilitar la comprensión de la notación, se tienen dos modelos bidimensionales: el círculo de color del NCS y el triángulo de color del NCS.




Figura 5. Espacio de color del NCS. (Fuente: NCS sitio oficial).

El círculo de color del NCS, figura 6, es una sección horizontal de la parte central del espacio de color del NCS vista desde arriba, donde los colores elementales se ubican como los puntos cardinales. Cada cuadrante entre dos colores elementales se divide en 100 partes, de las cuales se muestran cada 10. En la figura 6 se aprecia un ejemplo de un tono en particular, el Y90R, el cual representa un color con un 10% de amarillo y un 90% de rojo.




Figura 6. Círculo de color del NCS. (Fuente: NCS sitio oficial)

Por otro lado, el triángulo de color del NCS es una sección vertical del espacio de color de NCS para los diferentes tonos. La base del triángulo es la escala de grises desde el blanco (W) hasta el negro (S) y el vértice corresponde al máximo de cromaticidad (C) para el tono dado (en este caso el Y90R). La gráfica 7 proporciona el matiz del color, representado por las cantidades W, S y C.




Figura 7. Triángulo de color del NCS. (Fuente: NCS sitio oficial)

Así, la notación utilizada por el *Natural Color System* para la muestra seleccionada en las figuras 6 y 7 será:

S 1050 - Y90R

La letra S significa que la muestra es tomada del estándar, se aprecia un 10% de negro, 50% de cromaticidad y 40% de blanco, que se calcula sumando los porcentajes de negro y cromaticidad y luego restándolos de 100. Por su parte, el tono Y90R describe el grado de amarillo (10%) y rojo (90%) del color.

1.4. Técnicas Computacionales

1.4.1. Regresión Polinomial Múltiple. RPM.

Esta es una forma especial de ajuste de mínimos cuadrados, donde la función de caracterización es aproximada por un polinomio.

Para realizar un mapeo entre los valores *RGB* del escáner y los *CIEXYZ*, se definen relaciones como las siguientes:

$$\begin{aligned} X &= a_{11}R + a_{12}G + a_{13}B + a_{14}R^2 + a_{15}G^2 + a_{16}B^2 + \dots \\ Y &= a_{21}R + a_{32}G + a_{23}B + a_{24}R^2 + a_{25}G^2 + a_{26}B^2 + \dots \\ Z &= a_{31}R + a_{32}G + a_{33}B + a_{34}R^2 + a_{35}G^2 + a_{36}B^2 + \dots \end{aligned} \quad (1.5)$$

Donde los valores a_{ij} ($i, j = 1, 2, 3, \dots$) son los coeficientes a determinar.

El planteamiento se puede realizar de forma matricial:

$$[X \ Y \ Z] = [R \ G \ B \ \dots \ R^2 \ \dots \ RGB] \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \dots & \dots & \dots & \dots \\ a_{m1} & a_{m2} & \dots & a_{mn} \end{bmatrix} \quad (1.6)$$

Si se tienen n valores respuesta del escáner y sus correspondientes valores triestímulo, se hace necesario determinar la matriz A :

$$\mathbf{T} = \mathbf{SA} \quad (1.7)$$

Donde \mathbf{T} es la matriz de valores triestímulo, \mathbf{S} es la matriz de valores RGB del escáner y \mathbf{A} es la matriz de coeficientes o matriz de transformación. La matriz \mathbf{A} se determina directamente:

$$\mathbf{A} = \mathbf{S}^{-1}\mathbf{T} \quad (1.8)$$

Donde \mathbf{S}^{-1} es la matriz inversa de \mathbf{S} . Si \mathbf{S} no es una matriz cuadrada, es decir, si el sistema es sobre-determinado (más ecuaciones que variables), se debe determinar la pseudoinversa de \mathbf{S} . Teniendo los valores de la matriz \mathbf{A} , es posible calcular los valores *CIEXYZ*, para cualquier grupo nuevo de valores RGB del escáner¹⁰.

¹⁰ Cheung, V., et al. "A comparative study of the characterization of colour cameras by means of neural networks and polynomial transforms". *Color. Technol.* 120, 19-25. 2004.

1.4.2. Redes Neuronales Artificiales. RNA

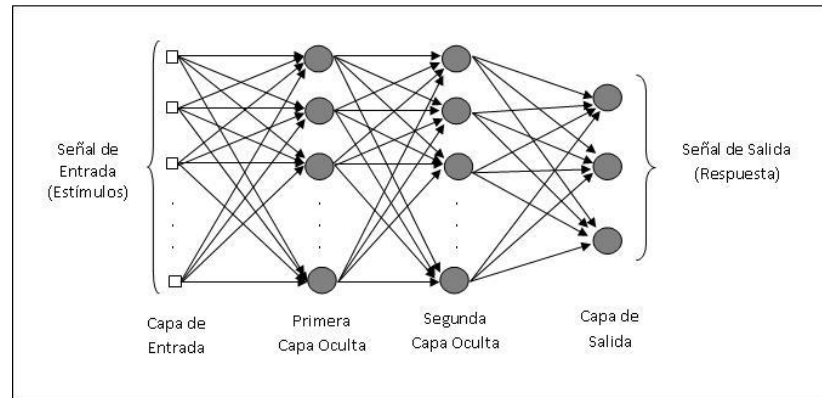


Figura 8. Modelo de una red neuronal artificial.

Una Red Neuronal Artificial (RNA) es un procesador distribuido en paralelo, construido por unidades simples de procesamiento, denominadas neuronas, cuyo funcionamiento simula el desempeño del cerebro humano a la hora de resolver problemas.

Entre los diferentes tipos de redes neuronales existentes se destaca el **Perceptrón Multicapa** (PMC o *MLP*, por sus siglas en inglés) en las cuales se basan la mayoría de las aplicaciones. Un Perceptrón Multicapa es una red formada por varias capas de unidades de procesamiento, o neuronas. Cada unidad recibe una entrada y a través de una función aplicada a la entrada, produce una salida. Esta función entre las entradas y salidas de las neuronas se conoce como función de activación o de transferencia, y por lo general es no lineal, aunque suele usarse funciones lineales entre algunas neuronas.

La entrada en cada unidad es la suma ponderada de las salidas de las unidades previas. En la primera capa, o capa de entrada, cada neurona recibe su entrada de un vector de entradas, y la capa de salida produce un vector de salida, después de que cada neurona, en las capas ocultas, ha desempeñado su función de activación.

Las unidades en las capas ocultas y de salida, reciben también una entrada ponderada fija al valor de la unidad denominada **bias**¹¹.

El entrenamiento de esta red neuronal consistirá, al igual que en el perceptrón simple, en presentar las entradas junto con las salidas deseadas para cada una de ellas y modificar los pesos de acuerdo con el error¹² (diferencia entre la salida deseada y la obtenida).

¹¹ Lukav, R., Plataniotis, K N. Color Image Processing. CRC Press, Taylor and Francis Group. 575 p. 2007.

¹² Westland, S. Ripamonti, C. Computational Color Science using Matlab. John Wiley and Sons, Ltd. England. 207 p. 2004.

La principal dificultad en el entrenamiento de redes de varias capas es encontrar los errores asociados con las capas ocultas; es decir, en las capas que no son la de salida (sólo se tiene salida deseada en las capas de salida).

Esto es debido a que los errores son necesarios para el aprendizaje, para saber cómo modificar los pesos de las neuronas en las capas ocultas. Así se da origen a algoritmos muy ingeniosos, de los cuales el precursor y más conocido por su simplicidad, es el que recibió el nombre de retro-propagación del error (*back-propagation*).

Así es, el funcionamiento de un PMC, básicamente: se aplica una entrada cuya salida se conoce (en este caso, datos de color del proceso de caracterización), luego se calcula primero la salida de las neuronas de entrada, estas salidas son las entradas de las neuronas de la(s) capa(s) oculta(s), con tales entradas se calcula la salida de las neuronas ocultas, y con éstas como entrada para las neuronas de salida, se calculan las salidas finales. Esta es la fase hacia delante, por así decirlo, en la red.

Luego se obtiene el error con respecto a la señal deseada y finalmente este error se retro propaga modificando los pesos.

El modelo de una neurona artificial consiste en la sumatoria de los valores de entrada x_i , previamente multiplicados por sus respectivos pesos **sinápticos** w_i y posteriormente evaluados en la función de activación o transferencia, $\varphi()$, para dar una salida v . Matemáticamente, se puede expresar:

$$v = \varphi(\sum x_i w_i) \quad (1.9)$$

Las funciones de transferencia son aquellas funciones matemáticas, utilizadas para modelar el comportamiento de una neurona artificial. Éstas, toman la sumatoria de las entradas ponderadas n más el sesgo y retornan una salida correspondiente a .

Tabla 1. Funciones de transferencia

Nombre de la función	Relación entrada/ salida
Lineal	$a = n$
Sigmoidea logarítmica	$a = \frac{1}{1 + e^{-n}}$
Tangente sigmoidea hiperbólica	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$




Figura 9. Funciones de transferencia.

2. Metodología

A continuación se describen cada una de las actividades realizadas para la ejecución del proceso de caracterización del escáner, junto con los equipos y materiales utilizados.

Con el fin de realizar el ajuste de una función que relacione los valores *RGB* y *CIEXYZ*, se hace necesario como primera medida adquirir una base de datos de espectros de reflectancia de muestras de color estándar, obteniendo de cada una de ellas los valores *XYZ*. Por otra parte, las mismas muestras se escanean, obteniendo luego los valores *RGB* de las imágenes cromáticas. De esta manera, se adquieren las coordenadas dependientes e independientes del dispositivo para las mismas muestras. Finalmente se hace el mapeo matemático mediante las técnicas mencionadas en el capítulo 1.

2.1. Toma de espectros de reflectancia

Las muestras empleadas en este procedimiento, fueron tomadas del atlas de color del *Natural Color System (NCS)* [25]. Se adquirieron espectros de reflectancia de 1300 parches de color. La figura muestra uno de los espectros obtenidos.




Figura 10. Espectro de reflectancia correspondiente a la muestra 0090-Y60R del atlas de color del NCS.

La toma de espectros se llevó a cabo por medio de un **espectrofotómetro** *Ocean Optics USB4000* acoplado por medio de una fibra óptica a una **esfera integradora** *Ocean Optics ISP-REF*. La figura 11 muestra el montaje empleado. El objeto, en este caso la muestra cromática del NCS, se ilumina con un haz de luz policromático, una bombilla halógena de Tungsteno. La esfera integradora está configurada con la geometría 8°/d, componente especular incluida, para la iluminación y recepción de la luz reflejada por la muestra, esta disposición viene recomendada en el atlas de la academia sueca del color.

Inicialmente los espectros de reflectancia r , se registran en 3648 datos en el rango de 350 nm hasta los 1000 nm, luego se normalizan a valores en el rango [0,1] mediante la expresión:

$$r_N = \left(\frac{r-B}{W-B} \right) \quad (2.1)$$

Donde r_N es la reflectancia normalizada, W y B son los espectros del blanco de referencia y el fondo (es decir, sin ningún estímulo cromático en el porta-muestra de la esfera). Los espectros normalizados finalmente se submuestran en el intervalo 380 a 780 nm a paso de 1 nm¹³.



Figura 11. Montaje del espectrofotómetro y esfera integradora.

Una vez adquiridos los espectros de reflectancia, se procede a diseñar un código en *MATLAB™* (*Mathworks Inc.*) que permite obtener los valores triestímulo de cada muestra. El código se presenta en el apéndice A.

¹³ Guerrero, J. Plata, A. Mejía, E. Cabanzo, R. Caracterización espectral de un escáner a partir de las señales RGB y HSV. Revista Avances en Sistemas e Informática. Vol. 7 No. 3. Diciembre de 2010. Medellín. ISSN 1657-7663.

2.2. Registro de las muestras mediante el escáner

Cada hoja del atlas del NCS se escanea y posteriormente se procede a calcular los valores *RGB* de las muestras cromáticas. La figura 12 corresponde a las hojas 2 y 23 (B) del atlas de color del NCS.

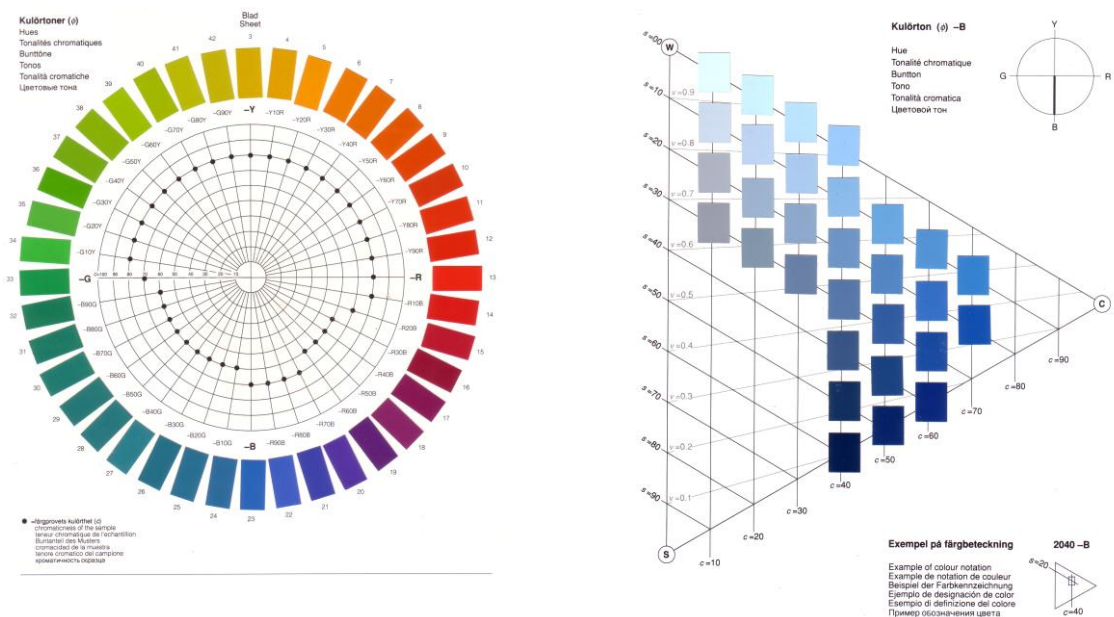


Figura 12. Hoja escaneada No. 2 y la hoja B (a la derecha), del atlas del NCS

Existen diversos métodos para calcular los valores *RGB* de una imagen. El propuesto en el presente trabajo consiste en un código en MATLAB que permite reproducir, de las hojas escaneadas, cada posición de las muestras de color y posteriormente determinar el valor de los primarios para cada imagen, la rutina se presenta en el apéndice A.

Todas las coordenadas (*RGB*) antes de cualquier proceso se normalizan en el rango [0,1] mediante la división entre 255 (el máximo valor de cada una de las coordenadas). Previo a la caracterización se debe asegurar que el escáner tenga deshabilitadas las funciones de balance de blanco y de ajuste automático de intensidad, evitando los procesos propios de normalización del dispositivo. Alternativamente, si el escáner no permite la desactivación del balance de blanco automático, todas las muestras deben presentarse con un único y adecuado blanco de referencia.

Teniendo los datos ya normalizados se procede a construir las matrices de valores *RGB* y *CIEXYZ* para asociarlas mediante los métodos matemáticos utilizados.

2.3. Métodos de caracterización

2.3.1. Caracterización por medio de Regresión Polinomial Múltiple

Como se explicó previamente en el capítulo anterior, por medio de esta técnica se pretende encontrar la relación entre el espacio de color (R, G, B) del escáner y el espacio estandarizado (X, Y, Z) , a través de un polinomio. La relación se puede apreciar en la ecuación 1.7.

La tarea de encontrar los coeficientes a_{ij} (matriz de caracterización o de transformación) permite determinar los valores triestímulo para cualquier vector nuevo de valores (R, G, B) ; es decir, para cualquier imagen nueva registrada por el escáner. El procedimiento de cálculo de la matriz de coeficientes es posible a través del código en MATLAB expuesto en el apéndice A.

Seis clases de polinomios son utilizados para el proceso de mapeo. Tres de ellos de primer grado, y los demás de segundo, tercer y cuarto grado respectivamente; contando con tres hasta 35 términos. Teniendo un grupo de entrenamiento y otro de prueba (de hojas del atlas de color del NCS) se procede a encontrar la matriz de coeficientes que proporcione la mejor transformación. Los resultados son comparados con los valores Lab a través del cálculo del ΔE_{ab} .

2.3.2. Caracterización por medio de Redes Neuronales Artificiales

La aplicación de las redes neuronales artificiales en el desarrollo del presente trabajo, involucró dos procesos a saber: entrenamiento y prueba. Durante la fase de entrenamiento se presentan a la red un grupo de vectores *entrada y objetivo* de la forma $\{e_1, o_1\}$, $\{e_2, o_2\}$... $\{e_q, o_q\}$. Aquí se lleva a cabo el algoritmo de retro propagación, que consiste en dos etapas o pasos de cómputo. El primero es el paso hacia adelante, donde la red deja inalterados los pesos sinápticos. El segundo es el paso hacia atrás, durante el cual la red cambia los pesos sinápticos y calcula el error.

La fase de prueba consiste en presentarle a la red ya entrenada, un grupo diferente de valores RGB y esperar que pueda adquirir los correspondientes $CIEXYZ$. De esta manera se puede comprobar que el entrenamiento se llevó a cabo con éxito.

En el presente proceso de caracterización se trabaja con redes tipo *perceptrón* multicapa, aplicando el algoritmo *back-propagation*.

Aunque existe una herramienta muy útil como el *toolbox* de redes neuronales de MATLAB, en esta etapa del trabajo se implementa un código propio para entrenar y probar la red neuronal, con base en el algoritmo del gradiente descendente¹⁴. Tal código se presenta en el apéndice A.

Sin embargo, con el fin de comparar la efectividad del código desarrollado, el entrenamiento y prueba de la red se lleva a cabo también usando el *toolbox* de Matlab.

Se tienen en cuenta diferentes arquitecturas de red, todas con una sola capa oculta, manteniendo fijos el número de neuronas en la capa de entrada (tres neuronas correspondientes a los *RGB*) y en la capa de salida (tres neuronas correspondientes a los *XYZ*) y variando el número de neuronas en la capa oculta. De esta manera una red con cinco neuronas en la capa oculta se representa de la siguiente manera: 3 – 5 – 3.

Cuando se lleva a cabo la fase de entrenamiento de las redes, los valores de los pesos sinápticos y de los bias se inicializan aleatoriamente y si una red en particular arroja buenos resultados se hace necesario recuperar de ella los valores de esos pesos y bias, para usarlos posteriormente en la fase de prueba. Para cada arquitectura de red se utilizan las funciones de activación o transferencia más comunes: la función sigmoidea en la capa oculta y lineal en la capa de salida.

¹⁴ Martin, T. Hagan, Mohammad B. Menjah. Training Feedforward Network with the Marquardt Algorithm. IEEE Transactions on Neural Networks. Vol. 5 No. 6. Noviembre 1994.

3. Resultados y Discusiones

Tanto para el método de regresión polinomial múltiple como para las redes neuronales, se toman grupos de entrenamiento y prueba, los cuales corresponden a hojas del atlas de color del *Natural Color System*.

Tabla 2. Grupos de hojas del atlas de color del NCS

Grupo	Hojas del atlas de color del NCS
Entrenamiento	Y60R, R20B, R50B, B, B60G, B70G, G20Y
Prueba	Y, Y60R, R20B, R80B, B40G, G, G60Y

Para constatar los resultados se calcula la diferencia de color *CIELAB* (ΔE_{ab}). Se ha trabajado con iluminante D65 y observador de 2° (*CIE 1931*).

$$\Delta E_{ab} = \sqrt{(\Delta L^*)^2 + (\Delta a^*)^2 + (\Delta b^*)^2} \quad (3.1)$$

El proceso de selección del mejor grupo de entrenamiento consistió en realizar un barrido sistemático de las hojas del atlas. Inicialmente se avanzó escogiendo cada tres hojas, luego cada cuarto y así sucesivamente, hasta dar con el grupo que exhibiera los mejores resultados en el cálculo del ΔE_{ab} . Este proceso es comparado con trabajos previos en los cuales se utiliza un grupo similar de hojas¹⁵.

3.1. Resultados del método RPM

El proceso de caracterización a través de esta técnica se lleva a cabo desarrollando un código que realice un mapeo entre las coordenadas. Se plantean polinomios de diferentes grados y se busca determinar el valor de los coeficientes de la ecuación matricial 1.7.

Para los grupos de entrenamiento y prueba se calcula la diferencia de color ΔE_{ab} . Así mismo, por medio de histogramas se presenta la densidad de probabilidad de los resultados. Además, se muestran las gráficas que relacionan el error con el número de términos de los polinomios para los grupos de entrenamiento y prueba¹⁶. Los polinomios utilizados junto con sus tamaños y grados se presentan en la siguiente tabla.

¹⁵ Yong, W. Haisong, X. Spectral characterization of scanner based on PCA and BP ANN. Chin. Opt. Lett 3. 725-728 (2005).

¹⁶ Ali Shams Nateri. Prediction of textile fabric color by color camera. RJTA Vol. 12 No. 2. 2008.

No. del método	Polinomio	No. de términos (m)	Grado
1	[R G B]	3	1
2	[R G B 1]	4	1
3	[R G B RGB 1]	5	1
4	[R G B RG RB GB R ² G ² B ² 1]	10	2
5	[R G B RG RB GB R ² G ² B ² R ² G G ² B B ² R R ² B G ² R B ² G R ³ G ³ B ³ 1]	20	3
6	[R G B RG RB GB R ² G ² B ² R ² G G ² B B ² R R ² B G ² R B ² G R ³ G ³ B ³ R ³ G R ³ B G ³ R G ³ B B ³ R B ³ G R ² GB RG ² B RGB ² R ² G ² R ² B ² G ² B ² R ⁴ G ⁴ B ⁴ 1]	35	4

Tabla 3. Estructura de los polinomios empleados en el método de RPM.

Los resultados del cálculo de la diferencia de color se muestran a continuación. Para hacer evidente la desviación estándar se brinda información de los valores máximos y mínimos.

No. de términos (m) del polinomio	Entrenamiento				Prueba			
	ΔE_{ab} Medio	ΔE_{ab} Máximo	ΔE_{ab} Mínimo	Desviación estándar	ΔE_{ab} Medio	ΔE_{ab} Máximo	ΔE_{ab} Mínimo	Desviación estándar
3	14.65	51.05	1.45	8.12	21.31	127.06	1.17	20.57
4	34.74	282.52	1.70	56.14	32.65	190.36	0.85	41.23
5	20.97	133.37	0.49	28.95	25.84	208.98	0.47	34.97
10	6.35	46.57	0.28	6.95	13.09	136.86	1.0314	15.31
20	6.09	44.60	0.48	6.67	10.81	54.01	1.305	9.57
35	5.46	42.33	0.05	6.53	10.19	106.04	0.39	12.27

Tabla 4. Resultados del método de RPM.

Mientras se aumenta el número de términos de los polinomios, al aumentar el grado del polinomio, es notoria la disminución del ΔE_{ab} . En los histogramas para el error ΔE_{ab} se presenta la distribución de los resultados.

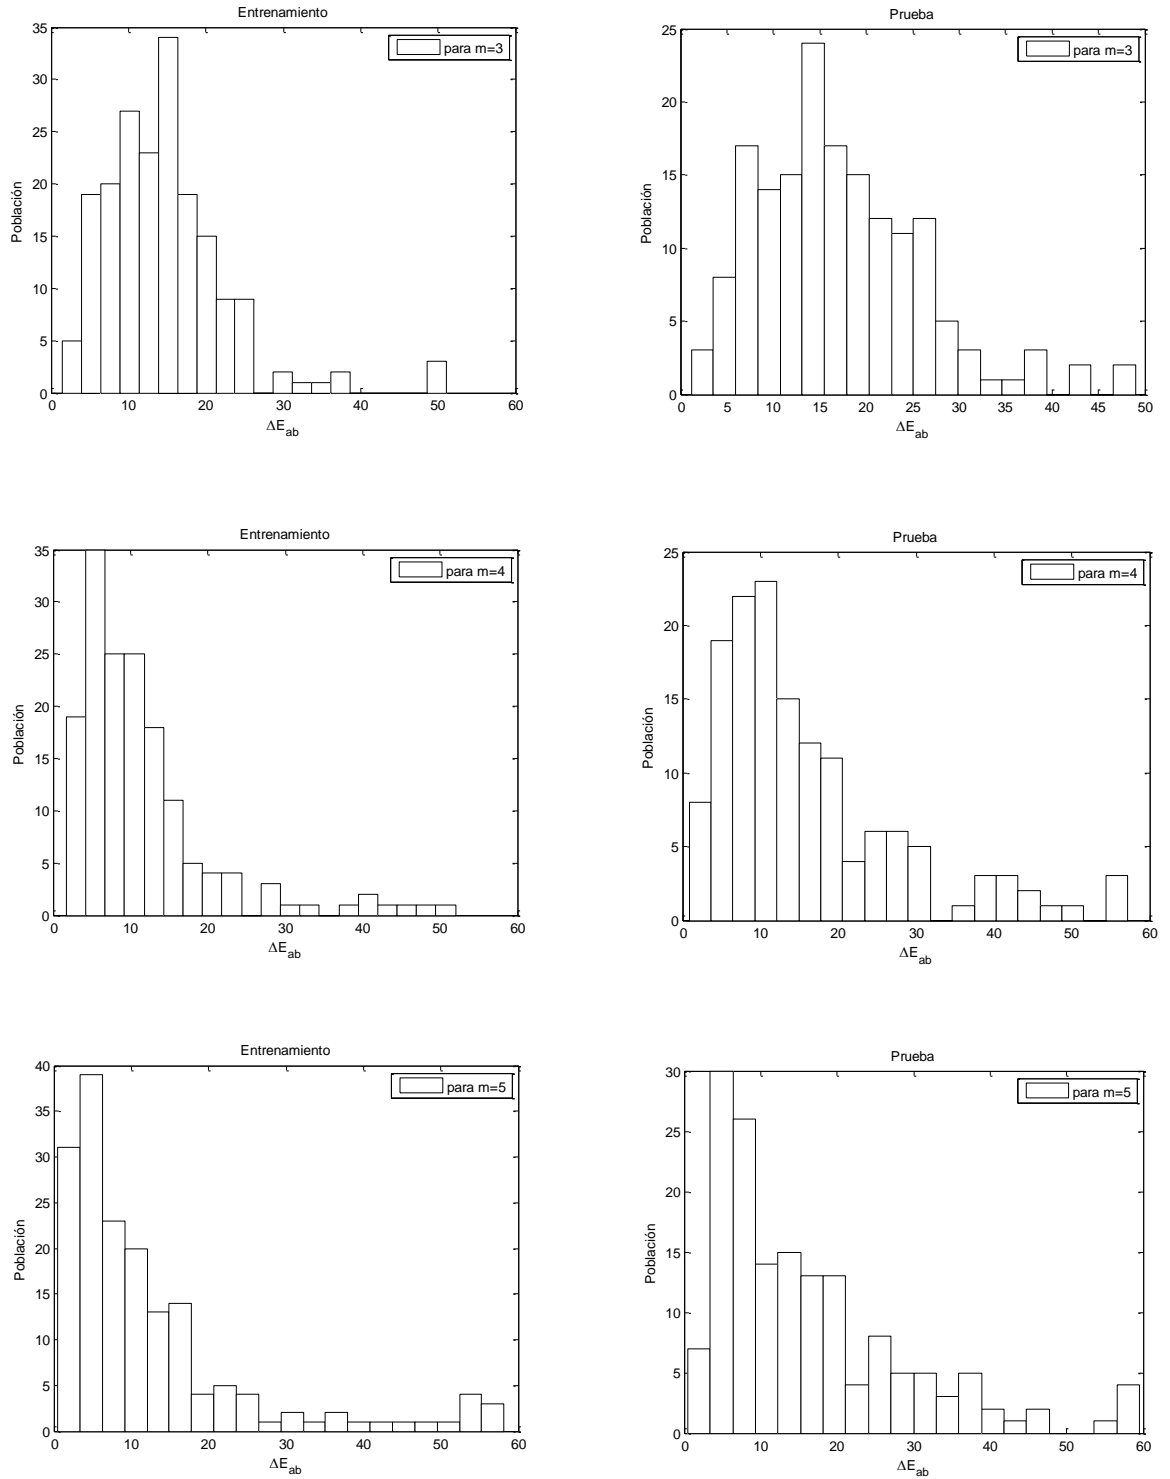


Figura 13. Histogramas método RPM. De 3 a 5 términos

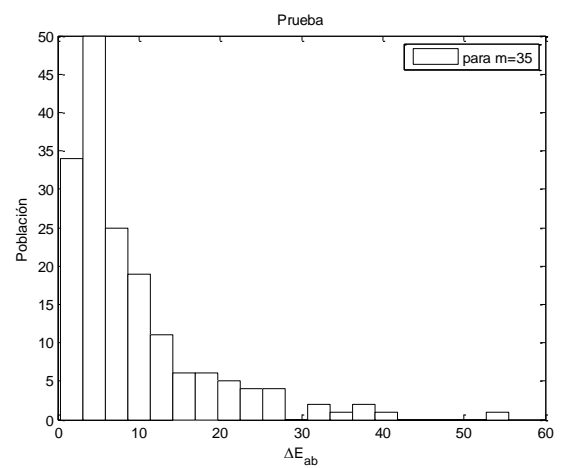
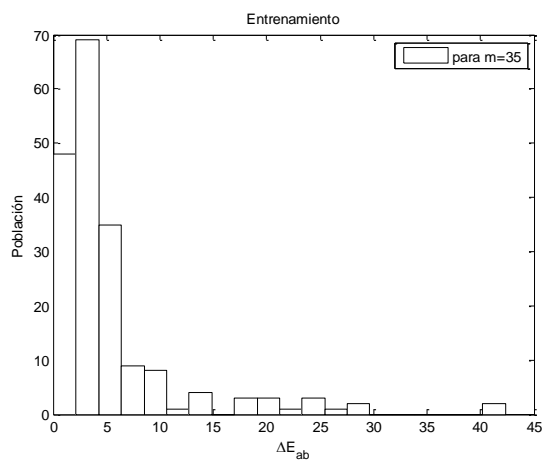
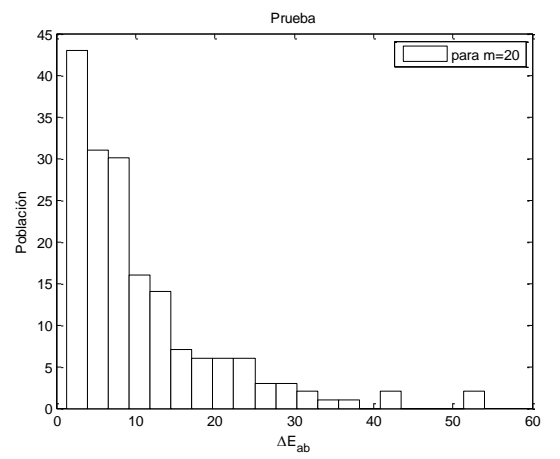

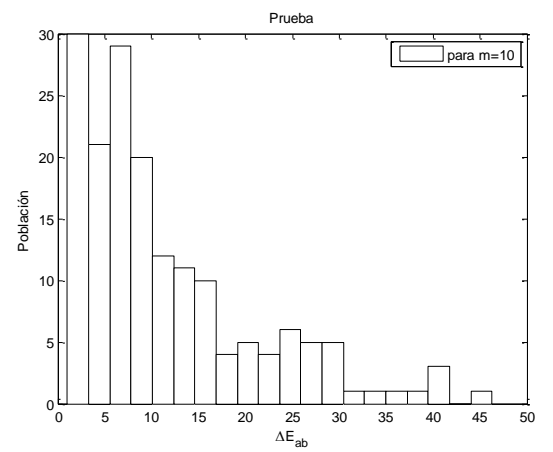



Figura 14. Histogramas método RPM. Con 10, 20 y 35 términos

En las siguientes figuras se muestra el ΔE_{ab} medio y máximo para cada uno de los polinomios empleados, en las fases de entrenamiento y prueba.

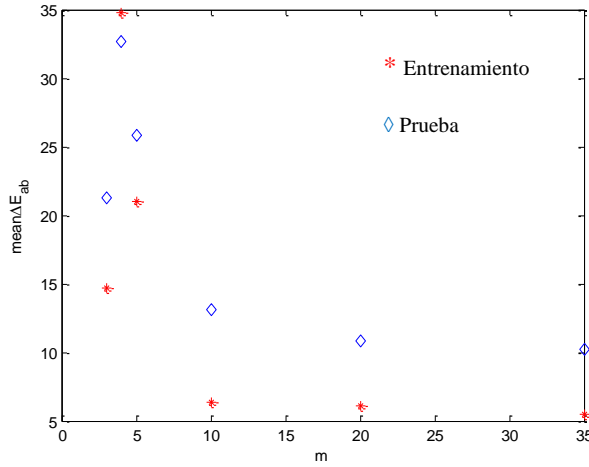


Figura 16. Diferencia de color promedio vs. Número de términos polinomiales (m)

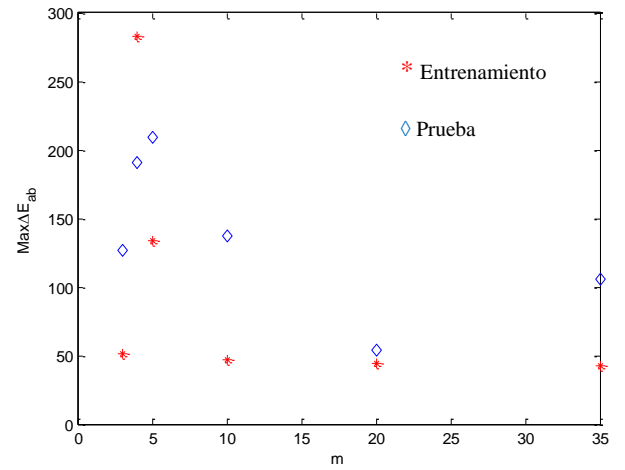


Figura 15. Diferencia de color máxima vs. Número de términos polinomiales (m)




Figura 18. Diferencia de color promedio y desviación estándar para el grupo de entrenamiento vs. No de términos polinomiales.




Figura 17. Diferencia de color promedio y desviación estándar para el grupo de prueba vs. No de términos polinomiales.

3.2. Resultados del método RNA

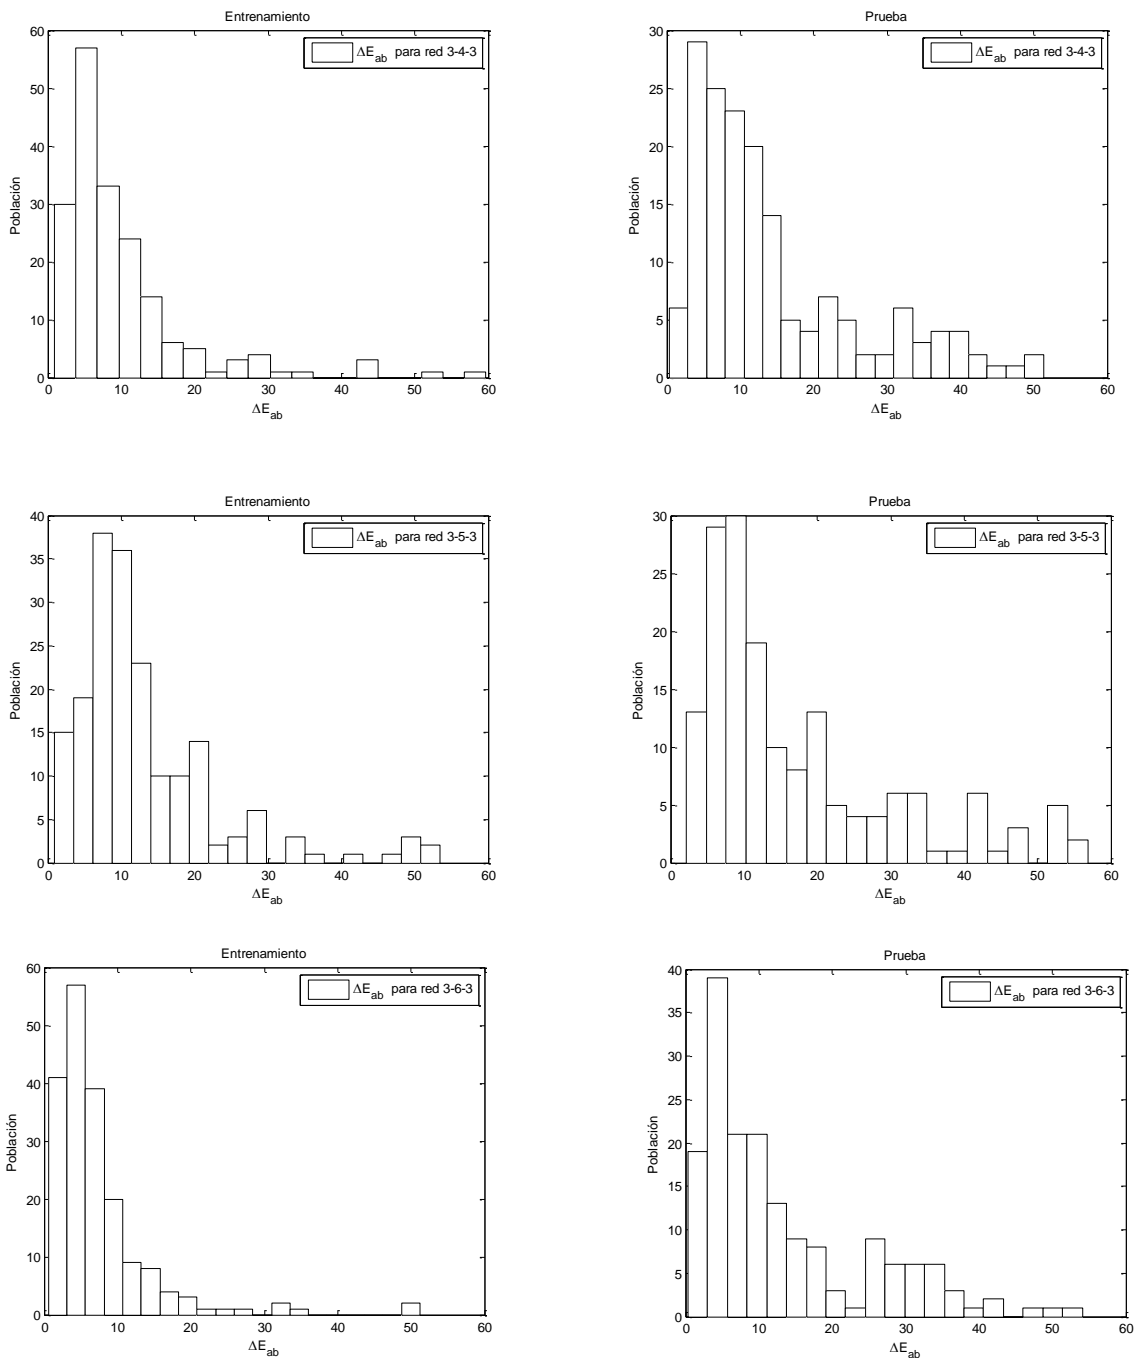
El uso de esta técnica para caracterizar el escáner se lleva a cabo diseñando un código que permita entrenar y probar diferentes arquitecturas de redes neuronales. Si bien Matlab tiene una función propia para trabajar con RNA, la función *newff* que permite crear, entrenar y probar una red tipo perceptron multicapa, en el presente trabajo se programó una rutina propia basada en el algoritmo del gradiente descendiente¹⁷. Se utilizaron pues las dos funciones (rutinas: *newff* de Matlab™ y la programada en el entorno Matlab™). Para encontrar la mejor arquitectura de red.

A continuación se presentan los valores del error colorimétrico y la desviación estándar para los grupos de prueba y entrenamiento con diferentes arquitecturas de red. Tanto en el código propio como con la función *newff*, se utilizó el mismo generador de números aleatorios para inicializar los pesos sinápticos y las tendencias (bias).

Resultados usando el algoritmo propio								
Estructura de la Red	Entrenamiento				Prueba			
	ΔE_{ab} Medio	ΔE_{ab} Máximo	ΔE_{ab} Mínimo	Desviación estándar	ΔE_{ab} Medio	ΔE_{ab} Máximo	ΔE_{ab} Mínimo	Desviación estándar
3 – 3 – 3	15.22	110.04	1.02	17.79	24.85	272.79	1.24	37.81
3 – 4 – 3	12.27	120.91	0.848	16.69	19.14	189.27	0.30	26.69
3 – 5 – 3	13.76	66.04	0.875	11.24	21.25	160.33	2.10	23.66
3 – 6 – 3	7.51	51.21	0.60	7.15	14.67	122.87	0.34	15.85
3 – 8 – 3	12.36	80.48	0.86	12.71	19.11	153.01	0.90	22.32
3 – 10 – 3	17.39	122.29	0.70	17.66	22.25	177.42	1.08	25.01
3 – 15 – 3	17.58	126.55	1.02	18.50	22.52	185.17	0.69	26.90
3 – 20 – 3	13.99	80.55	0.70	12.38	20.21	184.94	1.90	25.60
3 – 25 – 3	10.90	51.89	1.10	8.11	20.24	292.85	0.59	36.00
3 – 30 – 3	11.51	61.15	0.26	9.04	21.13	248.73	1.34	33.41
3 – 35 – 3	11.68	50.51	0.31	8.42	16.64	158.20	0.63	18.49
3 – 40 – 3	68.74	268.93	7.32	50.02	74.34	365.97	12.48	55.42
3 – 45 – 3	113.82	640.13	9.44	125.47	109.14	954.67	5.27	161.72
3 – 50 – 3	71.70	254.58	7.15	49.60	72.10	221.40	15.10	42.34
3 – 55 – 3	70.82	246.86	7.19	48.43	71.28	219.13	15.22	41.49
3 – 60 – 3	73.26	269.71	7.25	52.71	73.54	248.05	14.91	46.04

¹⁷ Martin, T. Hagan, Mohammad B. Menjah. Training Feedforward Network with the Marquardt Algorithm. IEEE Transactions on Neural Networks. Vol. 5 No. 6. Noviembre 1994.

Se puede apreciar que unas de las mejores arquitecturas de red son aquellas que presentan 4, 5 y 6 neuronas en la capa oculta, y más adelante se aprecia como el error disminuye para los grupos con 25 a 40 neuronas. Del mismo modo, al entrenar las redes se nota que para una cantidad mayor que 45 neuronas el error aumentaba significativamente, de modo que se decidió trabajar únicamente hasta ese número de neuronas. Las RNA pueden tener más de una capa oculta, sin embargo, en el presente trabajo solo se tienen en cuenta redes con una sola capa oculta. Reportes previos muestran que no hay resultados mejores con más de una capa oculta [8]. Se presentan a continuación los histogramas que muestran las tres mejores estructuras de red, donde se puede apreciar que la mayoría de los resultados del ΔE_{ab} tienen valores pequeños y los máximos son valores aislados en la mayoría de los casos.



Para la estructura de seis neuronas en la capa oculta (3 – 6 – 3) se muestra a continuación el error cuadrático medio (*mse*) alcanzado en la fase de entrenamiento, asimismo se presenta la relación entre los objetivos y las respuestas de la red para la fase de prueba.




Figura 20. Error de desempeño de la red vs. Número de épocas. Gradiente descendente

La red está programada para detener el entrenamiento al lograr un error mínimo de $1e^{-6}$ o al alcanzar 1000 épocas. En todos los casos, al variar el número de neuronas en la capa oculta, el criterio de parada ha sido el alcance del número de épocas.

En un espacio tridimensional generado por los valores triestímulo XYZ, la nube de las respuestas de la red se encuentra muy cercana a la de los valores objetivo (*target*) o deseados¹⁸.




Figura 21. Correlación entre los valores triestímulo deseados y los obtenidos por la red con el algoritmo propio.

¹⁸ Wandell, B. Farrell, J. Water into Wine. Converting scanner RGB to Teistimulus XYZ. SPIE Vol. 1909. Pag. 92-101.

Resultados usando la función <i>newff</i>								
Estructura de la Red	Entrenamiento				Prueba			
	ΔE_{ab} Medio	ΔE_{ab} Máximo	ΔE_{ab} Mínimo	Desviación estándar	ΔE_{ab} Medio	ΔE_{ab} Máximo	ΔE_{ab} Mínimo	Desviación estándar
3 – 3 – 3	9.16	43.70	0.63	7.36	15.48	65.89	0.22	11.77
3 – 4 – 3	12.56	95.81	0.46	13.43	18.12	94.45	1.16	16.88
3 – 5 – 3	10.46	80.54	0.92	10.48	19.23	118.23	0.25	20.07
3 – 6 – 3	10.07	95.47	0.82	13.36	16.04	120.70	1.21	17.17
3 – 8 – 3	7.91	41.88	0.65	7.26	17.56	99.21	1.20	18.67
3 – 10 – 3	9.41	53.44	0.37	9.67	19.16	274.73	1.22	31.31
3 – 15 – 3	8.27	74.34	0.56	8.99	23.20	352.86	0.79	41.21
3 – 20 – 3	8.23	72.01	0.46	10.22	16.13	150.34	1.12	19.86
3 – 25 – 3	7.40	39.02	1.145	6.19	16.66	117.99	1.57	16.23
3 – 30 – 3	6.19	39.68	0.27	6.31	22.25	286.56	1.02	33.69
3 – 35 – 3	7.45	55.04	0.57	8.00	20.28	214.75	0.16	26.90
3 – 40 – 3	7.60	62.60	0.55	9.48	35.58	536.04	0.61	75.83
3 – 45 – 3	6.41	43.80	0.62	6.18	20.37	177.71	0.67	22.23
3 – 50 – 3	13.19	74.78	0.38	12.27	22.86	254.98	1.36	30.50
3 – 55 – 3	12.74	58.78	1.30	9.49	24.74	232.30	1.35	30.30
3 – 60 – 3	4.97	28.26	0.10	4.69	25.29	345.99	0.60	46.77

Tabla 6. Resultados del método de RNA. Función *newff*.

Los resultados obtenidos al implementar la función *newff* de Matlab muestran unos valores menores para el ΔE_{ab} , puesto que tal función utiliza por defecto el algoritmo de Levenberg-Marquardt para el entrenamiento de la red. Dicho algoritmo se diferencia del de gradiente descendente en que logra minimizar el error con mayor rapidez.

Se presentan a continuación los histogramas que muestran las tres mejores estructuras de red, usando la *newff*, donde se puede apreciar que la mayoría de los resultados del ΔE_{ab} tienen valores pequeños y los máximos son valores aislados en la mayoría de los casos.

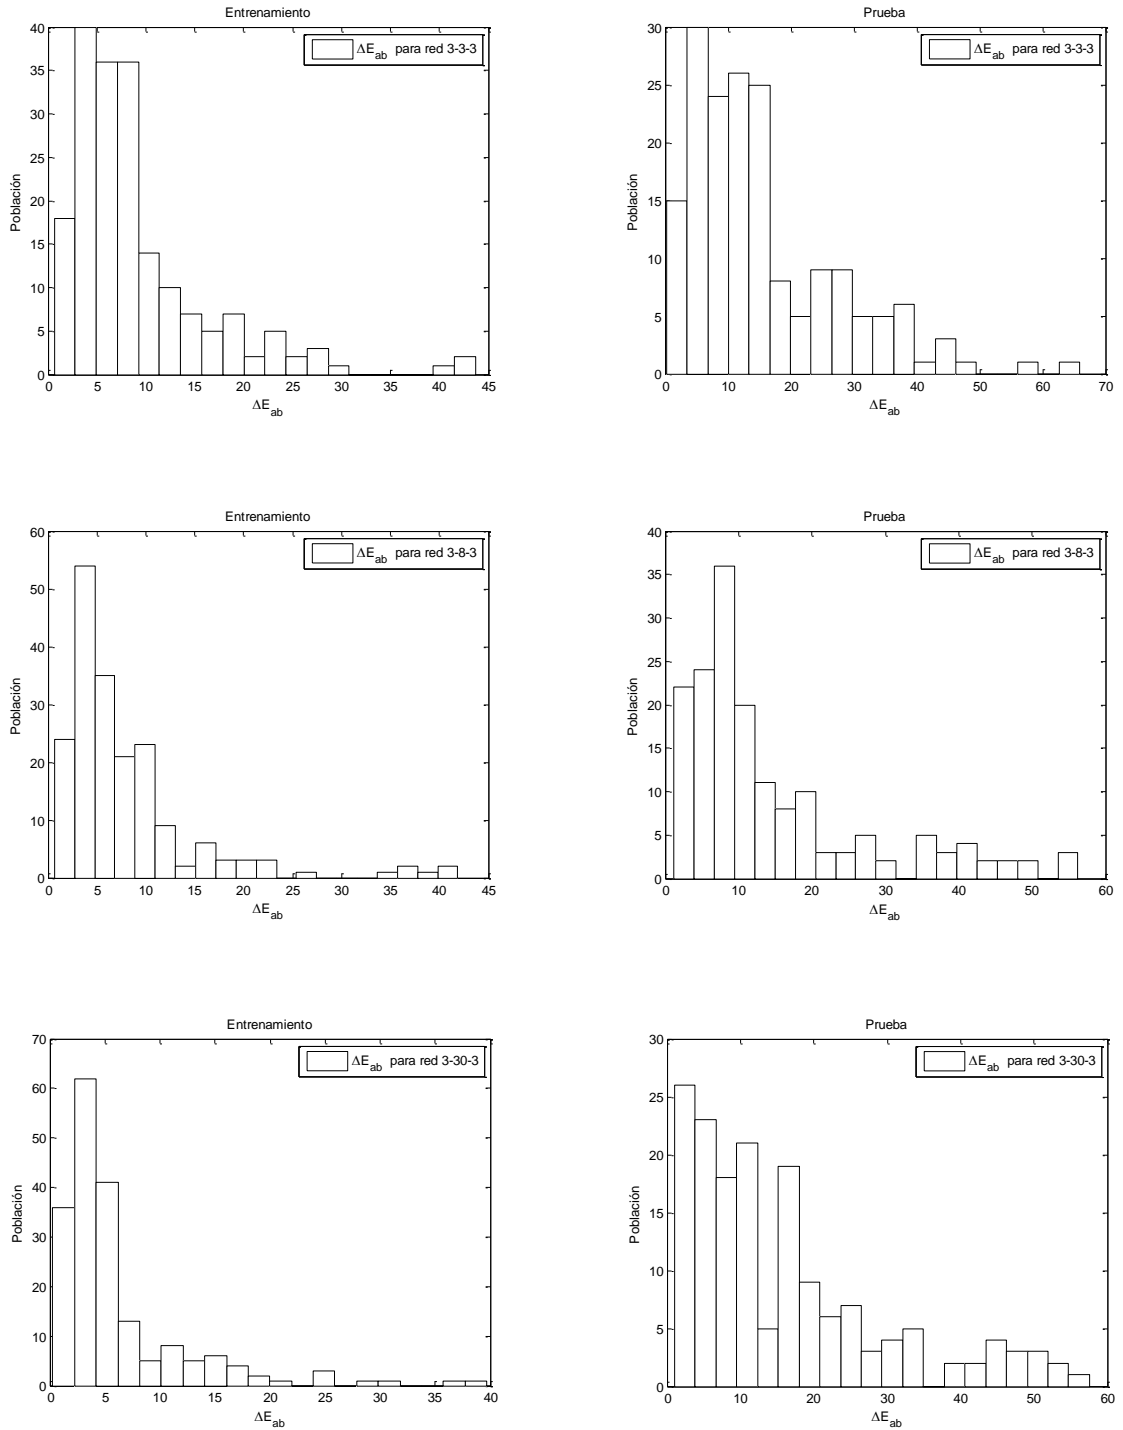


Figura 22. Histogramas para 3, 8 y 30 neuronas en la capa oculta con la función *newff*.

Para la estructura de 3 neuronas en la capa oculta (3 – 3 – 3) se muestran a continuación: el error cuadrático medio (*mse*) alcanzado en la fase de entrenamiento y la relación entre los objetivos y las respuestas de la red para la fase de prueba.




Figura 23. Error de desempeño de la red vs. Número de épocas. Usando la *newff*.




Figura 24. Correlación entre los valores triestímulo deseados y los obtenidos por la red, usando *newff*.

4. Conclusiones

En el presente trabajo se lleva a cabo la caracterización cromática de un escáner plano por medio de dos técnicas: la regresión polinomial múltiple y las redes neuronales artificiales. Se recopila una base de datos comprendida por muestras cromáticas del atlas de color de *Natural Color System*, con el fin de tener colores estandarizados para asegurar así la eficiencia del proceso. Cada hoja del atlas de color se registra con el escáner y posteriormente se obtienen las coordenadas *RGB* de cada color; por otra parte se obtiene el espectro de cada muestra cromática por medio de un espectrofotómetro y una esfera integradora, lo que permite calcular las coordenadas *CIEXYZ*. Teniendo los espacios de color correspondientes se procede a realizar el mapeo entre ellos, buscando la mejor forma de relacionarlos.

Del proceso de caracterización propuesto se puede concluir lo siguiente:

1. El uso de las dos técnicas de caracterización ofrece resultados alentadores, dado que al escoger un polinomio con 35 términos se logra alcanzar un error cromático promedio de 10.19 con desviación estándar de 12.27 para el grupo de prueba. A su vez al usar las RNA se obtiene un error de 14.67 con desviación estándar de 15.85 con el algoritmo gradiente descendente, y 15.48 con desviación estándar de 11.77 con el algoritmo Levenberg-Marquardt.
2. Los resultados muestran en las dos técnicas un valor máximo del error colorimétrico significativamente alto. Un análisis de este hecho permite distinguir un grupo pequeño de muestras cromáticas que inciden considerablemente en ello. Dichas muestras tienen la particularidad de tener valores muy pequeños en sus coordenadas *XYZ*. Al realizar una revisión de los histogramas, es notorio que tales valores del error eran pocos y la mayoría de los valores se encuentran cerca del promedio.
3. La regresión polinomial múltiple aventajó a las redes neuronales, sobretodo en el tiempo de ejecución de la técnica.
4. La diferencia primordial ente el algoritmo de Levenberg-Marquardt y gradiente descendente (el código propio diseñado en este trabajo), es el mayor grado de convergencia del primero, debido a la eficiencia del *toolbox* de Matlab. No obstante, es altamente enriquecedor el trabajo realizado al poder programar el algoritmo de gradiente descendente para entrenar las RNA.
5. Durante el proceso de entrenamiento con el método de RPM, mientras mayor es el número de términos mejor es el resultado obtenido, como sería de esperarse; con todo, el manejo de las RNA permite concluir que la mejor arquitectura no es necesariamente aquella con más capas ocultas o con mayor número de neuronas en la capa oculta, sencillamente el mejor ajuste se produce, en la mayoría de los casos, para un número pequeño de neuronas; lo primordial es encontrar un grupo de pesos sinápticos y bias que produzcan el mejor ajuste.

Bibliografía

A. Shams-Nateri, S. H. Amirshahi. 12th International CSI Computer Conference. 20-22 February 2007.

Ali Shams Nateri. *Predition of Textile Fabric Color by Digital Camera*. RJTA Vol. 12, No. 2. 2008

Bishop, J.M., M. J. Bushnell. Westland, S. *The Application of Neural Networks to Computer Recipe Prediction*. Vol. 1, p. 3-9. 2007.

C.A. Osorio, E. Mejía, J.E. Guerrero. *Spectral reflectance curves for multispectral imaging, combining different techniques and a neural network*. Rev. mex. fis. vol. 55 No. 2 México Apr. 2009. p. 120-124.

Cheung, V., et al. "A comparative study of the characterization of colour cameras by means of neural networks and polynomial transforms". Color. Technol. 120, 19-25. 2004.

Cheung, Westland, S. Tenth Color Imaging Conference. 117

Guerrero, J., Plata, A., Mejía, E., Cabanzo, R. *Caracterización espectral de un escáner a partir de las señales RGB y HSV*. Revista Avances en Sistemas e Informática, Vol. 7 No. 3, diciembre de 2010 – Medellín. ISSN 1657-7663.

Guyton, A., Hall, J. *Textbook of Medical Physiology*. Eleventh edition, Elsevier Saunders. 1116 p. 2006

Haykin, J. *Artificial Neural Networks, a comprehensive foundations*. Prentice- Hall, Inc. Segunda Edición. 1999.

Hecht, E. *Óptica*. Tercera edición. Pearson – Addison Wesley. 2000.

Kang, H., Anderson P. *Neural network applications to the color scanner and printer calibrations*. Journal of Electronic Imaging. 1(2), p. 125-135 (April 1992).

Lukav, R., Plataniotis, K N. *Color Image Processing*. CRC Press, Taylor and Francis Group. 575 p. 2007.

Martin T. Hagan, Mohammad B. Menhaj. *Training Feedforward Networks with the Marquardt Algorithm*. IEEE Transactions on Neural Network. Vol. 5, No 6, Noviembre 1994.

Pratt, W. *Digital Image Processing*. John Wiley and sons, inc. 735 p. 2001.

Pratt, W., Mancill, C. *Spectral estimation techniques for the spectral calibration of a color image scanner*. Applied Optics. Vol. 15, Issue 1, p. 73-75 (1976).

- R. Schettini, B. Barolo, E. Boldrin, *Colorimetric calibration of color scanners by back propagation*, Pattern Recognition Letters, Vol. 16(10), 1995.
- Ronnier Luo. *Device Calibration of a Color Image Scanner Digitizing System by Using Neural Networks*. IEEE. Vol. 1, p. 59-62. 1995.
- Scandinavian Colour Institute AB, Colour Atlas. 2nd. Ed. Stockholm, 1989, pp 4-44.*
- Sharma, G. Digital Color Imaging Handbook. Xerox Corporation, Webster, New York. 2003
- Shevell, S. *Science of Color. 2nd edition*. Elsevier. 339 p. 2003.
- Sokolowski, K. *Colour Scanner Calibration - A comparison of different methods Master's Thesis*. 2003
- Usui, S. *Neural networks for device-independent digital color imaging*. Elsevier Science Inc., 123 (1), p. 115-125. 2000
- Volz, H. *Industrial Color System*, Wiley-VCH. 1995.
- Wandell, B., Farrell, J. *Water into wine. Converting scanner RGB to Tristimulus XYZ*. SPIE Vol. 1909. Pag. 92-101.
- Westland, S. Ripamonti, C. *Computational Color Science using Matlab*. John Wiley and Sons, Ltd. England. 207 p. 2004.
- Xinwu Li. *Scanner color management model based on improved back-propagation neural network*. Chinese Optics Letters. Vol. 6, No 3. 231. 2008.
- Yilmaz, I. *Color Calibration of Scanners using Polynomial Transformation*. XXth ISPRS Congress: Proceedings of Commission V, Istanbul, Turkey, p. 890-895 (2004).
- Yong Wang and Haisong Xu, "Spectral characterization of scanner based on PCA and BP ANN," Chin. Opt. Lett. **3**, 725-728 (2005).

Apéndice A

CÓDIGOS EN MATLAB

Regresión polinomial

```
cd C:\Users\ACER\Desktop
A=textread('RGB.txt'); %Entradas normalizadas (Valores RGB)
T=textread('XYZ.txt'); % Valores objetivo (Valores XYZ)

s=length(A);
A1=[A(:,1) A(:,2) A(:,3) ones(s,1)];
A2=[A(:,1) A(:,2) A(:,3) A(:,1).*A(:,2).*A(:,3) ones(s,1)];
A3=[A(:,1) A(:,2) A(:,3) A(:,1).*A(:,2) A(:,1).*A(:,3) A(:,2).*A(:,3)
A(:,1).*A(:,1) A(:,2).*A(:,2) A(:,3).*A(:,3) ones(s,1)];
A4=[A(:,1) A(:,2) A(:,3) A(:,1).*A(:,2) A(:,1).*A(:,3) A(:,2).*A(:,3)
A(:,1).*A(:,1) A(:,2).*A(:,2) A(:,3).*A(:,3) A(:,1).*A(:,2).*A(:,3)
A(:,1).*A(:,1).*A(:,2) A(:,2).*A(:,2).*A(:,3) A(:,3).*A(:,3).*A(:,1)
A(:,1).*A(:,1).*A(:,3) A(:,2).*A(:,2).*A(:,1) A(:,3).*A(:,3).*A(:,2)
A(:,1).*A(:,1).*A(:,1) A(:,2).*A(:,2).*A(:,2) A(:,3).*A(:,3).*A(:,3)
ones(s,1)];
A5=[A(:,1) A(:,2) A(:,3) A(:,1).*A(:,2) A(:,1).*A(:,3) A(:,2).*A(:,3)
A(:,1).*A(:,1) A(:,2).*A(:,2) A(:,3).*A(:,3) A(:,1).*A(:,2).*A(:,3)
A(:,1).*A(:,1).*A(:,2) A(:,2).*A(:,2).*A(:,3) A(:,3).*A(:,3).*A(:,1)
A(:,1).*A(:,1).*A(:,3) A(:,2).*A(:,2).*A(:,1) A(:,3).*A(:,3).*A(:,2)
A(:,1).*A(:,1).*A(:,1) A(:,2).*A(:,2).*A(:,2) A(:,3).*A(:,3).*A(:,3)
A(:,1).*A(:,1).*A(:,1).*A(:,2) A(:,1).*A(:,1).*A(:,1).*A(:,3)
A(:,2).*A(:,2).*A(:,2).*A(:,1) A(:,2).*A(:,2).*A(:,2).*A(:,3)
A(:,3).*A(:,3).*A(:,3).*A(:,1) A(:,3).*A(:,3).*A(:,3).*A(:,2)
A(:,1).*A(:,1).*A(:,2).*A(:,3) A(:,1).*A(:,2).*A(:,2).*A(:,3)
A(:,1).*A(:,2).*A(:,3).*A(:,3) A(:,1).*A(:,1).*A(:,2).*A(:,2)
A(:,1).*A(:,1).*A(:,3).*A(:,3) A(:,2).*A(:,2).*A(:,3).*A(:,3)
A(:,1).*A(:,1).*A(:,1).*A(:,1) A(:,2).*A(:,2).*A(:,2).*A(:,2)
A(:,3).*A(:,3).*A(:,3).*A(:,3) ones(s,1)];
C=pinv(A1)*T;
t=A1*C;
for n=1:length(t)
    Laexp(n,:)=labc3(t(n,:), 'D65');
end
cd C:\Users\ACER\Desktop
Lateo=textread('Lateo.txt');
d=(sqrt(sum((Lateo-Laexp).^2,2)));
deltas=['mean(d)=', num2str(mean(d)), '    max(d)=', num2str(max(d)), '
min(d)=', num2str(min(d)), '    std(d)=', num2str(std(d))];
disp(deltas)
figure(1);
xh=0:3:60;
hist(d,20,xh)
h=findobj(gca, 'Type', 'patch');
set(h, 'Facecolor', 'w', 'EdgeColor', 'k');
xlabel('\DeltaE_a_b')
ylabel('Población'), title('Entrenamiento')
```

CÁLCULO DE LOS VALORES XYZ

```
c=1;
Q=[2 9 41 35 30 29 23 18 15];
for i=1:length(Q)
for s=1:60
cd 'C:\Users\ACER\Desktop\NCSCanon\Reflectancias'
z=['hoja' num2str(Q(i)) '\p' num2str(s) '.txt' ];
if exist(z,'file')~=0
[L,r]=leere(z);
plot(L,r);pause(0.5)
T=XYZ(r,'A');
T1(c,:)=T;
c=c+1;
close all
clear all
else
end
end
end
cd 'C:\Users\ACER\Desktop'
a=['XYZ' '.txt'];
fid=fopen(a,'wt');
fprintf(fid,'%d %d %d\n',T1);
```

En la anterior rutina se ejecuta un llamado de dos funciones: XYZ y leere, las cuales tienen como finalidad llamar cada una de las reflectancias de las muestras de color y calcular los valores triestímulo de cada una. Las funciones se muestran a continuación:

```
function T=XYZ(r,iluminante)
Lambda=380:779;
%=====
%Observadores CIE
%=====
cd C:\Users\ACER\Desktop\CIE\observadores
Cx=textread('1931_C_x.txt');
Cy=textread('1931_C_y.txt');
Cz=textread('1931_C_z.txt');
xtrazo=interp1(Cx(:,1),Cx(:,2),Lambda);
ytrazo=interp1(Cy(:,1),Cy(:,2),Lambda);
ztrazo=interp1(Cz(:,1),Cz(:,2),Lambda);
%=====
%Iluminantes CIE
%=====
cd C:\Users\ACER\Desktop\CIE\Iluminantes
if nargin>1
switch(iluminante)
case{'D65'}
z='CIE_D65.txt';
ilu=textread(z);
case{'A'}
z='CIE_A.txt';
ilu=textread(z);
```

```

case{'D50'}
z='CIE_D50.txt';
ilu=textread(z);
end
else
z='CIE_A.txt';
ilu=textread(z);
end
A=interp1(ilu(:,1),ilu(:,2),Lambda);
%=====
k=1/sum(A.*ytrazo);
X=k*sum(A.*r.*xtrazo);
Y=k*sum(A.*r.*ytrazo);
Z=k*sum(A.*r.*ztrazo);
T=[X Y Z];
return

function [Lambda,r]=leere(z)
Lambda=380:779;
if exist(z,'file')~=0
p=textread(z, '',3648,'headerlines',17); %(17 para algunas
reflectancias) Lee el espectro de reflectancia
p=p';
Re=p(2,:);%Intensidad en cuentas
Le=p(1,:);%Longitud de onda en nm
Rn=Re(1,156:2136); % Rango de acuerdo a la curva de calibración del
espectrofotómetro
L=Le(1,156:2136);
r=interp1(L,Rn,Lambda);
else
r='No existe este archivo';
end

```

CÁLCULO DE LOS VALORES RGB

```

clc
clear all
close all

for m=3:3
t=20;
M(:,:,1)=255*ones(2676,2360);
M(:,:,2)=255*ones(2676,2360);
M(:,:,3)=255*ones(2676,2360);
cd ' C:\Users\ACER\Desktop\NCS_Canon\hojas_escaneadas'
z=['hoja' num2str(m) '.BMP'];
if exist(z,'file')~=0
I=imread(z);figure(1);
imagesc(I);title(z);
button=1;
k=1;
I=double(I);
while button~=3
[y x button]=ginput(1);

```

```

x=round(x); y=round(y);
c=[I(x,y,1) I(x,y,2) I(x,y,3)];
figure(2);
M(x-t:x+t,y-t:y+t,1)=I(x,y,1)*ones(2*t+1);
M(x-t:x+t,y-t:y+t,2)=I(x,y,2)*ones(2*t+1);
M(x-t:x+t,y-t:y+t,3)=I(x,y,3)*ones(2*t+1);
imshow(uint8(M));
figure(1);
total(k,:)=c;
k=k+1;
end
total(k-1,:)=[];
gtotal=total';
cd 'C:\Users\ACER\Desktop\'
z1=['RGBhoja' num2str(m) '.txt'];
fid=fopen(z1,'wt');
fprintf(fid,'%d %d %d\n',gtotal);
close all
clear all
else
end
end
end

```

DIFERENCIA DE COLOR ΔE_{ab}

```

clc
clear all
close all

m=[3 4 5 10 20 35];
meandelta=[14.6571 34.7416 20.9725 6.3554 6.0997 5.4675];
meantest=[21.3105 32.6599 25.8486 13.0995 10.8174 10.1913];
maxtest=[127.0694 190.3652 208.9854 136.8639 54.0167 106.0407];
maxdelta=[51.0555 282.5216 133.3760 46.5719 54.6014 42.3370];
figure(3);
plot(m,meandelta,'r*',m,meantest,'bd');xlabel('m');ylabel('mean\DeltaE_a_b');%axis([0 40 10 25])
figure(4);
plot(m,maxdelta,'r*',m,maxtest,'bd');xlabel('m');ylabel('Max\DeltaE_a_b');%axis([0 40 140 210])
s1=std(meandelta-meantest)*ones(size(m));
figure(5);
errorbar(m,meantest,s1,'x');xlabel('m');ylabel('mean\DeltaE_a_b');
s2=std(maxtest-maxdelta)*ones(size(m));
figure(6);
errorbar(m,maxdelta,s2,'x');xlabel('m');ylabel('Max\DeltaE_a_b');

```

GRADIENTE DESCENDENTE

```
clc
clear all
close all
cd C:\Users\ACER\Desktop
%=====
%Datos de entrada y su normalización
%=====
P=textread('RGB.txt'); P=P/255; %Entradas normalizadas (Valores RGB)
T=textread('XYZ.txt'); % Valores objetivo (Valores XYZ)
%=====
%Inicialización de pesos y bias para la capa de entrada y la capa
oculta
%=====
raiz=400; % generador de números aleatorios
[FI CI]=size(P);
nco=5; %Número de neuronas de la capa oculta
rand('twister',raiz); W1=rand(CI,nco);
rand('twister',raiz); b1=rand(1,nco);
rand('twister',raiz); W2=rand(nco,CI); %Pesos que relacionan la capa
oculta con la capa de salida
rand('twister',raiz); b2=rand(1,CI) ;% bias de la capa oculta
%Parámetros de entrenamiento
minerror=1e-6;
maxierror=1e-1;
maxiepoca=1000;
epoca=0;
c=1;
alfa=0.1;
figure(1);
Eq=1e-1;
semilogy(epoca,Eq,'-'); grid on; axis([0 maxiepoca minerror
maxierror]);
xlabel('Épocas'); ylabel('Error de desempeño');
hold on
while ((Eq>minerror)&&(epoca<maxiepoca)) ;
    for i=1:FI
        Op=sigmoidea(P,W1,b1); % función de activación primera capa
        Oq=lineal(Op,W2,b2); Oq=Oq';
        %%Cálculo del error cuadrático medio total%%
        Eq=sum(sum((T-Oq).^2))/(CI*FI);
        %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
        dM=-(T(i,:)-Oq(i,:));dM=dM';
        d2= repmat(Op(i,:).*(1-Op(i,:)),nco,1).*eye(nco)*(W2*dM);
        dVdW2=dM*Op(i,:);
        dW2=-alfa*dVdW2 ;
        dVdb2=dM;
        db2=-alfa*dVdb2';

        dVdW1=d2*P(i,:);
        dW1=-alfa*dVdW1;
        dVdb1=d2;
        db1=-alfa*dVdb1';

        b2=b2+db2;
        b1=b1+db1;
        W2=W2+dW2';
```

```

        W1=W1+dW1';
    end
    epoca=epoca+1;
    epoc(c)=epoca;
    c=c+1;
    drawnow
    semilogy(epoca,Eq, '-'); grid on; axis([0 maxiepoca minerror
maxierror]);
end
Eq
%=====
%Grupo de prueba
%=====
PP=textread('RGBP.txt'); PP=PP/255;
OpP=sigmoidea(PP,W1,b1);
OqP=lineal(OpP,W2,b2);

figure (2);
plot3(PP(:,1),PP(:,2),PP(:,3),'ok'); grid on; hold on
plot3(OqP(1,:),OqP(2,:),OqP(3:),'*r');
xlabel('X'); ylabel('Y'); zlabel('Z');
legend('Objetivos','Respuestas')
%=====
%Delta Eab
%=====
for n=1:length(Oq)
    Laexp(n,:)=labc3(Oq(n,:), 'D65');
end
OqP=OqP';
for n=1:length(OqP)
    LaexpP(n,:)=labc3(OqP(n,:), 'D65');
end
cd C:\Users\ACER\Desktop
Lateo=textread('Lateo.txt');
LateoP=textread('LateoP.txt');
d=(sqrt(sum((Lateo-Laexp).^2,2)));
deltas=['mean(d)=', num2str(mean(d)), '    max(d)=', num2str(max(d)), '
min(d)=', num2str(min(d)), '    std(d)=', num2str(std(d))];
disp(deltas)
dP=(sqrt(sum((LateoP-LaexpP).^2,2)));
deltasP=['mean(dP)=', num2str(mean(dP)), '    max(dP)=',
num2str(max(dP)), '    min(dP)=', num2str(min(dP)), '    std(dP)=',
num2str(std(dP))]; disp(deltasP)
%HISTOGRAMAS%
figure(3);
c=1;
for i=1:length(d)-1
    if d(i)<=60
        a(c)=d(i);
        c=c+1;
    else
        s(c)=d(c);
    end
end
end
xh=0:3:60;
hist(a,20,xh)
h=findobj(gca, 'Type', 'patch');

```

```

set(h, 'Facecolor', 'w', 'EdgeColor', 'k');
xlabel('\DeltaE_a_b')
ylabel('Población'), title('Entrenamiento'), legend(['\DeltaE_a_b para red 3-', num2str(nco), '-3'])
figure(4);
c=1;
for i=1:length(dP)-1
    if dP(i)<=60
        aP(c)=dP(i);
        c=c+1;
    else
        sP(c)=dP(c);
    end
end
end
xh=0:3:60;
hist(aP,20,xh)
h=findobj(gca, 'Type', 'patch');
set(h, 'Facecolor', 'w', 'EdgeColor', 'k');
xlabel('\DeltaE_a_b')
ylabel('Población'), title('Prueba'), legend(['\DeltaE_a_b para red 3-', num2str(nco), '-3'])

```

NEWFF

```

clc
clear all
close all

cd 'C:\Users\ACER\Desktop'
P=textread('RGB.txt'); P=P/255; %Entradas normalizadas (Valores RGB)
T=textread('XYZ.txt'); % Valores objetivo (Valores XYZ)
P1=[0 1;0 1;0 1];
T1=[0 1;0 1;0 1];
P=P';
T=T';

raiz=400;
%for nco=5:5:10
nco=6;
S=nco;
net=newff(P1,T1,S);
rand('twister',raiz),net.IW{1}=rand(size(net.IW{1}));
rand('twister',raiz),net.LW{2,1}=rand(size(net.LW{2,1}));
rand('twister',raiz),net.b{1}=rand(size(net.b{1}));
rand('twister',raiz),net.b{2}=rand(size(net.b{2}));
net.trainParam.epochs=1000;
net.performFcn='mse';
net.trainParam.time=inf;
net.trainParam.goal=0.001;
net.trainParam.max_fail=5;
net.trainParam.mem_reduc=1;
net.trainParam.min_grad=1e-6;
net.trainParam.mu=0.001;

```

```

net.trainParam.mu_dec=0.1;
net.trainParam.mu_inc=10;
net.trainParam.mu_max=1e10;
net.trainParam.show=1;
net.divideFcn='';

[net,tr]=train(net,P,T);

oq=sim(net,P);
PP=textread('RGBP.txt'); PP=PP/255; PP=PP';
oqP=sim(net,PP);

figure(2);
plot3(PP(1,:),PP(2,:),PP(3:,:), 'ok'); grid on; hold on
plot3(oqP(1,:),oqP(2,:),oqP(3:,:), '*r');
xlabel('X'); ylabel('Y'); zlabel('Z');
legend('Objetivos','Respuestas')
%=====
%Delta Eab
%=====
oq=oq';
for n=1:length(oq)
    Laexp(n,:)=labc3(oq(n,:), 'D65');
end
oqP=oqP';
for n=1:length(oqP)
    LaexpP(n,:)=labc3(oqP(n,:), 'D65');
end
cd C:\Users\ACER\Desktop
Lateo=textread('Lateo.txt');
LateoP=textread('LateoP.txt');
d=(sqrt(sum((Lateo-Laexp).^2,2)));
deltas=['mean(d)=', num2str(mean(d)), '    max(d)=', num2str(max(d)), '
min(d)=', num2str(min(d)), '    std(d)=', num2str(std(d))];
disp(deltas)
dP=(sqrt(sum((LateoP-LaexpP).^2,2)));
deltasP=['mean(dP)=', num2str(mean(dP)), '    max(dP)=',
num2str(max(dP)), '    min(dP)=', num2str(min(dP)), '    std(dP)=',
num2str(std(dP))]; disp(deltasP)
%HISTOGRAMAS%
figure(3);
c=1;
for i=1:length(d)-1
    if d(i)<=60
        a(c)=d(i);
        c=c+1;
    else
        s(c)=d(c);
    end
end
end
xh=0:3:60;
hist(a,20,xh)
h=findobj(gca,'Type','patch');
set(h,'Facecolor','w','EdgeColor','k');
xlabel('\DeltaE_a_b')
ylabel('Población'), title('Entrenamiento'), legend(['\DeltaE_a_b para
red 3-', num2str(nc), '-3'])
figure(4);

```

```

c=1;
for i=1:length(dP)-1
    if dP(i)<=60
        aP(c)=dP(i);
        c=c+1;
    else
        sP(c)=dP(c);
    end
end
end
xh=0:3:60;
hist(aP,20,xh)
h=findobj(gca,'Type','patch');
set(h,'Facecolor','w','EdgeColor','k');
xlabel('\DeltaE_a_b')
ylabel('Población'), title('Prueba'), legend(['\DeltaE_a_b para red 3-
', num2str(nc), '-3'])

```