

Caracterización espectral de un escáner a partir de las señales RGB y HSV

Spectral characterization of flatbed scanner from RGB and HSV signals

Jáder Guerrero Bermúdez Ph. D.¹, Física. Alexandra Plata Planidina F.¹, Enrique Mejía Ospino Ph. D.², Rafael Cabanzo Hernández M. Sc.²

1. GOTS, Grupo de Óptica y Tratamiento de Señales, Escuela de Física

2. LEAM, Laboratorio de Espectroscopía Atómica y Molecular, Escuela de Física y Escuela de Química
Facultad de Ciencias - Universidad Industrial de Santander, Colombia
jader@uis.edu.co

Recibido para revisión 01 de septiembre de 2009, aceptado 28 de octubre de 2010, versión final 02 de noviembre de 2010

Resumen— Se entiende por caracterización espectral de un escáner la obtención de coordenadas de la imagen explorada de un objeto cromático, en espacios de color estándar a partir de las coordenadas rojo, verde y azul RGB (Red, Green, Blue) o los atributos tono, saturación y valor, HSV (Hue, Saturation, Value). Este proceso facilita la comunicación entre el escáner y otros dispositivos de despliegue e impresión de imágenes, al mismo tiempo que aumenta la fidelidad en la reproducción del color. En este trabajo se calibró un escáner a color, Canon Lide 20, utilizando muestras del Atlas del Color, NCS (Natural Color System). El procedimiento se basa en la asociación de las señales cromáticas del sensor del escáner, RGB y HSV de la imagen, con los coeficientes que ponderan una base vectorial obtenida por análisis de componentes principales de un conjunto de muestras del atlas. Esta asociación se desarrolla mediante una red neuronal artificial de propagación hacia delante que usa para su entrenamiento la estrategia de propagación hacia atrás de errores. El desempeño del proceso se evalúa mediante el cálculo del error espectral cuadrático medio y la fórmula de diferencia color CIEDE2000. Los resultados son comparables a los reportados con otros procedimientos basados tanto redes neuronales como en regresión mediante polinomios.

Palabras Clave— Espectros de Reflectancia, Calibración de un Escáner a Color, Redes Neuronales Artificiales.

Abstract—Spectral characterization of a flatbed color scanner allows obtaining the spectral reflectance of an object from color space dependent on the device, i.e. RGB values or attributes HSV. In this work, a color scanner, Canon Lide 20, was calibrated using a set of color chips in the natural color system (NCS) Color Atlas. The procedure is based on the combination of chromatic signals, RGB and HSV of the scanned image, with the coefficients obtained by principal component analysis of a set of samples of the atlas. This relation is developed through a backpropagation artificial

neural network. The performance of this process is assessed by calculating the spectral root mean square error and color difference formula CIEDE2000. The results show that it is feasible to calibrate a scanner in order to predict spectral reflectance curves.

Keywords— Spectral Reflectance, Color Scanner Calibration, Artificial Neural Network.

I. INTRODUCCIÓN

Un escáner plano es un dispositivo que permite la exploración, registro y reproducción de imágenes ópticas de objetos de naturaleza bidimensional. Con el propósito de aumentar la fidelidad en las tareas de archivo, despliegue y comunicación de los documentos explorados, resulta importante su caracterización espectral y colorimétrica, procedimiento que implica la obtención de las coordenadas en espacios de color independientes del dispositivo *CIE XYZ/Lab* a partir de las coordenadas rojo, verde y azul (*RGB*) [1-3].

Existen numerosas técnicas para la calibración y la caracterización espectral cromática de un escáner [4-6], la mayoría se fundamenta en un catálogo estándar o carta patrón de muestras coloreadas y algoritmos de regresión mediante polinomios en el sentido de mínimos cuadrados, interpolación y redes neuronales [7-12]. En este trabajo se presenta un procedimiento que relaciona las señales (*RGB*) y los atributos tono, saturación y valor (*HSV*) de las muestras, con escalares que ponderan una base vectorial, obtenida mediante análisis de componentes principales de un conjunto de espectros de reflectancia. El mapeo entre los espacios de color *RGB/HSV* y las componentes principales se modela mediante el

entrenamiento de una red neuronal artificial con entrenamiento de propagación hacia delante y estrategia de aprendizaje, la propagación hacia atrás de errores con algoritmo de optimización de *Levenberg-Marquardt*.

La novedad del procedimiento propuesto reside en la consideración de los atributos del color, coordenadas del espacio *HSV*, en la capa de entrada de la red neuronal. Los indicadores de desempeño para la reconstrucción espectral y del color, error espectral cuadrático medio y la fórmula de diferencia color *CIEDE2000*, se encuentran dentro de los márgenes de incertidumbre reportados en trabajos previos de calibración de escáner [9] para los conjuntos de entrenamiento, prueba y validación de la red.

II. MARCO TEÓRICO

El análisis de componentes principales (ACP) es la transformación lineal con matriz asociada formada por los vectores propios o característicos de la correlación o alternativamente de la covarianza de un arreglo de observaciones. Los vectores propios que corresponden a los mayores autovalores retienen las características más importantes del grupo original de datos; por tanto, tomando algunos pocos vectores característicos es posible reducir la dimensionalidad de las observaciones. Esta descripción resulta apropiada para la representación de una curva suave, como es el caso de la reflectancia espectral.

Consideremos el arreglo $\mathbf{r}_{1 \times N}$ una versión discreta de un espectro de reflectancia de la superficie de un objeto, muestreado en N longitudes de onda $[\lambda_1, \lambda_2, \dots, \lambda_N]$ del dominio visible del espectro. Disponiendo un conjunto de M espectros de reflectancia espectral en las filas de una matriz, incluyendo el ruido experimental del muestreo, se obtiene el arreglo $\mathbf{R}_{M \times N}$, que constituye el conjunto original de datos. Cada fila de $\mathbf{R}_{M \times N}$ es una curva espectral y cada columna se asocia a una longitud de onda.

La matriz $\mathbf{C}_{N \times N}$, que contiene las correlaciones entre los espectros de reflectancia se calcula con la expresión (1), [9].

$$\mathbf{C}_{N \times N} = \frac{1}{N-1} (\mathbf{R}_{N \times M}^T \mathbf{R}_{M \times N}) \quad (1)$$

El superíndice T en la ecuación anterior indica la matriz transpuesta. Los N vectores propios $\mathbf{v}_{N \times 1}$, de la matriz $\mathbf{C}_{N \times N}$, conforman una base vectorial ortonormal. Estos vectores pueden ser arreglados en sentido decreciente de sus respectivos autovalores, en las columnas de la matriz $\mathbf{V}_{N \times N}$.

La combinación lineal de los vectores propios, ponderados por un conjunto de N escalares, reconstruye exactamente el grupo original de datos. Estos escalares forman un vector $\mathbf{s}_{1 \times N}$, cuyas componentes caracterizan un espectro de reflectancia en la nueva base vectorial. Disponiendo los vectores $\mathbf{s}_{1 \times N}$ correspondientes a cada reflectancia, en M filas de la matriz $\mathbf{S}_{M \times N}$, podemos obtener la matriz original de datos, mediante el producto,

$$\mathbf{R}_{M \times N} = \mathbf{S}_{M \times N} \mathbf{V}_{N \times N} \quad (2)$$

Los vectores $\mathbf{s}_{1 \times N}$, que representan cada espectro de reflectancia, se calculan invirtiendo la matriz $\mathbf{V}_{N \times N}$ en la ecuación anterior.

La reducción de la dimensionalidad se obtiene conformando la matriz $\mathbf{V}_{p \times N}$, a partir de un subconjunto de p ,

($p < N$), vectores propios; aquellos con los correspondientes autovalores más altos, que permiten estimar con la precisión suficiente el conjunto original de reflectancias.

Análogamente, como en la ecuación (2), la reflectancia estimada $\hat{\mathbf{R}}_{M \times N}$, se obtiene mediante

$$\hat{\mathbf{R}}_{M \times N} = \mathbf{S}_{M \times p} \mathbf{V}_{p \times N} \quad (3)$$

La matriz $\mathbf{S}_{M \times p}$, cuyas filas son los vectores $\mathbf{s}_{1 \times p}$, que representan respectivamente una reflectancia en la nueva base vectorial, se calcula teóricamente según:

$$\mathbf{S}_{M \times p} = \hat{\mathbf{R}}_{M \times N} \text{pinv}(\mathbf{V}_{p \times N}) \quad (4)$$

En la ecuación anterior, $\text{pinv}(\mathbf{V}_{p \times N})$, representa la pseudo-inversa de la matriz $\mathbf{V}_{p \times N}$.

La elección de p determina la dimensión del nuevo espacio vectorial. La cantidad p , puede estimarse de acuerdo al índice acumulativo de varianza. En teoría pocos componentes principales, entre seis y nueve, logran explicar, generalmente, el 99% de la varianza de un conjunto de datos.

La otra herramienta utilizada en este estudio es una red neuronal artificial (RNA) tipo *back-propagation*. El entrenamiento de esta RNA mapea las señales de color de la muestra, dependientes del dispositivo *RGB/HSV*, con el vector de escalares $\mathbf{s}_{1 \times p}$, que representa la reflectancia espectral en el espacio de componentes principales del conjunto original de datos.

Dos modelos se trabajaron en la capa de entrada de la RNA; uno de ellos tenía como neuronas en la capa de entrada de la red los tres (3) valores del espacio *RGB*. En el segundo modelo, se presentaron seis (6) neuronas en la capa de entrada de la red: los tres valores *RGB* y los tres atributos *HSV*. La salida contenía seis (6) neuronas en ambos casos. [9,12]

Sistemáticamente se exploraron diferentes tipos de arquitectura, en cuanto al número de capas ocultas y neuronas por capa, con énfasis en redes de una y dos capas. Durante todo el experimento, las matrices de pesos y tendencias iniciales (*bías*) fueron las mismas para todas las arquitecturas, este aspecto es especialmente importante para establecer comparaciones. Se fijó en 1000 el número máximo de épocas, aunque algunas configuraciones lograron una convergencia, con anterioridad en el indicador de desempeño, que se estimaba mediante el error cuadrático medio entre los escalares obtenidos por ACP y los predichos por la red para un conjunto de coordenadas color dado. Las funciones de transferencia fueron: lineal en la capa de entrada y salida, y tangente sigmoidea para capas ocultas.

III. PROTOCOLO EXPERIMENTAL

Para calibrar el escáner a color, plano, *Canon Lide 20* se utilizaron muestras de la segunda edición del Atlas del Color del *NCS (Natural Color System)* [13]. Esta edición del atlas tiene una población de 1526 elementos cromáticos, incluyendo grises desde el 5% hasta el 95% de claridad, ordenados sistemáticamente y codificados de acuerdo a sus atributos de negrura, croma y tono. Cada elemento es un cuadrado de color sólido, área 10 mm x 14 mm, soportado en papel laqueado con pintura opaca semimate. La designación de color del sistema comprende el porcentaje de negrura, el valor cromático y el tono. Por ejemplo: NCS 2040-Y10R, significa, 20% de negrura, 40% de croma; el tono corresponde a 10% de rojo y 90% de amarillo.

Las muestras utilizadas corresponden a los siguientes tonos: Y50R, R20B, R50B, B, B60G, B70G, G20Y, G80Y y adicionalmente cuarenta elementos sobre el plano ecuatorial del *NCS*, con contenido cromático entre el 60% y 80% correspondientes a cada uno de los tonos en el atlas. Esta colección de 251 cuadrados ha sido usada en trabajos previos de calibración de escáner [9] y constituye una *muestra de conveniencia*, que produce los mejores resultados en el proceso de entrenamiento y prueba de las redes neuronales.

La población de muestras se dividió, alternando los matices, en 126 elementos para el entrenamiento de la red y 125 para la prueba del procedimiento. Además, se seleccionó de manera aleatoria un conjunto de 153 elementos para la generalización o validación de la calibración. Los tonos correspondientes a este grupo son: Y70R, R70B, B50G, G40Y. El grupo de generalización

no participó en ninguna de las etapas de la calibración del escáner y tiene como objetivo establecer márgenes de incertidumbre del proceso.

Las muestras se manejaron de dos maneras: por un lado, se obtuvieron sus coordenadas *RGB*, explorando su imagen mediante el sensor *CCD (Charge-coupled device)* del escáner, con una resolución de 300 puntos por pulgada (dpi), digitalizadas a 256 niveles de gris, [0 255], para cada uno de sus canales cromáticos, rojo, verde y azul. Las coordenadas en el espacio *HSV* se calcularon a partir de las coordenadas *RGB*, mediante expresiones bien conocidas [3]. Todas las coordenadas de color, antes de cualquier proceso, se normalizaron en el rango [0 1]. Antes de iniciar la caracterización cromática, debe asegurarse que el escáner tiene deshabilitados las funciones de balance de blanco y cualquier otra relacionada con el ajuste automático de intensidad.

Por otro lado, se registraron los espectros de reflectancia respectivos de cada muestra mediante un espectrofotómetro *Ocean Optics USB4000*, acoplado por medio de una fibra óptica a una esfera integradora *Ocean Optics ISP-REF*. La esfera adopta la geometría $8^\circ/d$, de la *CIE (Commission Internationale d'Eclairage)* para iluminación y recepción de la luz reflejada por la muestra. Inicialmente, los espectros se registraron en 3648 datos en el rango de 350 nm hasta los 1000 nm, luego fueron normalizados a valores [0 1] y submuestreados en el intervalo 400 a 700 nm a paso de 1 nm.

A partir de estos datos se conformó la matriz $\mathbf{R}_{M \times N}$, permitiendo encontrar las componentes principales, asociadas con sendas señales *RGB* ó *RGB-HSV*, mediante el entrenamiento de una RNA. El procedimiento se programó en el entorno MATLAB™, (*Mathworks Inc*).

IV. RESULTADOS

En la Tabla 1 se exhibe el desempeño teórico del análisis de componentes principales para la colección de prueba y entrenamiento, en términos de los promedios del error espectral cuadrático medio \overline{SRMS} y de la diferencia de error colorimétrico $\overline{\Delta E_{00}}$ (*CIEDE2000*) con iluminante D50 y observador de 2° (ó *CIE1931*). Los *factores paramétricos* en la fórmula de ΔE_{00} se asumen iguales a la unidad. Estos valores establecen los límites teóricos para la calibración para este procedimiento. También se presentan, en esta tabla, las respectivas desviaciones y valores máximos de estas métricas de desempeño. El número de vectores principales de la base es seis.

Tabla 1. Desempeño teórico de la reconstrucción por Análisis de Componentes Principales.

| \overline{SRMS} | Desv. SRMS | Max. SRMS | $\overline{\Delta E_{00}}$ | Desv. ΔE_{00} | Max. ΔE_{00} |
|-------------------|------------|-----------|----------------------------|-----------------------|----------------------|
| 0.011 | 0.006 | 0.044 | 0.599 | 0.947 | 9.273 |

Tabla 2. Resultados de las arquitecturas de las redes exploradas para los grupos de entrenamiento y prueba.

| Entrada: señal RGB - HSV | | | | |
|--------------------------|------------------------|----------------------------|-------------------|----------------------------|
| RNA | Grupo de Entrenamiento | | Grupo de prueba | |
| | \overline{SRMS} | $\overline{\Delta E_{00}}$ | \overline{SRMS} | $\overline{\Delta E_{00}}$ |
| 6-5-6 | 0,016 | 2,774 | 0,026 | 3,970 |
| 6-10-6 | 0,013 | 2,332 | 0,033 | 5,446 |
| 6-20-6 | 0,012 | 2,063 | 0,032 | 5,413 |
| 6-30-6 | 0,012 | 1,799 | 0,031 | 4,677 |
| 6-40-6 | 0,012 | 1,886 | 0,029 | 4,785 |
| 6-50-6 | 0,012 | 1,884 | 0,035 | 6,175 |
| 6-60-6 | 0,012 | 1,687 | 0,035 | 5,901 |
| 6-70-6 | 0,012 | 1,653 | 0,031 | 5,590 |
| 6-80-6 | 0,010 | 1,708 | 0,045 | 9,988 |
| 6-10-10-6 | 0,012 | 2,067 | 0,028 | 4,517 |
| 6-20-20-6 | 0,012 | 1,991 | 0,033 | 5,407 |
| 6-30-30-6 | 0,012 | 1,805 | 0,040 | 6,925 |

Los promedios de estas métricas, en los grupos de prueba y entrenamiento, para algunas arquitecturas de RNA exploradas se muestran en la Tabla 2. Se aprecia en esta tabla, para las muestras de entrenamiento y en las redes de una sola capa oculta, que el \overline{SRMS} y $\overline{\Delta E_{00}}$ tienden a valores pequeños en la medida en que se incrementa el número de neuronas en esta capa. El valor de estas mismas métricas para los grupos de prueba y validación, tiende a crecer cuando se incrementa el número de neuronas en la capa oculta.

Ahora bien, la elección de una determinada arquitectura debe guardar compromisos entre los grupos de entrenamiento, prueba y generalización. En ese sentido, la Tabla No.3 exhibe los promedios para todas las muestras con los dos modelos de datos de entrada utilizados.

Con el propósito de mostrar los alcances de este proceso de calibración espectral y cromática, en la Figura 1 se exhiben los histogramas del error ΔE_{00} , (CIEDE2000), para las poblaciones

Tabla 3. Resultados de las arquitecturas de las redes exploradas para todas las muestras.

| RNA | Entrada: señal RGB | | Entrada: señal RGB - HSV | | |
|-----------|--------------------|----------------------------|--------------------------|----------------------------|-------|
| | Todas las muestras | | Todas las muestras | | |
| | \overline{SRMS} | $\overline{\Delta E_{00}}$ | \overline{SRMS} | $\overline{\Delta E_{00}}$ | |
| 3-5-6 | 0,046 | 5,008 | 6-5-6 | 0,044 | 5,073 |
| 3-10-6 | 0,044 | 5,233 | 6-10-6 | 0,048 | 7,423 |
| 3-20-6 | 0,082 | 6,841 | 6-20-6 | 0,049 | 6,431 |
| 3-30-6 | 0,044 | 6,114 | 6-30-6 | 0,049 | 6,375 |
| 3-40-6 | 0,043 | 5,255 | 6-40-6 | 0,048 | 6,191 |
| 3-50-6 | 0,044 | 5,405 | 6-50-6 | 0,049 | 6,580 |
| 3-60-6 | 0,047 | 6,678 | 6-60-6 | 0,050 | 6,806 |
| 3-70-6 | 0,043 | 5,227 | 6-70-6 | 0,047 | 6,976 |
| 3-80-6 | 0,044 | 5,980 | 6-80-6 | 0,056 | 9,925 |
| 3-10-10-6 | 0,054 | 6,858 | 6-10-10-6 | 0,047 | 6,181 |
| 3-20-20-6 | 0,043 | 5,121 | 6-20-20-6 | 0,050 | 7,411 |
| 3-30-30-6 | 0,043 | 5,069 | 6-30-30-6 | 0,049 | 6,383 |

de entrenamiento, prueba y validación, cuando se usa la RNA 6-5-6. Esta arquitectura guarda un adecuado compromiso respecto a las métricas empleadas. Así mismo, en la Figura 2 se muestra una curva con, $\mu=0,243$ y $\sigma=0,0083$, reconstruida mediante esta misma arquitectura de red.




Figura 1. Histogramas del ΔE_{00} para las muestras de entrenamiento, prueba y validación con arquitectura de red neuronal artificial 6-5-6.




Figura 2. Ejemplo de reflectancia medida y reconstruida numéricamente

V. CONCLUSIONES

Se mostró que es factible calibrar y caracterizar espectral y cromáticamente un escáner asociando, mediante una red neuronal artificial, sus señales en los espacios *RGB* y *HSV* con un conjunto de escalares que ponderan una base vectorial obtenida por análisis de componentes principales.

Los promedios del error colorimétrico para la mayoría de las arquitecturas de redes examinadas, y para este tipo de muestras, indican que las diferencias en sensación cromática son *perceptibles pero aceptables* (error colorimétrico < 5 unidades ΔE_{00}).

Un análisis de los promedios globales hace evidente que todas las arquitecturas estudiadas exhiben un comportamiento comparable entre sí y a los reportados en la literatura, principalmente para la población de entrenamiento. Curvas con un alto índice de ajuste e histogramas del error muestran los alcances del procedimiento.

AGRADECIMIENTOS

Los autores agradecen a la VIE-UIS por financiar el proyecto 5162, marco para el desarrollo de este trabajo.

REFERENCIAS

[1] H.G. Völz, Industrial Color Testing. Fundamentals and Techniques. 2nd Ed. New York: Wiley-VCH, 2001, pp. 17-69.
 [2] S. Westland and C. Ripamonti, Computational Color Science using Matlab. Chichester: John Wiley and Sons, Ltd., 2004, pp 27 - 155.

[3] W.K. Pratt, Digital Image Processing. Third Edition. New York: John Wiley and Sons, Inc, 2001, pp 45 -88.
 [4] S. Miaohong and G. Healey, Using reflectance models for color scanner calibration, J. Opt. Soc. Am A., vol 19, no. 4, pp. 645-656, Apr., 2002.
 [5] W.K Pratt and C. Mancill, Spectral estimation techniques for the spectral calibration of a color image scanner, Applied Optics, vol. 15, no. 1, pp. 73-75, 1976.
 [6] H.L Shen and X. John, Spectral characterization of a color scanner by adaptive estimation, J. Opt. Soc. Am A., vol. 21, no.7, pp. 1125-1130, July 2004.
 [7] V. Cheung, S. Westland, D. Connah and C. Ripamonti, A comparative study of the characterization of colour cameras by means of neural networks and polynomial transforms, Coloration Technology, no. 120, pp 19-25, 2004.
 [8] R. Schettini, B. Barolo and E. Boldrin, Colorimetric calibration of color scanner by back-propagation, Pattern Recognition Lett., vol 10, no.16, pp. 1051-1056, Oct., 1995.
 [9] Y. Wang and H. Xu, Spectral characterization of scanner based on PCA and BP ANN, Chinese Optics Letters, vol 3, no. 12, pp. 725-728, Dec., 2005.
 [10] X. Li, "Scanner color management model based on improved back-propagation neural network, Chinese Optics Letters, vol. 6, no. 3, pp. 231-234, March 2008.
 [11] H. Kan and P. Anderson, Neural network applications to the color scanner and printer calibrations, Journal of Electronic Imaging, vol 1 no. 2, pp. 125-135, Apr., 1992
 [12] S. Usui, Y. Arai and S. Nakauchi, "Neural networks for device-independent digital color imaging," Information Science, vol 123, no. 1, pp. 115-125, Marc 2000
 [13] Scandinavian Color Institute AB, Colour Atlas. 2nd. Ed. Stockholm, 1989, pp 4-44.

Universidad Nacional de Colombia Sede Medellín

Facultad de Minas



Escuela de Ingeniería de Sistemas

Misión

La misión de la Escuela de Ingeniería de Sistemas es fomentar y apoyar la generación o la apropiación de conocimiento, la innovación y el desarrollo tecnológico en el área de ingeniería de sistemas e informática sobre una base científica, tecnológica, ética y humanística.



Visión

La formación integral de profesionales desde el punto de vista científico, tecnológico y social que les permita adoptar, aplicar e innovar conocimiento en el campo de los sistemas e informática en sus diferentes aspectos, aportando con su organización, estructuración, gestión, planeación, modelamiento, desarrollo, procesamiento, validación, transferencia y comunicación; para lograr un desempeño profesional, investigativo y académico que contribuya al desarrollo social, económico, científico y tecnológico del país.



Escuela de Ingeniería de Sistemas
Dirección Postal:
Carrera 80 No. 65 - 223 Bloque M8A
Facultad de Minas. Medellín - Colombia
Tel: (574) 4255350 Fax: (574) 4255365
Email: esistema@unalmed.edu.co
<http://pisis.unalmed.edu.co/>

