

Artículo Original

## Predicción del color y contenido de humedad en café cerezo mediante redes neuronales y regresión de mínimos cuadrados parciales

[Prediction of color and moisture content in coffee fruits by neural networks and partial least squares regression]

Wilson Manuel Castro Silupu\*, Ives Julian Yoplac Tafur, Cesar Augusto López Portocarrero

Facultad de Ingeniería Zootecnista, Agronegocios y Biotecnología. Universidad Nacional Toribio Rodríguez de Mendoza. Ciudad Universitaria S/N, Barrio Higos Urco, Chachapoyas – Amazonas.

\*e-mail: [wilson.castro@untrm.edu.pe](mailto:wilson.castro@untrm.edu.pe)

---

### Resumen

La presente investigación se enfocó en el desarrollo de modelos de predicción del color en coordenadas CIELab y el contenido de humedad de café cerezo mediante la tecnología de imágenes hiperespectrales; comparando el ajuste por un modelo de regresión lineal múltiple – PLSR (Partial least squares regression) y un modelo no lineal (ANN – artificial neural network). La muestra se conformó de 200 granos de café cerezo en diferentes estados de madurez, dividiéndola en 120 granos para calibración y 80 de validación. La muestra fue caracterizada mediante colorimetría en el espacio CIELab y determinación de la humedad. Posteriormente se adquirieron imágenes hiperespectrales de cada grano y se almacenaron en formato \*.bil. El procesamiento de las imágenes se realizó mediante un sistema desarrollado e implementado en el software matemático Matlab 2010a, mediante funciones \*.m e interfaces de usuario (GUIs). Se desarrollaron modelos de ajuste para cada una de las coordenadas de color y el contenido de humedad, calculándose los coeficientes de correlación en calibración y validación. Los resultados mostraron que las redes neuronales tienen un mayor ajuste en calibración con coeficientes de correlación superiores a 0,90 mientras que el PLSR generó coeficientes entre 0,42 y 0,48.

**Palabras clave:** ANN, CIELab, PLSR

### Abstract

This research was focused on the development of prediction models for colour in CIELab coordinates and the moisture content of coffee fruits by hyperspectral imaging technology; comparing the adjustment for multiple linear regression model - PLSR (Partial least square regression) and a nonlinear model (ANN - neural network artificial). The sample consisted of 200 coffee fruits at different stages of maturity, dividing it into 120 grains for calibration and validation 80. The sample was characterized by colorimetry in the CIELAB space and moisture determination. Later hyperspectral images of each grain is acquired and stored in \*.bil. The image processing was performed using a system developed and implemented in the mathematical software Matlab 2010a through functions \*.m and graphical user interfaces (GUIs). Were developed models for each of the colour coordinates and the moisture content and calculated the correlation coefficients for calibration and validation. The results showed that neural networks have a best adjustment in calibration with correlation coefficients higher than 0.90 while the PLSR produce ratios between 0.42 and 0.48.

**Keywords:** ANN, CIELab, PLSR

---

## INTRODUCCIÓN

En la industria agroalimentaria el desarrollo de sistemas de control de calidad eficaces y que garanticen la producción segura de alimentos durante las operaciones procesamiento es una de las metas más buscadas por los científicos de alimentos. En la actualidad muchos sistemas de inspección de calidad alimentaria se realizan por inspectores entrenados, lo cual es tedioso, laborioso, lento, costoso y sujeto a subjetividad y error humano. En este panorama el desarrollo de métodos automatizados de evaluación de la calidad optimiza el control del proceso y elimina la subjetividad y errores humanos. Es así que técnicas ópticas, no destructivas, tales como el análisis de imagen y la espectroscopia están disponibles actualmente para la determinación y aseguramiento de la calidad alimentaria (Pallotino, Menesatti, Costa, Paglia, De Salvador, 2010; Kumar and Mittal, 2007; Shankar, Sokhansanj, Bandyopadhyay, Bawa, 2010; Singh, Choudhary, Jayas, Paliwal, 2010). La simplicidad, precisión y rapidez así como el limitado nivel de preparación de las muestras hacen de las técnicas ópticas las más prometedoras en la determinación de las propiedades físicas y químicas de los productos agroalimentarios. De entre todas las técnicas ópticas las imágenes hiperespectrales acoplan tanto las ventajas de los sistemas de visión como la espectroscopia; proporcionando información del alimento, tanto espacial como espectral de manera simultánea. Esta técnica se puede definir como la "adquisición simultánea de imágenes espaciales en muchas bandas espectrales contiguas medidas a partir de una plataforma de operación remota" (Schaepman, 2007).

El principio básico de las imágenes hiperespectrales se basa en el hecho de que todas las muestras bajo análisis, reflejan, dispersan, absorben y emiten energía electromagnética obteniendo diferentes patrones en longitudes de onda específicas debido a la diferencia en la composición química y estructura física inherente de la muestra bajo análisis. Estas características se denominan firmas espectrales o espectros de huella digital. La firma espectral es la característica única de la muestra bajo análisis. Para un material dado, si el porcentaje de reflectancia (también absorbancia o transmitancia) se representa frente a la

longitud de onda, la curva resultante se conoce como la "firma espectral" de ese material" (Wu and Sun, 2013; Gómez, 2010).

Según Liu et al. (2013) un sistema de imágenes hiperespectrales compuesto por una cámara, un espectrógrafo, una lente, un sistema de iluminación y un ordenador equipado con un software de adquisición de imágenes. En el caso de sistemas de escaneo lineal (Pushbroom) la cámara es un detector bidimensional que recoge simultáneamente la información espectral y espacial, el espectrógrafo es el corazón del sistema, se caracteriza por no tener partes móviles para generar un espectro en cada punto o línea escaneada, la lente, delante del espectrógrafo, enfoca el haz de luz procedente de la muestra y la dispersa en diferentes direcciones de acuerdo con la longitud de onda. Las señales recogidas se expresan como imagen de dos dimensiones, una dimensión representa el eje espectral ( $\lambda$ ) y la otra contiene la dimensión espacial (X) de la línea analizada. La segunda dimensión espacial (Y) se genera mediante el movimiento de la muestra en la línea de la unidad óptica a lo largo de la escena, la resolución espectral del sistema depende de la resolución del espectrógrafo, la magnitud de la resolución espectral se determina por la anchura de la rendija del espectrógrafo y el tamaño de las aberturas de entrada y salida. Además la lente, la iluminación, el espectrógrafo y la cámara tienen que ser adaptados y seleccionados cuidadosamente entre sí para un análisis espectral en particular. En cuanto a las aplicaciones de las imágenes hiperespectrales, se ha demostrado gran potencial en la detección de defectos en frutos y hortalizas, en granos y alimentos procesados (Ariana and Lu, 2008), en la determinación de parámetros de calidad en manzana, fresa y naranja (Peng and Lu, 2008), en la clasificación de granos de trigo (Choudhary, Mahesh, Paliwal, Jayas, 2009; Mahesh, Manickavasagana, Jayasa, Paliwala, White, 2008; Windham, Heitschmidt, Smith, Berrang, 2005).

Entre las investigaciones que han evaluado parámetros composicionales mediante la tecnología de imágenes hiperespectrales se encuentra la de Noh and Lu (2007) que usando imágenes hiperespectrales de fluorescencia y reflectancia y modelo basado en inteligencia artificial, redes neuronales, en el intervalo de

500 - 1040 nm determinaron la firmeza, contenido de sólidos solubles totales y contenido de humedad en manzana Golden Delicious, obteniendo coeficientes de correlación entre 0.74 y 0.94. Por otro lado, Morgano, Faria, Ferrao, Bagagnolo and Ferreira (2008) determinaron el contenido de humedad en granos de café, utilizando espectroscopia de infrarrojo y cercano y un modelo PLSR se obtuvieron coeficientes de correlación de entre 0.26 y 0.56. En tanto Min, Qingguo and Min (2013) evaluaron el color y contenido de humedad durante el secado de soja vegetal mediante un modelo de regresión mediante PLSR en el rango de longitud de onda de entre 400 y 1000 nm, obteniendo coeficientes de correlación entre 0.83 y 0.91. Como se aprecia los estudios que utilizan la tecnología de imágenes hiperespectrales se apoyan en el análisis de la información obtenida mediante técnicas estadísticas como el PLSR o de inteligencia artificial como redes neuronales, una revisión que comenta algunas de las técnicas más usadas la presenta Wu and Sun (2013).

#### *Regresión de mínimos cuadrados parciales*

Este método estadístico permite transformar las variables de entrada X en la salida Y; en nuestro caso, X consistió en los valores de reflectancia para diferentes longitudes de onda (patrones) en varias posiciones en las muestras, mientras que Y son los valores de contenido de almidón. El PLSR descompone tanto X como Y mediante proyecciones ortogonales, con la restricción que la descomposición describa como las variables cambian tanto como sea posible. Después de la descomposición de las variables, hay un paso de regresión en el que se utiliza la descomposición de X para calcular el valor de Y. Sin embargo, el PLSR genera problemas cuando existe alta multi-colinealidad en la matriz X, como en el caso de los datos hiperespectrales, en los que el número de


longitudes de onda es mayor al de las muestras. En este caso se hace uso previamente del análisis de principales componentes (PCA) a fin de reducir la dimensionalidad y extraer componentes o longitudes de onda con los cuales se alimenta el modelo PLSR (Abdel-Rahman, Mutanga, Odindi, Adam, Odindo and Ismail 2014; Dai, Cheng, Sun, Zeng. 2014; Dai, Cheng, Sun, Zeng, Xiong, 2015, Fernandes, Lousada, Morais, Xavier, Pereira, Melo-Pinto, 2013). El modelo general se detalla en la figura 1.

#### *Redes neuronales*


Los avances en la capacidad de cómputo y sus aplicaciones, en los procesos de detección de patrones, han permitido el desarrollo de sistemas de clasificación y predicción basada en el reconocimiento de patrones, conocidos como redes neuronales (Daqrouq, Tutunji, 2015; Fernández et al., 2013; Nakano, 1997, Mizushima and Lu, 2013). Estos generan la toma de decisiones a partir de una base de datos con la información de casos preclasificados, la cual se compara con la información de entrada de nuevos casos (Omid, Khojastehnazhand, Tabatabaeefar, 2010; Pernkopf, Wohlmayr, 2013).

Las redes neuronales, inspirados inicialmente por el sistema nervioso humano, combinan la complejidad de las técnicas estadísticas con el auto-aprendizaje, imitando el proceso cognitivo humano. La figura 2 ilustra la topología típica de una estructura de red neural; toda la red es un conjunto muy complicado de interdependencias y puede incorporar algún grado de no linealidad (Abdel-Rahman et al., 2014; Nakano, 1997).

Como ambas técnicas han sido utilizadas en diversas investigaciones se ha propuesto en esta investigación comparar los resultados de la aplicación de ambas técnicas a la predicción de los parámetros de color y contenido de humedad en café cerezo.



**Figura 1.** Detalle del modelo PLSR



**Figura 2.** General Topología de la estructura de la red neural.  
Fuente: Alacalı, Akbaş, Doran (2011)

## MATERIALES Y MÉTODOS

### Material biológico


La muestra en estudio estuvo compuesta de 200 granos de café cerezo variedad arábica (*Coffea arabica* L.) colectados para el fin de esta investigación en campos de cultivo del distrito de Limabamba, provincia de Rodríguez de Mendoza del departamento de Amazonas en la temporada de cosecha 2015. La muestra se conformó por 60 granos pintones, 80 granos maduros y 60 sobremaduros; cuidado que Los granos seleccionados no mostrasen defectos, golpes, enfermedades ni agentes contaminantes y se dividieron en 120 para calibración y 80 de validación.

### Componentes y configuración del sistema de adquisición de imágenes hiperespectrales

En esta investigación se utilizó un sistema de adquisición de imágenes hiperespectrales,

adquirido a la empresa Resonon - USA, en modo de reflectancia con enfoque en línea (Pushbroom), en un rango de longitud de onda de 400-1000 nm.

Los elementos físicos o Hardware del sistema, modelo PIKA XC, se detallan a continuación: consta de una cámara CCD (charged coupled device) de alto rendimiento, un espectrógrafo unido a una lente de zoom, una fuente de iluminación, un ordenador para el control de la cámara y adquisición de las imágenes y una plataforma de manejo de la muestra. Asimismo, como parte del sistema se contó con el software de adquisición de imágenes Spectronon 2.61 de la empresa RESONON el cual permite establecer los parámetros de actuación de los componentes previamente mencionados durante la adquisición de las imágenes. En la figura 3 se pueden apreciar los principales componentes de este sistema.



**Figura 3.** Elementos del sistema de adquisición de imágenes hiperespectrales

## Metodología

La metodología empleada en esta investigación se dividió en las siguientes etapas:

### Preparación de muestra

A fin de preservar las muestras se procedió a lavar y desinfectar los granos con una solución de NaCl al 0,5%; posteriormente se almaceno en refrigeración a 12 °C y una humedad relativa de 95%.

### Caracterización de la muestra

Para la caracterización de las muestras se determinó el contenido de humedad en base húmeda (%), mediante el método 925.10 (ISP, 2015) y el color, expresado en unidades adimensionales para cada una de las coordenadas de color  $L^*$ ,  $a$  y  $b$ , mediante el método colorimétrico (Herrera, Torres, Tascón and Montoya, 2011).

### Adquisición de imágenes

Cada muestra se colocó en la plataforma de muestra para ser transportada a velocidad y tiempo de exposición ajustados al campo de visión de la cámara; esta información se almaceno que contenía la información de lectura o archivo de cabecera, en formato \*.hdr y un archivo con la información de cada pixel y sus respectivas bandas o canales en formato \*.bil. El procedimiento se controló mediante el software de adquisición de imágenes Spectronon2.61; el hipercubo se conformó por imágenes de intensidad en el rango de 400 a 1000 nm, en bandas distanciadas entre si cada una por 8 nm (75 bandas).

### Desarrollo e implementación de sistema de análisis de imágenes hiperespectrales de café cerezo

El análisis de imágenes obtenidas de cada grano se procesó mediante un sistema especialmente desarrollado e implementado, mediante funciones \*.m e interfaces graficas de usuario (GUIs), en el software matemático Matlab 2010a.

Este software posibilito las tareas de

a) Segmentación – la segmentación se basó en el método de segmentación por umbralizado; en el cual se utiliza la diferencia de contrastes entre el fondo y la muestra para seleccionar la ROI o región de interés que en este caso está compuesta por los pixeles que conforman a la muestra.

b) Extracción de información perfiles espectrales promedio – La información espectral se realizó ubicando puntos equidistantes entre el centro y el perímetro de la muestra y promediando los valores de reflectancia en cada banda para los diferentes pixeles. El resultado es el perfil espectral promedio.

c) Determinación de modelo de ajuste entre perfiles espectrales, humedad y color – El desarrollo de los modelos de ajuste entre los perfiles espectrales e información de color o humedad se basó en el empleo de métodos multivariados tales como las redes neuronales multicapa o PLSR.

### Comparación de métodos

Los modelos desarrollados fueron comparados mediante los valores del coeficiente de correlación ( $r^2$ ) obtenidos para cada uno de los parámetros en estudio.

## RESULTADOS Y DISCUSIONES

### Características de la muestra

Debido a que las muestras se colectaron a diferentes grados de madurez se estimó conveniente expresar los parámetros que caracterizan a la muestra mediante los histogramas de la figura 4.

Del histograma de la figura 4a se observa que la media de los parámetros de color obtenidos en esta investigación coincide con los reportados Carvajal, Aristizábal, Oliveros, Montoya and Wilson (2011); asimismo coinciden con el contenido de humedad reportado por Marín, Arcila, Montoya, Oliveros (2004) en las últimas etapas de maduración, véase tabla 1.

**Tabla 1.** Valor medio de los parámetros de color y humedad

Parámetro de color						Humedad	
$L^*$	$CV_L$ (%)	$a$	$CV_a$ (%)	$b$	$CV_b$ (%)	Media	$CV_{Humedad}$ $d$ (%)
30,6	11,2	13,2	34,3	8,8	45,9	68,3	3,9
30,5*	4,3*	9,7*	64,8*	2,8*	48,9*	68,7**	1,5**

Fuente: A partir de \*Carvajal et al. (2011) y \*\* Marín et al. (2004)

### *Adquisición de hipercubos*

En la figura 5 se muestran tanto la imagen RGB como algunas imágenes de intensidad de una de las muestras adquiridas en esta investigación.

Como es posible apreciar en la figura 5 las imágenes hiperespectrales se conforman de imágenes de intensidad para cada una de las 75 bandas; en el caso de la selección del número de bandas que conformaran el hipercubo está obedece a limitaciones del hardware o capacidad de computo.

### *Sistema de análisis de imágenes*

#### *hiperespectrales y desarrollo de modelos*

El sistema desarrollado se implementó en forma modular, mediante un único GUI en el cual se dispusieron botones de comando que habilitaron las diferentes opciones para el análisis de las imágenes. El funcionamiento del GUI se muestra en la figura 6.

Algunos de los principales programas informáticos utilizados para la aplicación de la tecnología de imágenes hiperespectrales y su aplicación en investigaciones recientes son Matlab, ENVI, Unscrambler, JMP y R, entre otros (Abdel-Rahman et al., 2014; Barbedo, Tibola and Fernández, 2015; Everard, Kim and Lee, 2014; Fernández et al., 2013; Mishra, Cordella, Rutledge, Barreiro, Roger, Diezma, 2016; Rud, Shoshany, Alchanatis, 2013; Simko, Jimenez-Berni, Furbank, 2015). Estos programas cuentan con rutinas preestablecidas para el pre-procesamiento y análisis de imágenes hiperespectrales o, en su defecto, debieron ser implementadas por los investigadores para las condiciones del muestreo y/o su posible uso como herramienta industrial. Algunos ejemplos de esto último serían el caso de la investigación de Gómez-Sanchis et al. (2010) quienes desarrollaron aplicaciones para la determinación de la calidad en cítricos o, más recientemente, Naganathan, Cluff, Samal, Calkins, Jones, Lorenzen and Subbiah (2015a,

2015b). quienes desarrollaron un sistema para el análisis de la ternura de carne de res. En ambos casos, los sistemas se implementaron mediante el software matemático Matlab, desarrollando funciones en lenguaje Script, de acuerdo a las necesidades de cada caso. Sin embargo, estas aplicaciones son esencialmente herramientas de laboratorio, sin miras al uso industrial o comercial, reduciendo por ende su impacto y es este el espacio que desea cubrir la aplicación desarrollada en esta investigación.

La información resultante, perfil espectral promedio de cada una de las muestras, se almacena en una hoja Excel para posteriormente utilizarlo en la etapa de desarrollo de modelos. En la figura 7 se muestran los perfiles espectrales ordenados de acuerdo a sus cambios en el color y humedad.

Estos perfiles coinciden con el reportado por Carbajal et al. (2011) para los frutos de café a los 230 de iniciada la antesis floral. Sin embargo; en dicho artículo no se menciona la ubicación de los puntos utilizados para obtener el perfil espectral, información que como menciona Gómez-Sanchis (2010) influencia en la percepción del espectro por efecto de la geometría del sólido y debe de corregirse o estandarizar la ubicación para la adquisición de la información espectral en las muestras en estudio. Esta última opción fue la considerada en el desarrollo del sistema; ubicando los puntos de muestreo equidistantes a 0,75 R desde el centro geométrico.

En cuanto a los modelos basados en redes neuronales y PLSR se procedió a construir estos modelos con la totalidad de longitudes de onda, el color y el porcentaje de humedad. Para la construcción de los modelos basados en redes neuronales se utilizaron los parámetros mencionados en la tabla 2.

**Tabla 2.** Parámetros utilizados para el desarrollo de los modelos de redes neuronales

Parámetro	Valor
Nº capas	= 2
Nº neuronas capa 1	= 75
Nº neuronas capa 2	= 1
Función de activación capa 1	= tansig
Función de activación capa 2	= lineal
Método de entrenamiento	= Levenberg – Marquadt
Nº muestras de entrenamiento	= 120
Nº muestras de validación	= 80

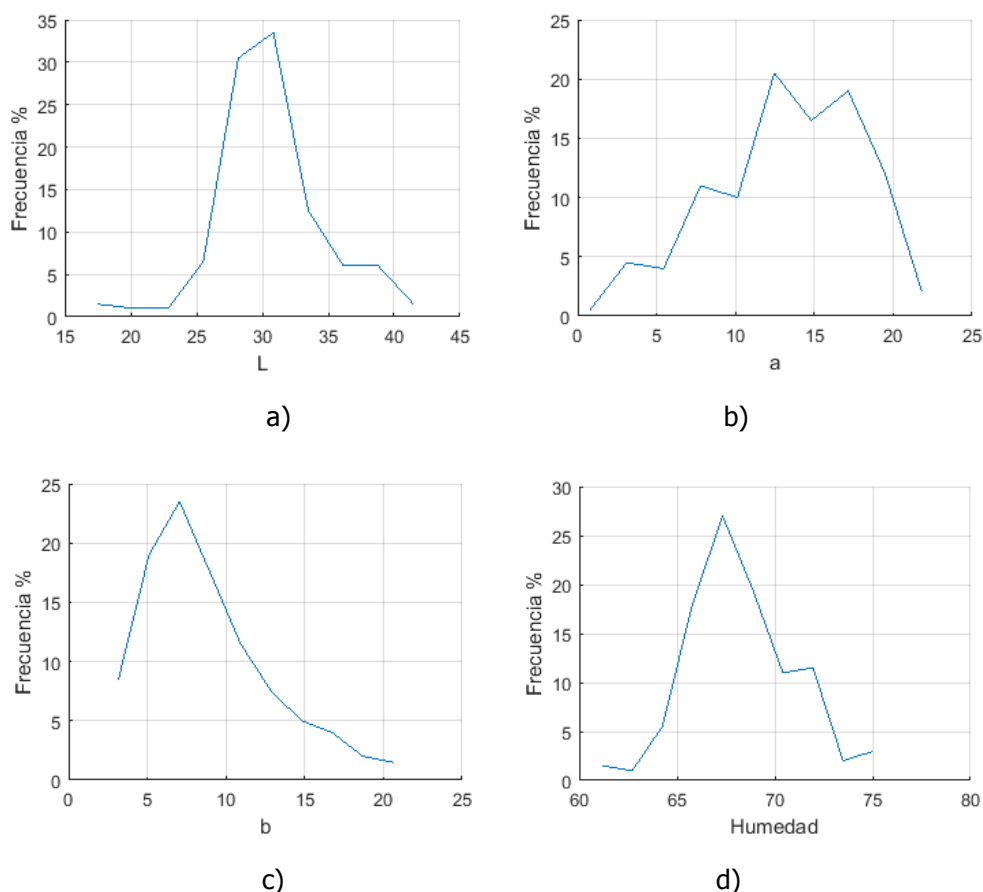
En cuanto al desarrollo del modelo PLSR se utilizó la función *plsregress*, precargada en el software matemático Matlab. Los resultados del ajuste de los modelos de redes neuronales y PLSR se muestran en la figura 8.

Los métodos de análisis aplicados a la tecnología de imágenes hiperespectrales han sido diversos; basado en regresiones lineales múltiples (PLSR- Partial Least Square Regression, SPLSR – Standarized Partial Least Square Regression, PCA – Principal Component Analysis), métodos no lineales (k-NN – k – Nearest Neighbor, ANN –Artifitial Neural Network, BN – Bayesina Network) y otros métodos (CCA–Canonical Correlation Analysis, SVM – Support Vector Machine) (Everar et al., 2014; Fernández et al., 2013; Misha et al., 2016; Mizushima and Lu, 2013; Naganathan et al., 2015a; Pernkopf and Wohlmayr, 2013; Simko et al., 2015).

#### Comparación de métodos


En la figura 9 se muestran los coeficientes de correlación para cada uno de los parámetros de color y humedad según modelos.

Como se aprecia de la figura 9 cada método permite obtener coeficientes de correlación tanto en calibración como en validación; observándose que las redes neuronales logran alcanzar los máximos valores de ajuste en la etapa de calibración; superior al 0,90 en cuanto al ajuste mediante PLSR se observa que se alcanzan valores entre 0,42 y 0,48. En todos los casos se muestra que hay una tendencia similar entre la calibración y la validación para ambos métodos y los diferentes parámetros en estudio. La mayoría de los estudios reportados muestran resultados en función del sistema utilizado y el método de análisis; realizad una revisión de las investigaciones en los últimos años se encuentra la investigación de Abdel-Rahman et al. (2014) quien predijo el rendimiento en campos de cultivo con diferentes tipos de agua de irrigación utilizando el PLSR y SPLSR; obteniendo coeficientes de correlación de 0,54-0,64 y 0,92-0,94 para cada método. De esta forma se demuestra que la elección del método de ajuste es decisiva en los resultados a obtener con la tecnología de imágenes hiperespectrales.

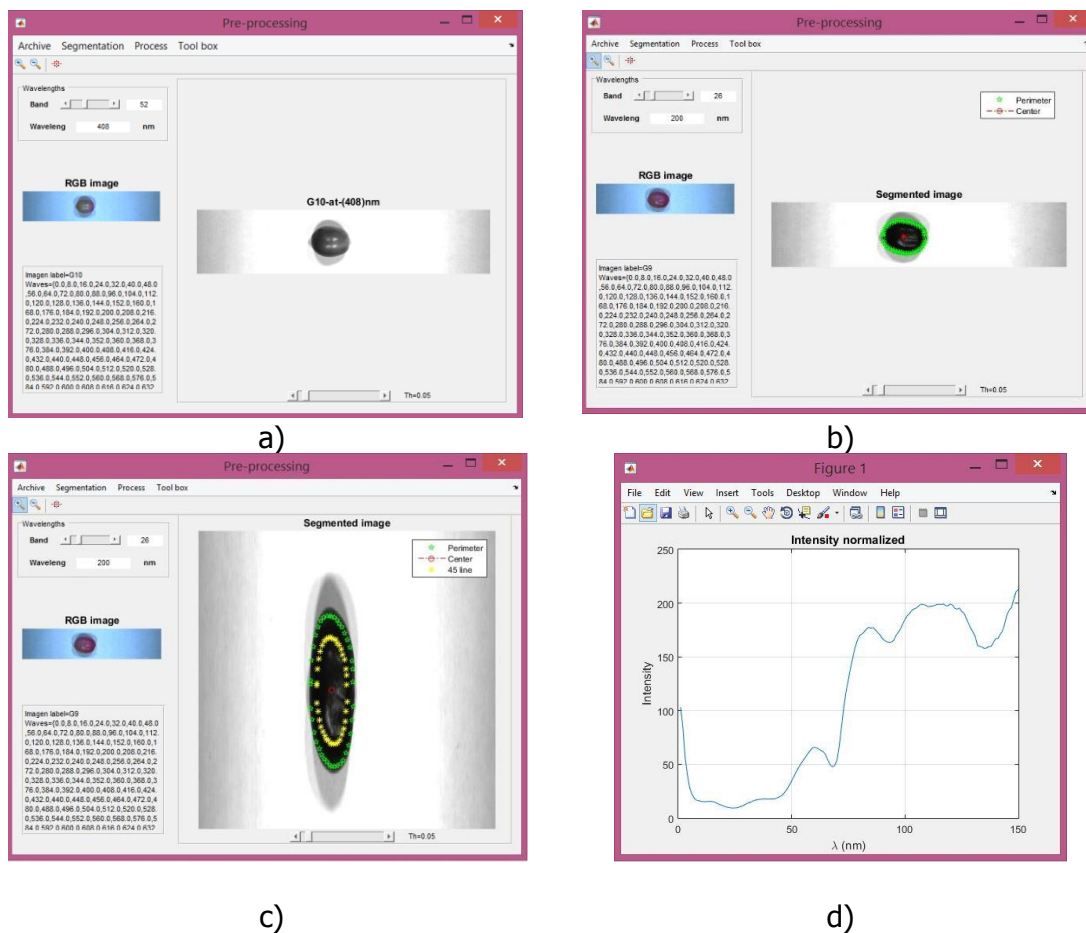


**Figura 4.** Histogramas de los parámetros en estudio a)  $L^*$ , b)  $a$ , c)  $b$ , d) Humedad

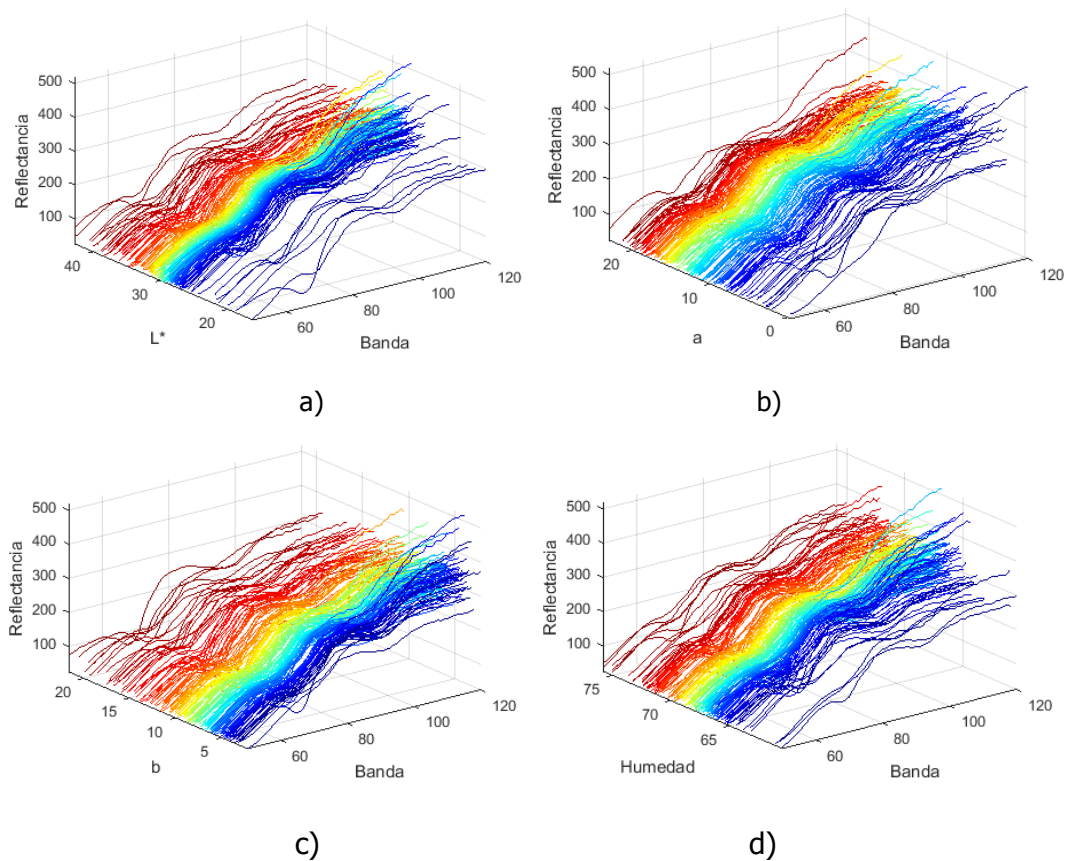




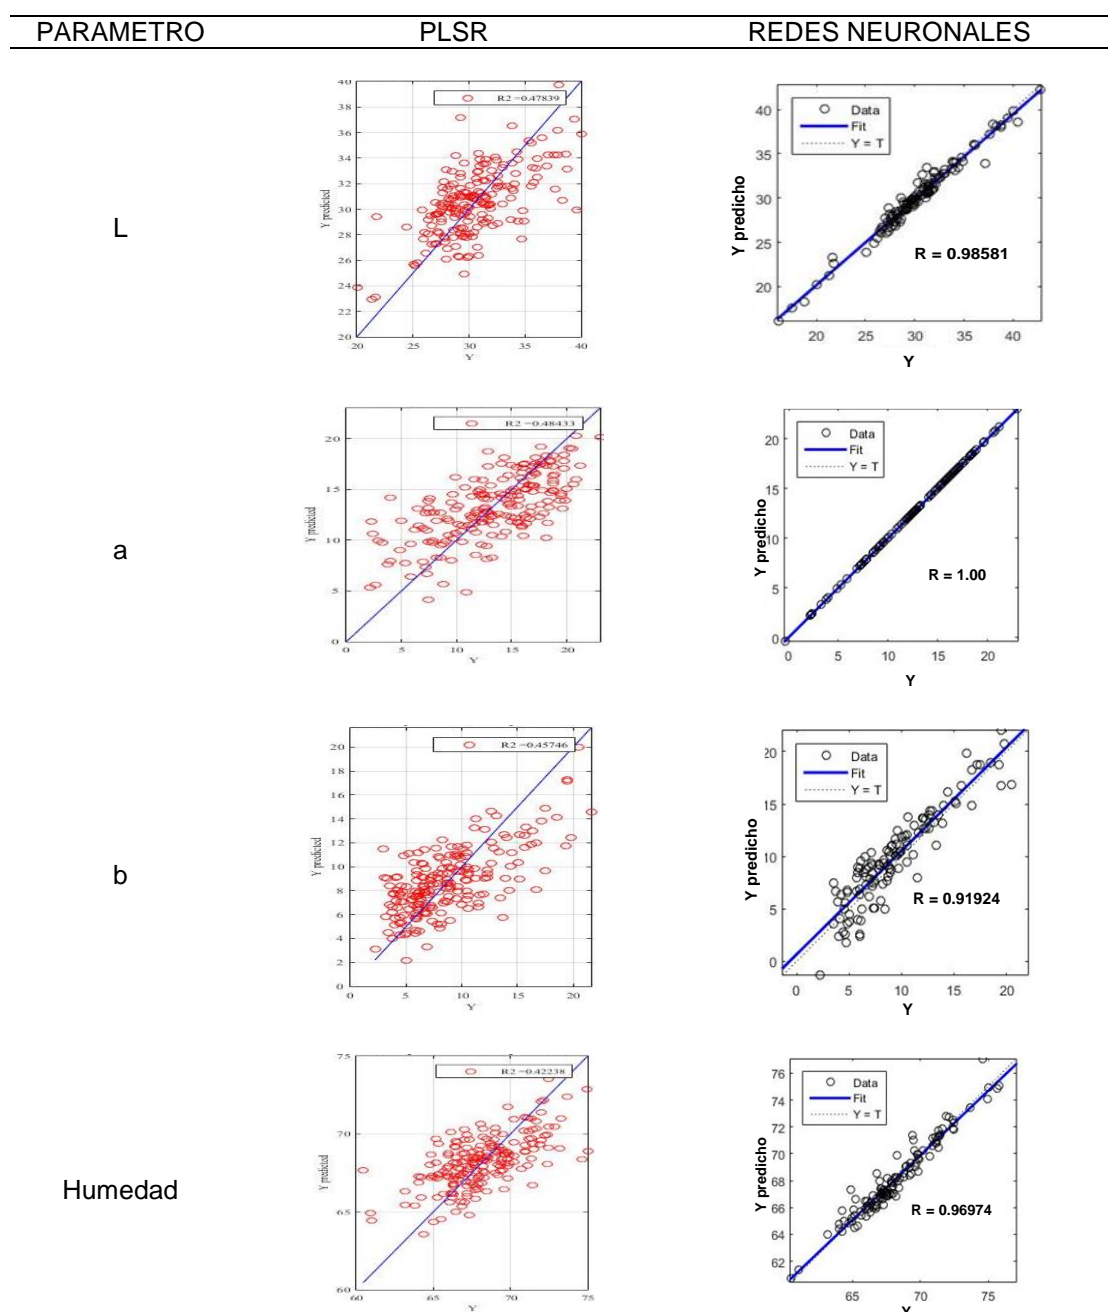
**Figura 5.** Imagen RGB e imágenes de intensidad a 400, 600 y 800 nm de un grano de café de la muestra



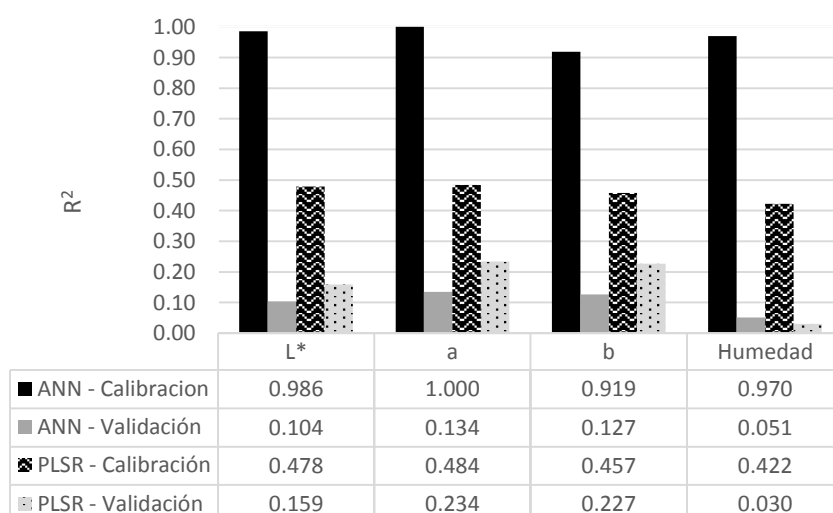
**Figura 6.** Vistas del uso del sistema desarrollado a) cargado de imagen b) resultado de la segmentación c) selección de puntos cálculo del perfil d) graficado del perfil espectral promedio



**Figura 7.** Perfiles espectrales para la muestra en estudio ordenada de acuerdo a parámetros de color y humedad



**Figura 8.** Y predicho vs Y real en la calibración de los modelos evaluados



**Figura 9.** Coeficientes de correlación para los modelos desarrollados y parameras en estudio

## CONCLUSIONES

El sistema desarrollado para esta investigación permite obtener la información espectral y generar modelos de ajuste para la predicción de las coordenadas de color y la humedad en café cerezo.

El coeficiente de ajuste de los modelos de predicción de las coordenadas de color y el contenido de humedad, mediante los perfiles espectrales de reflectancia, difieren de acuerdo al modelo a utilizar; obteniéndose mayores valores con redes neuronales en comparación con el método de mínimos cuadrados parciales.

## REFERENCIAS BIBLIOGRÁFICAS

- Abdel-Rahman E, Mutanga O, Odindi J, Adam E, Odindo A, Ismail R. 2014. A comparison of partial least squares (PLS) and sparse {PLS} regressions for predicting yield of Swiss chard grown under different irrigation water sources using hyperspectral data. *Comput Electron Agr.* 106: 11 – 19.
- Alacalı S, Akbaş B, Doran B. 2011. Prediction of lateral confinement coefficient in reinforced concrete columns using neural network simulation. *Appl Soft Computing.* 11: 2645–2655.
- Ariana D, Lu R. 2008. Detection of internal defect in pickling cucumbers using hyperspectral transmittance imaging. *Transactions of the ASABE*, 51: 705–713.
- Barbedo J, Tibola C, Fernandes J. 2015. Detecting Fusarium head blight in wheat kernels using hyperspectral imaging. *Biosyst Eng.* 131: 65 – 76.
- Carvajal J, Aristizábal I, Oliveros C, Montoya M, Wilson J. 2011. Coffee Fruit (*Coffea arabica* L.) Colorimetry During its Development and Maturation. *Revista Facultad Nacional de Agronomía, Medellín.* 64: 6229–6240.
- Choudhary R, Mahesh S, Paliwal J, Jayas D. 2009. Identification of wheat classes using wavelet features from near infrared hyperspectral images of bulk samples. *Biosyst Eng.* 102: 115–127.
- Dai Q, Cheng J, Sun D, Pu H, Zeng X, Xiong Z. 2015. Potential of visible/near-infrared hyperspectral imaging for rapid detection of freshness in unfrozen and frozen prawns. *J Food Eng.* 149: 97 – 104.
- Dai Q, Cheng J, Sun D, Zeng X. 2014. Potential of hyperspectral imaging for non-invasive determination of mechanical properties of prawn (*Metapenaeus*). *J Food Eng.* 136: 64 – 72.
- Daqrouq K, Tutunji T. 2015. Speaker identification using vowels features through a combined method of formants, wavelets, and neural network classifiers. *Applied Soft Computing*, vol. 27, 231–23.
- Everard C, Kim C, Lee H. 2014. A comparison of hyperspectral reflectance and fluorescence imaging techniques for detection of contaminants on spinach leaves. *J Food Eng.* 143: 139 – 145.
- Fernández A, Lousada J, Morais J, Xavier J, Pereira J, Melo-Pinto P. 2013. Comparison between neural networks and partial least squares for intra-growth ring wood density measurement with hyperspectral imaging. *Comput Electron Agr.* 94: 71 – 81.
- Gómez J. 2010. Detección automática de podredumbres en cítricos mediante procesamiento avanzado de imágenes hiperespectrales. Tesis de doctorado, Universitat de València
- Herrera J, Torres I, Tascón C, Montoya J. 2011. Colorimetría del fruto de café (*Coffea arabica* L.) durante su desarrollo y maduración. *Rev. Fac. Nal. Agr. Medellín.*, 64(2): 6229–6240.
- Instituto de Salud Pública (ISP). 2015. "Determinación de humedad en alimentos". <http://www.redlaboratorios.mx/wp-content/uploads/metodos/MetodosAnalisisHumedad.pdf> [Consultado agosto 2015]
- Kumar, S., Mittal, G. (2010). Rapid detection of microorganisms using image processing parameters and neural network. *Food-Bioprocess-Tech.* 3(1): 741–751.
- Liu D, Sun D, Zeng X. 2013. Recent advances in wavelength selection techniques for hyperspectral image processing in the food industry. *Food-Bioprocess-Tech.* 7: 307–323.
- Mahesh S, Manickavasagana A, Jayasa D, Paliwala J, White N. 2008. Feasibility of near-infrared hyperspectral imaging to differentiate Canadian wheat classes. *Biosyst Eng.* 101: 50–57.

- Marín S, Arcila J, Montoya E, Oliveros C. 2004. Cambios físicos y químicos durante la maduración del fruto de café *Coffea arabica* L. var. Colombia. <http://biblioteca.cenicafe.org/handle/10778/265> [Consultado septiembre 2015]
- Min H, Qingguo W, Min. Z. 2013. Prediction color and moisture content in soybean during drynghperspectral imaging. *J Food Eng.* 28: 12-17.
- Mishra P, Cordella C, Rutledge D, Barreiro P, Roger J, Diezma B. 2016. Application of independent components analysis with the {JADE} algorithm and {NIR} hyperspectral imaging for revealing food adulteration. *J Food Eng.* 168: 7 – 15.
- Mizushima A, Lu R. 2013. An image segmentation method for apple sorting and grading using support vector machine and Otsu's method. *Comput Electron Agr.* 94: 29 – 37.
- Morgano M, Faria C, Ferrao C, Bragagnolo N, Ferreira M. 2008. Determination of moisture in raw coffee by near infra-red reflectance spectroscopy and multivariate regression. *Int J Food Sci Tech.* 28: 12-17
- Naganathan G, Cluff K, Samal A, Calkins C, Jones D, Lorenzen C, Subbiah J. 2015a. A prototype on-line {AOTF} hyperspectral image acquisition system for tenderness assessment of beef carcasses. *J Food Eng.* 154: 1 – 9.
- Naganathan G, Cluff K, Samal A, Calkins C, Jones D, Lorenzen C, Subbiah J. 2015b. Hyperspectral imaging of ribeye muscle on hanging beef carcasses for tenderness assessment. *Comput Electron Agr.* 116: 55 – 64.
- Nakano K. 1997. Application of neural networks to the color grading of apples. *Comput Electron Agr.* 18: 105–116.
- Noh H, Lu R. 2007. Hyperspectral laser-induced fluorescence imaging for assessing apple fruit quality. *Postharvest Biol Tec.* 43: 193–201.
- Omid M, Khojastehnazhand M, Tabatabaeefar A. 2010. Estimating volume and mass of citrus fruits by image processing technique. *J Food Eng.* 100: 315–321.
- Pallottino F, Menesatti P, Costa C, Paglia G, De Salvador F. 2010. Image analysis techniques for automated hazelnut peeling determination. *Food-Bioprocess-Tech.* 3 (1): 155–159.
- Peng Y, Lu R. 2008. Analysis of spatially resolved hyperspectral scattering images for assessing apple fruit firmness and soluble solids content. *Postharvest Biol Tec.* 48: 52–62.
- Pernkopf F, Wohlmayr M. 2013. Stochastic margin-based structure learning of Bayesian network classifiers. *Pattern Recognition.* 46, 464 – 471.
- Shankar T, Sokhansanj S, Bandyopadhyay S, Bawa A. 2010. A Case study on optimization of biomass flow during single-screw extrusion cooking using genetic algorithm (GA) and response surface method (RSM). *Food-Bioprocess-Tech.* 3(1): 489–510.
- Simko I, Jimenez-Berni J, Furbank R. 2015. Detection of decay in fresh-cut lettuce using hyperspectral imaging and chlorophyll fluorescence imaging. *Postharvest Biol Tec.* 106: 44 – 52.
- Singh C, Choudhary R, Jayas D, Paliwal J. 2010. Wavelet analysis of signals in agriculture and food quality inspection. *Food-Bioprocess-Tech.* 3(1): 2–12.
- Schaepman M. 2007. Spectrodirectional remote sensing: From pixels to processes. *Int J Appl Earth Obs.* 9: 204–223.
- Rud R, Shoshany M, Alchanatis V. 2013. Spatial-spectral processing strategies for detection of salinity effects in cauliflower, aubergine and kohlrabi. *Biosyst Eng.* 114: 384 – 396.
- Windham W, Heitschmidt G, Smith D, Berrang M. 2005. Detection of ingesta on pre-chilled broiler carcasses by hyperspectral imaging. *International Journal of Poultry Science.* 4(12): 959–964.
- Wu D, Sun D (2013). Advanced applications of hyperspectral imaging technology for food quality and safety analysis and assessment: A review — Part I: Fundamentals. *Innov Food Sci Emerg.* 19: 1-14.