

# TÉCNICAS DE VISIÓN ARTIFICIAL PARA LA IDENTIFICACIÓN DE DOS DEFECTOS DEL CAFÉ LAVADO

Juan Mateo Castrillón Cuervo\*; Juan Rodrigo Sanz Uribe\*\*; Paula Jimena Ramos Giraldo\*\*\*

---

**CASTRILLÓN C., J.M.; SANZ U., J.R.; RAMOS G., P.J. Técnicas de visión artificial para la identificación de dos defectos del café lavado. Revista Cenicafé 69(1):83-90. 2018**

La clasificación de café ayuda a obtener una mejor calidad de la bebida y un mayor precio en el mercado. Al igual que a simple vista, a partir de un procesamiento digital de imágenes se observaron diferencias apreciables entre los granos sanos de café lavado y los que tienen los defectos “fermento” e “inmaduro”. El café lavado cuando tiene el defecto fermento muy avanzado presenta una coloración más oscura del pergamino mientras que los granos de café lavado inmaduros presentan una coloración verdosa. En esta investigación se adquirieron imágenes digitales de granos sanos y defectuosos, bajo condiciones controladas de iluminación y fondo. Se desarrolló un algoritmo de segmentación de los granos y se estudiaron diferentes espacios de color, con el fin de determinar las mayores diferencias entre las tres clases de granos (sanos, fermento e inmaduro). La mayor dispersión entre clases se generó en el plano B-G de la representación de color RGB, donde se aplicaron tres clasificadores: lineal, bayesiano y K-vecinos más cercanos (K-NN). La eficacia promedio de los clasificadores fue 88,4%, 79,3% y 88,1%, respectivamente. Por el desempeño y bajo costo computacional fue seleccionado el clasificador lineal, en cuya validación, el porcentaje de correcta identificación fue de 91,4%. Los resultados de esta investigación tienen el potencial de ser usados en una máquina electrónica para la separación de los granos con estos defectos.

**Palabras clave:** Imágenes digitales, clasificación electrónica, clasificación de café, algoritmos.

---

## ARTIFICIAL VISION TECHNIQUES TO IDENTIFY TWO DEFECTS OF WASHED COFFEE

Coffee classification helps to obtain better cup quality and higher prices in the market. As well as with the naked eye, clear differences among healthy, sour and immature washed coffee beans, were observed with processed digital images. When washed coffee has a very advanced sour defect, the color of its husk is darker while immature washed coffee beans have a greenish coloration. In this study, digital images of healthy and defective coffee beans were obtained under controlled lighting and background conditions. A segmenting algorithm of the grains was developed and several color spaces were studied in order to find the greatest differences among the three classes: healthy, fermented, and immature beans. The greatest dispersion was observed in the B-G plane of the RGB color representation, in which three classifiers, namely, linear, Bayesian and K-nearest neighbors (K-NN) were applied. The mean efficacies of the classifiers were 88.4%, 79.3% and 88.1%, respectively. Due to good performance and low computational cost, the linear classifier, which validation had a right identification percentage of 91.4%, was chosen. The results of this research can be used in an electronic machine to separate those defective beans.

**Keywords:** Digital images, electronic classification, coffee classification, algorithms.

---

\*Asistente de Investigación (hasta 2015), \*\*Investigador Científico III, \*\*\*Investigador Científico I, respectivamente. Disciplina de Poscosecha, Centro Nacional de Investigaciones de Café, Cenicafé. Manizales, Caldas, Colombia.

Las exigencias de alta calidad del mercado requieren tecnologías que realicen controles cada vez más precisos y rigurosos. En café existen dos defectos que reducen de forma significativa el valor del grano: El primero, es el grano “inmaduro” proveniente del café pintón o verde, el cual genera astringencia o acidez indeseable en la taza, y segundo es el “fermento”, atribuido a malas prácticas en el proceso de beneficio, particularmente en la etapa de fermentación del mucílago, donde el café tras un largo período de sobrefermentación, presenta olores, sabores y aspecto propios de este defecto. Un alto contenido de café con fermento en una muestra, causa un efecto negativo sobre los atributos de la bebida (11). Los defectos mencionados presentan características que son visiblemente apreciables después de lavar el café para remover su mucílago degradado; el café inmaduro presenta una coloración verdosa que desaparece cuando el café empieza su proceso de secado y el café con fermento presenta una coloración del pergamino más oscura, en comparación con el café sano. El propósito de este trabajo es identificar los cambios de tonalidad aplicando técnicas de visión artificial, a través de algoritmos que diferencien los defectos en el café lavado. Estos algoritmos serán implementados en una máquina autónoma que logre separar granos defectuosos de los sanos.

## MATERIALES Y MÉTODOS

El trabajo de investigación se llevó a cabo en las instalaciones del laboratorio de Visión Artificial de la Disciplina de Poscosecha, del Centro Nacional de Investigaciones de Café-Cenicafé. El procesamiento de las imágenes se realizó en dos herramientas computacionales: un compilador de lenguaje C++ en conjunto con la librería open CV 2.9 (2) y Scilab, de código abierto y libre distribución. La metodología de la investigación estuvo constituida por tres

fases: I) Caracterización inicial de los granos y adquisición de la base de datos, II) Desarrollo de algoritmos que logren separar regiones de interés en los granos, y III) Evaluación de los clasificadores para identificar dichos defectos.

**Fase I):** Se seleccionaron manualmente 100 granos de café Variedad Castillo®, en cada clase: i) Sanos, ii) Defecto fermento y iii) Defecto inmaduro, provenientes de la Estación Experimental Naranjal y procesados en el beneficiadero de semilla de Cenicafe. Un grano de café posee dos superficies: una cara con forma convexa y una cara plana ensanchada con una hendidura, ambas fueron analizadas, disponiendo los granos en una campana de inspección. Dicha campana se compone de una iluminación controlada tipo LED (6500K), con tonalidad neutra, 24 W de potencia y patrón de radiación Lambertiano, además de una cámara industrial de alta velocidad, marca Emergent HS-2000C, con capacidad de tomar hasta 338 fps (*frames per second*, por sus siglas en inglés) a una resolución de 2 MP, ubicada en la parte superior.

Para garantizar una correcta segmentación digital (13) de los granos (separación de la información digital correspondiente al fondo y a los granos), se utilizó un fondo azul cian (*Red: 0, Green: 116 y Blue: 238*), utilizado en un estudio anterior (12). Dicho fondo permite la segmentación de la totalidad de los granos defectuosos o sanos presentes en la escena. Para esta segmentación se utilizó la componente de color *Cb* del espacio de representación YCbCr (por sus siglas en inglés: *Luminance, Chroma difference Blue y Chroma difference Red*) con una conversión desde el espacio de color RGB (por sus siglas en inglés: *Red, Green y Blue*) como se muestra en la Ecuación <1> (7).

$$\begin{bmatrix} Y \\ Cb \\ Cr \end{bmatrix} = \begin{bmatrix} 16 \\ 128 \\ 128 \end{bmatrix} + \begin{bmatrix} 65,48 & 128,55 & 24,96 \\ -37,79 & -74,20 & 112 \\ 112 & -93,78 & -18,21 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} <1>$$

Las imágenes con los 300 granos a caracterizar, se analizaron digitalmente, para encontrar las regiones que mostraban mayores cambios en su nivel de intensidad en el espacio de color RGB, como sugerían trabajos anteriores (9, 10); también se observó la forma de los granos (3), estudiando la viabilidad de un ajuste matemático, que permitiera calcular los parámetros de dicha figura para desplazarlos y segmentar las regiones de interés dentro de la misma.

Posteriormente, se seleccionó la cara del grano con mayores cambios de tonalidad y se adquirieron imágenes de 3.000 granos con defecto fermento e inmaduro, y 800 granos sanos que sirvieron de control, construyendo así la base de datos de entrenamiento y validación. Los granos con defecto fermento, previamente se sometieron a períodos de sobrefermentación sin agua, entre 38 y 114 h, para determinar el tiempo promedio desde el cual es apreciable el cambio de tonalidad de los granos dentro del espectro visible.

**Fase II):** Se construyeron e implementaron los algoritmos de segmentación y extracción de información en los lenguajes de programación ya mencionados. Para segmentar las regiones de interés dentro de los granos, se ajustó una elipse a los contornos de cada grano encontrado. Por medio de una regresión lineal (1, 5) se estimaron los valores iniciales de la elipse (coordenadas del centroide, eje mayor, eje menor y ángulo de inclinación) y, posteriormente, mediante regresión no lineal de mínimos cuadrados, se aproximó la elipse que mejor se ajustó al conjunto de datos (6). Con el centro de la elipse, la longitud de los ejes de cada contorno elíptico y la imagen binaria de la escena adquirida, se logró segmentar cualquier región dentro de un grano. Finalmente, se calculó la media aritmética de las regiones de interés (ROI) segmentadas, en los espacios de color RGB,

HSV y  $La^*b^*$ , teniendo como resultado nueve características de cada ROI.

Representando los datos en un plano cartesiano, se buscó la mayor separación entre clases, determinando la combinación de características XY más efectiva para aplicar los clasificadores

**Fase III):** A partir de la ROI y el par de componentes de color más representativas, se procedió a la implementación de tres tipos de clasificadores: lineal, Bayesiano y  $K$ -Vecinos más Cercanos (*K-Nearest Neighbors*, por sus siglas en inglés).

El clasificador lineal separa las clases dentro de una nube de puntos, a partir de una expresión lineal sobre el plano cartesiano, posee un costo computacional mínimo, con una alta precisión de clasificación, aunque en ocasiones puede tener una sensibilidad alta cuando la fuente de extracción de las características es propensa al ruido o cambios repentinos debido a condiciones externas (8). El clasificador Bayesiano modela funciones de densidad con distribuciones normales, tomando la desviación estándar y la media de un grupo de datos iniciales como conjunto de entrenamiento, y estima la probabilidad de que un nuevo dato pertenezca a una de las clases de entrenamiento, por medio de su probabilidad *a posteriori* para cada clase, basándose en el teorema de Bayes y en la probabilidad condicional (14). El clasificador  $K$ -NN ( $k$ -vecinos más cercanos) en cambio, clasifica los datos de acuerdo a la ubicación espacial de un conjunto de datos previamente clasificado y etiquetado, calculando la distancia euclidiana de un nuevo dato hasta cada uno de los puntos de entrenamiento dados. El dato de prueba pertenecerá a la clase a la que más cerca se encuentre; puede ser extendido a varias clases cercanas (vecinos) manteniendo  $k$

impar (14), sin embargo, para este estudio solo se trabajó con  $k$  igual a uno.

Para el entrenamiento de todos los clasificadores se utilizaron 30 muestras de 200 granos de café y para la validación se utilizó la información de los 1.400 granos de café restantes. Se utilizó la eficacia (Ecuación <2>), basada en la tabla de contingencia o confusión (4), como métrica para determinar el desempeño de cada clasificador y herramienta computacional.

$$E = \frac{N_{ss} + N_{dd}}{N} \quad <2>$$

Donde:

$E$  = eficacia

$N_{ss}$  = número de granos sanos identificados como sanos

$N_{dd}$  = número de granos defectuosos identificados como defectuosos

$N$  = número total de granos analizados

## RESULTADOS Y DISCUSIÓN

La iluminación controlada permite eliminar perturbaciones externas en la escena, como sombras o cambios de intensidad en la luz, originando datos completos y ordenados de los contornos de los granos de café, lo que se traduce en ajustes precisos al aplicar el algoritmo seleccionado para el ajuste elíptico (Figura 1).

Los defectos estudiados en este experimento mostraron alteraciones de coloración del pergamino del café<sup>1</sup> y la almendra en el interior del grano, particularmente a lo largo de la hendidura y en los dos extremos o lóbulos que ésta misma separa. Dichas alteraciones presentan cambios de color hueso oscuro en granos sanos, por tonos

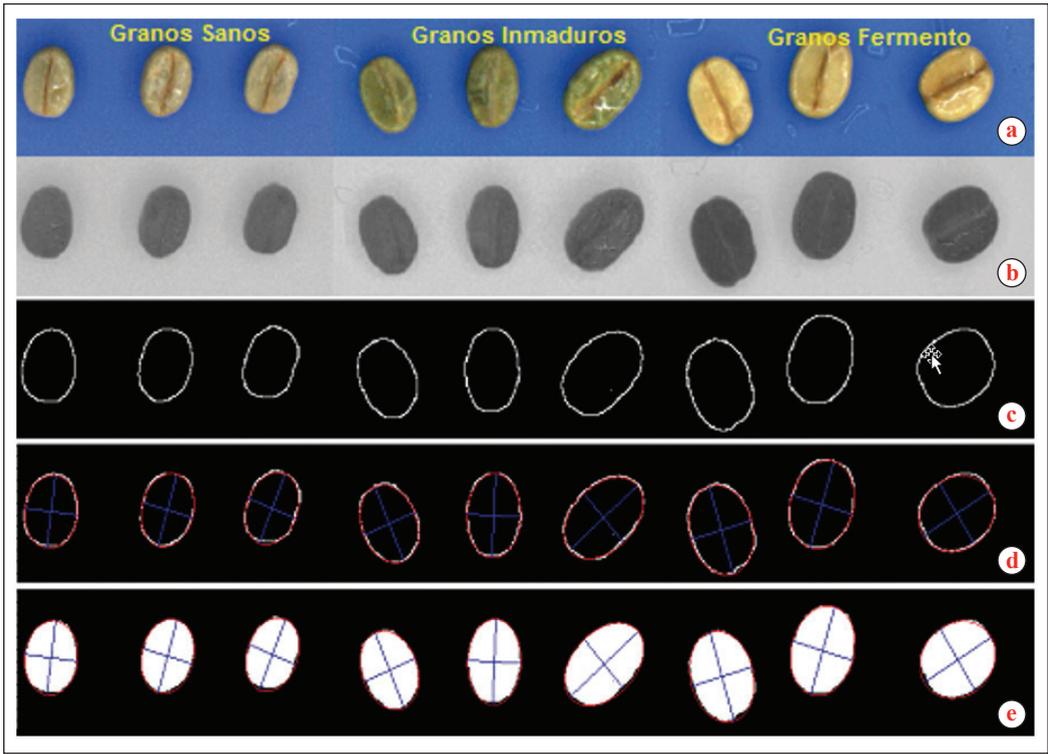
verdes para granos inmaduros y coloraciones marrón oscuro para granos tipo fermento. Los cambios de coloración se hacen más evidentes en los lóbulos de los granos y la hendidura. En la cara convexa solamente se observaron diferencias de tonalidad para granos inmaduros, razón por la cual se optó por analizar únicamente las superficies planas de los granos.

Se utilizaron desplazamientos de los ejes de la elipse ajustada para segmentar dichas regiones, trasladando el eje mayor a través del eje menor un 30%, se segmentaron los lóbulos del grano, y realizando una negación lógica a la imagen binaria pudo segmentarse la hendidura (Figura 2).

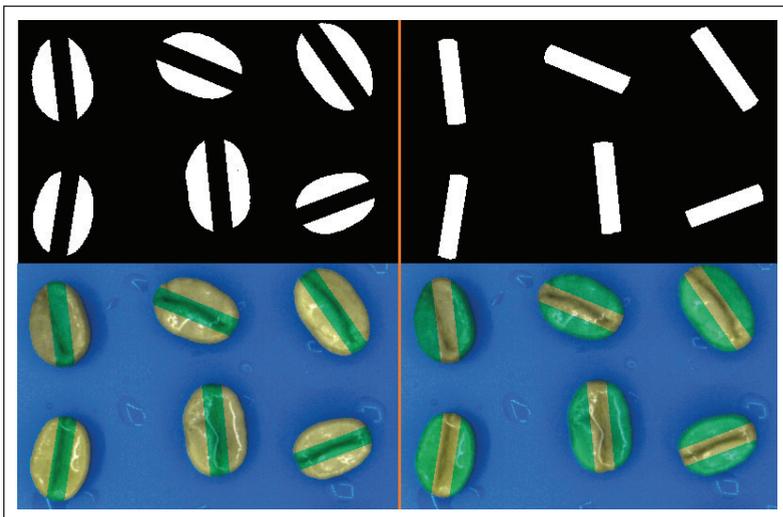
Para determinar la ROI a analizar se midió el cambio de coloración de las componentes de color RGB, HSV y  $La^*b^*$ , en las regiones segmentadas, para los tres tipos de granos de café. Tanto en los lóbulos como en la hendidura se presentan cambios en cada una de las componentes de color mencionadas, sin embargo, el rango dinámico de dichas variables es mayor para la zona de los lóbulos, generando mayores dispersiones al momento de relacionar las características de color en un plano cartesiano. En la Figura 3 se muestra el rango de las componentes (RGB y HSV) de color, tanto en los lóbulos como en la hendidura, para los granos en todos los estados, por medio de un análisis de intervalos de confianza con un nivel de significancia del 95%.

El espacio de color  $La^*b^*$  no mostró diferenciación en la componente  $a^*$ , y debido a que la componente  $L$  es altamente susceptible a los cambios de luz externa, solo se observaba diferenciación en la componente

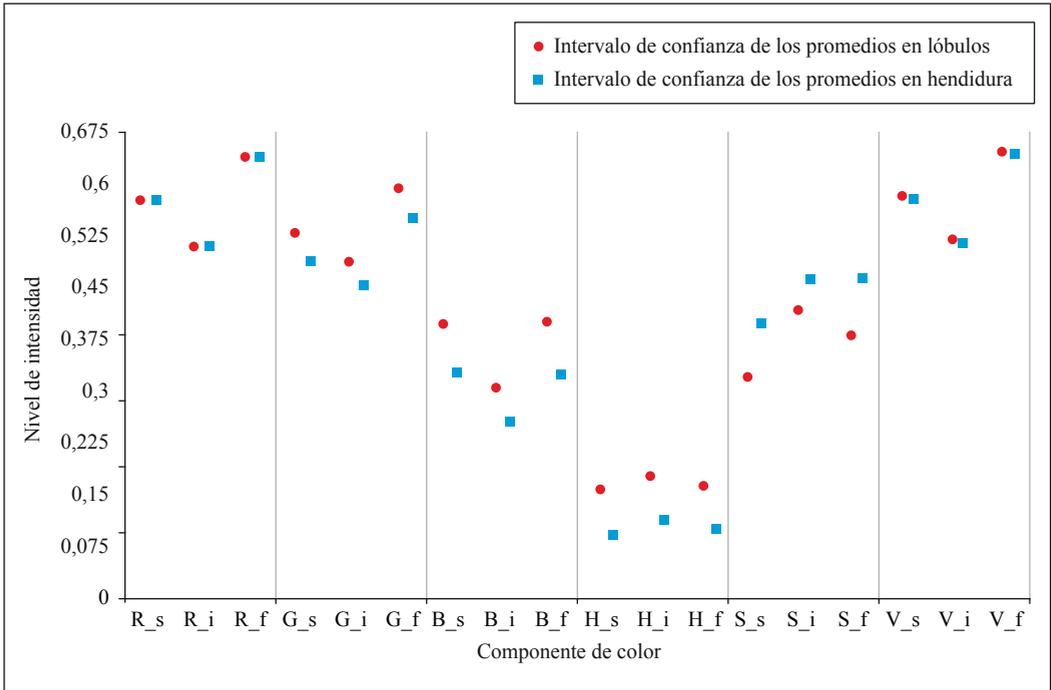
<sup>1</sup> Luego de fermentar y remover el mucílago del café despulpado, es posible apreciar los defectos de la almendra a través de la capa del grano conocida como pergamino, el cual al estar húmedo es translúcido.



**Figura 1.** a. Imagen con granos sanos, inmaduros y tipo fermento; b. Representación de color Cb; c. Contornos de la imagen; d. Ajuste elíptico (rojo) con sus respectivos ejes superpuestos sobre los contornos (blanco); e. Imagen binaria con ajuste elíptico y ejes correspondientes.



**Figura 2.** Segmentación de lóbulos o extremos (izq.) y de la hendidura de los granos de café en su cara plana (der.).



**Figura 3.** Intervalos de confianza al 95% para las características seleccionadas en los espacios de color RGB y HSV.

b\*, por lo que se descartó este espacio para las clasificaciones posteriores. La variable que muestra mayor diferenciación de promedios entre los granos sanos e inmaduros es la componente de color S del espacio HSV, sin embargo, es sujeta a brillos ocasionados por las gotas de agua presentes en el café lavado, la segunda componente con mayor diferencia fue la B del espacio RGB, con valor de 0,092, mientras que la mayor diferencia entre sanos y fermento se presenta en G del mismo espacio de color con un valor de 0,075; estos valores equivalen a 17 y 23 niveles de intensidad, respectivamente, para imágenes de 8 bits de profundidad.

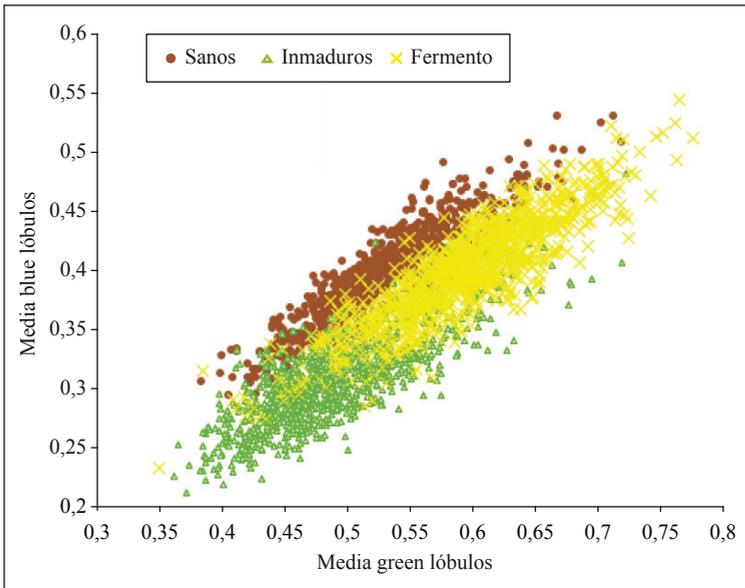
Con el promedio de las componentes B y G de la ROI segmentada sobre los lóbulos, se creó el gráfico de dispersión de la Figura 4, donde se aprecian tres nubes de puntos,

correspondientes a la relación GB de los granos sanos, fermento e inmaduros.

La eficacia promedio de identificación de los clasificadores, al discriminar entre granos sanos e inmaduros es de 93,44%, y la clasificación entre granos sanos y con defecto fermento es de 87,31% (Tabla 1). Para el clasificador lineal se varió la pendiente de la recta desde 0,60 hasta 0,75. La eficacia mostrada se obtuvo con pendiente igual a 0,71.

**Tabla 1.** Eficacias de los clasificadores evaluados.

	Identificación	Tipo de clasificador		
		Lineal	Bayes	KNN
Eficacia (%)	Inmaduros	93,44	85,87	92,14
	Fermento	87,31	71,33	84,06
	<b>Combinados</b>	<b>90,43</b>	<b>70,69</b>	<b>85,87</b>



**Figura 4.** Distribución de clases sano, inmaduro y fermento en el plano BG.

Se realizaron evaluaciones variando la cantidad de puntos de entrenamiento entre 100 y 400, tratando de encontrar mejores eficacias, pero éstas variaron desde una centésima de decimal hasta apenas una unidad, en comparación con los valores obtenidos al entrenar con 200 datos, razón por la cual los demás análisis solamente se realizaron con 200 datos de entrenamiento. Al evaluar los clasificadores para discriminar entre sanos y afectados, se obtuvieron las eficacias resaltadas al final de la Tabla 1. El bajo desempeño del clasificador de Bayes está relacionado con la cercanía entre clases, es decir, hay traslapes entre las curvas normales, ya que el promedio de la pendiente de la recta desde el origen hasta los puntos de la nube de sanos fue de 0,752 y para la recta de defectuosos de 0,650, con desviación estándar de 0,032 y 0,048, respectivamente.

Posteriormente, se validó la eficacia de clasificación con 200 nuevos granos de cada tipo, teniendo como resultado una

eficacia promedio de 91,4%. Las evaluaciones realizadas muestran que el clasificador con mejor desempeño para la aplicación planteada es el lineal; sin embargo, depende en gran medida de condiciones externas, las cuales son inherentes a cualquier sistema de adquisición, sin importar la disposición del sistema de iluminación controlada, para solucionar esto, se están adelantando trabajos para utilizar un clasificador lineal con pendiente dinámica, donde la pendiente que separa los granos defectuosos de los sanos se ajuste automáticamente dependiendo del promedio, desviación estándar y otras medidas estadísticas tomadas a todos los píxeles que conforman cada imagen.

En este estudio puede concluirse que se cuenta con un algoritmo, basado en las componentes de color G y B, que tiene la capacidad de identificar granos de café lavado con los defectos fermento e inmaduro, de los granos sanos, con una eficacia promedio de 91,4%, que se considera aceptable para ser usado en desarrollos posteriores.

El clasificador lineal demostró tener mayores eficacias que clasificadores más elaborados, como son el Bayesiano y el k-vecinos más cercanos. Esto muestra robustez del proceso y el costo computacional de la implementación es relativamente bajo, si se compara con otro tipo de clasificadores, lo que posibilita generar análisis en tiempo real.

En el análisis descriptivo por intervalos de confianza arrojó una dispersión de la muestra del 0,3%, lo que permite concluir que el hardware usado para capturar las escenas, garantiza alta estabilidad con respecto a alteraciones externas, dando a la información resultante en la imagen digital y al sistema de adquisición una alta confiabilidad de los datos. Al mismo tiempo, esto permitió obtener contornos completos y con ruido despreciable, para segmentar cualquier región dentro del grano, a partir de los parámetros de la elipse calculada, con un mínimo requerimiento computacional.

## AGRADECIMIENTOS

Los autores agradecen a los investigadores y auxiliares de la Disciplina de Poscosecha de Cenicafé, al Departamento Administrativo de Ciencia, Tecnología e Innovación – Colciencias por la cofinanciación del proyecto “Visión artificial para la clasificación automática de café pergamino húmedo”, código 2251-569-33151, contrato 2013-0151.

## LITERATURA CITADA

1. BOOKSTEIN, F.L. Fitting conic sections to scattered data. *Computer graphics and image processing* 9(1):56-71. 1979.
2. BRADSKI, G.; KAEHLER, A. *Learning open CV*. Beijing : O'Reilly media, 2008. 556 p.

3. COSTA, L.D.F.D.; CESAR, R.M. JR. *Shape analysis and classification: Theory and practice*. Florida : CRC press, 2000. 680 p.
4. FAWCETT, T. An introduction to ROC analysis. *Pattern recognition letters* 27(8):861-874. 2006.
5. FITZGIBBON, A.W.; FISHER, R.B. *A buyer's guide to conic fitting*. Birmingham : British machine vision conference, 1995.
6. GANDER, W.; GOLUB, G.H.; STREBEL, R. Least-squares fitting of circles and ellipses. *BIT numerical mathematics* 34(4):558-578. 1994.
7. GONZÁLEZ, R.C.; WOODS, R.E.; EDDINS, S.L. *Color image processing*. p. 329. En: GONZALEZ, R.C.; WOODS, R.E.; EDDINS, S.L. *Digital image processing using MATLAB*. (s.l.) : Gatesmark publishing, 2009. 827 p.
8. HERBRICH, R. *Learning kernel classifiers: Theory and algorithms*. Massachusetts : MIT press, 2002.
9. RAMOS G., P.J.; SANZ U., J.R.; ESTRADA E., J.H. Sistema opto-electrónico para la identificación de frutos de café por estados de maduración. *Cenicafé* 62(1):87-99. 2011.
10. RAMOS G., P.J.; SANZ U., J.R.; OLIVEROS T., C.E. Identificación y clasificación de frutos de café en tiempo real, a través de la medición de color. *Cenicafé* 61(4):315-326. 2014.
11. ROA M., G.; OLIVEROS T., C.E.; ÁLVAREZ G., J.; RAMÍREZ G., C.A.; SANZ U., J.R.; DÁVILA A., M.T.; ÁLVAREZ H., J.R.; ZAMBRANO F., D.A.; PUERTA Q., G.I.; RODRÍGUEZ V., N. Apéndice B. p. 266-271. En: CENICAFÉ. *Beneficio ecológico de café*. Chinchiná : CENICAFÉ, 1999.
12. SANZ U., J.R., RAMOS G., P.J.; CASTRILLÓN C., J.M.; FERRIER, N. Characterization of defective washed coffee beans for electronic sorting. *Saint Petersburg : Proceedings of the international Scientific*, 2015.
13. SZELISKI, R. Segmentation. En: SZELISKI, R. *Computer vision: Algorithms and applications*. New York : Springer, 2010. 812 p.
14. THEODORIDIS, S.; KOUTROUMBAS, K. *Pattern recognition*. San Diego : Academic press, 2003. 689 p.