

LA VISION ARTIFICIAL APLICADA AL PROCESO DE PRODUCCION DEL CAFE

NUBIA MONTES

Grupo de Percepción y Control Inteligente, Universidad Nacional de Colombia, Manizales

GUSTAVO OSORIO

Grupo de Percepción y Control Inteligente, Universidad Nacional de Colombia, Manizales

FLAVIO PRIETO

Grupo de Percepción y Control Inteligente, Universidad Nacional de Colombia, Manizales

FABIOLA ANGULO

Grupo de Percepción y Control Inteligente, Universidad Nacional de Colombia, Manizales

Recibido para revisión 3 Junio de 2001, aceptado 20 Agosto de 2001; versión final recibida 17 Noviembre de 2001

RESUMEN: En este trabajo se presentan los resultados obtenidos en el desarrollo de un Sistema de Visión Artificial para la Automatización de la cosecha de café. El sistema de visión está compuesto de diferentes etapas. Después de la adquisición de las imágenes, éstas son adecuadas para obtener buenos resultados en el proceso de segmentación. Posteriormente se desarrollaron algoritmos para realizar la segmentación de frutos de café maduros y verdes, utilizando técnicas de detección y de comparación de propiedades locales. Finalmente se implementaron algoritmos para la caracterización y clasificación de granos de café basados en las propiedades morfológicas y de color, estos últimos orientados al pronóstico de cosecha, a la automatización de la cosecha de café y a la detección de enfermedades y plagas.

PALABRAS CLAVES: Visión artificial, procesamiento de imágenes, automatización, cosecha de café.

ABSTRACT: We show some results in the development of an Artificial Vision System to be used in the automation of the harvest coffee process. The vision system is composed of different stages. First, the acquired images are enhanced in order to obtain a good quality image for segmentation. Second, the segmentation process, where algorithms are developed by using region-oriented, edge linking and boundary detection techniques. Third, the representation and description process, where algorithms are based on color and morphological properties are developed, focused in the harvest prediction, the harvesting automation process and the diseases detection.

KEY WORDS: Artificial vision, image processing, automation, harvest coffee process.

1 INTRODUCCION

El café colombiano debe disminuir los costos de producción en el mediano y largo plazo para mantener su competitividad en el mercado internacional; el mayor costo asociado a esta producción está relacionado con la recolección del grano maduro. El estado de la caficultura colombiana está determinado por diversos factores derivados de las políticas macroeconómicas que han dado lugar a la revaluación del peso, elevadas tasas de interés y alto costo de la mano de obra requerida para producir café. En la recolección del café en Colombia se requiere una gran cantidad de mano de obra. Aunque esto realza la importancia social del café como generador de empleo, también indica la debilidad competitiva de la caficultura colombiana debido a

que en los costos de producción actuales, la mano de obra empleada en la recolección, tiene una elevada participación (40% aproximadamente) (Oliveros, 2000).

Las tecnologías de visión artificial y procesamiento digital de imágenes están siendo utilizadas en diferentes países como parte integral de sistemas que realizan tanto la recolección de productos agrícolas, como el control en varias etapas del proceso (Jimenez et al., 2000, Paulus et al., 1997, Hayashi et al., 1997, Plá et al., 1993). Algunos tópicos de especial interés en el proceso de producción de café, en los cuales la Visión Artificial puede ser útil, están relacionados con:

- El pronóstico de cosecha, para determinar algunos de los parámetros necesarios para el modelo de pronóstico de cosecha empleado por la Federación

Nacional de Cafeteros de Colombia. Específicamente realizando medidas relacionadas con los componentes de producción por árbol, como son: la cantidad de ramas formadas sobre el tallo principal, la cantidad de nudos formados en las ramas, la cantidad de frutos formados en los nudos que alcancen a llegar a maduración.

- La cosecha mecanizada, desempeñando diferentes tareas como por ejemplo: determinar las condiciones óptimas para utilizar un cosechador mecánico específico, detección de frutos verdes en el proceso de beneficio y detección espacial de frutos maduros para cosecha selectiva empleando un sistema robotizado.
- La detección de plagas o enfermedades en las plantaciones de café, siempre y cuando estas plagas o enfermedades produzcan deterioro en los granos.

Es importante aclarar, que el enfoque propuesto no es el único para la solución de estos problemas. Se han desarrollado trabajos utilizando vibración de follaje y vibración de tallo entre otros (Henao, 2000).

En este artículo se presentan los desarrollos que se están llevando a cabo en las áreas de pronóstico de cosecha y cosecha mecanizada de café. Específicamente se están desarrollando sistemas para la segmentación, caracterización y clasificación de granos maduros y verdes de café.

En la Sección 2 se presentan algunos algoritmos básicos que permiten adecuar las imágenes adquiridas para obtener mejores resultados en las etapas de segmentación y clasificación de los granos.

La Sección 3 presenta la etapa de segmentación de frutos de café. Inicialmente se analizan las características de color de los píxeles con el algoritmo SCT/center (Spherical Coordinate Transform) (Umbaugh, 1998) que agrupa las regiones de interés, después se separan las componentes no conexas en la imagen resultado del algoritmo anterior, y se etiquetan con valores diferentes (Bässmann, 1995). El siguiente paso es calcular los centroides de las regiones resultantes, y a partir de éstos, encontrar algunos puntos pertenecientes al borde del grano.

La etapa de caracterización y clasificación de los frutos de café es presentada en la Sección 4. La caracterización se realiza de acuerdo al grado de maduración de los granos. En esta etapa se realizan medidas de tamaño de los granos mediante el cálculo del área, análisis de color en los espacios RGB y HSI, y otras características que brindan información discriminante.

En la Sección 5 se muestran los resultados obtenidos con los algoritmos implementados y en la



Figura 1. Imagen original.

última Sección se presentan las conclusiones de este trabajo.

2 ADQUISICIÓN Y ADECUACIÓN DE LAS IMÁGENES

2.1 Adquisición de las imágenes

Las imágenes de laboratorio han sido adquiridas usando una cámara analógica y una cámara de vídeo digital, en ambos casos las condiciones de iluminación han sido controladas para evitar brillos y sombras en las imágenes. Además de controlar las condiciones de iluminación, también se ubicaron los nudos de café sobre fondos de diferentes colores (negro, gris y blanco) con el fin de observar la variación en los resultados de los algoritmos. Las imágenes resultantes tienen tres componentes de color: RGB (*Red, Green, Blue*). La Figura 1 muestra el resultado de adquisición de una imagen de granos de café, por el método propuesto.

2.2 Algoritmos para la adecuación de las imágenes

El objetivo de la adecuación de una imagen es disminuir el ruido presente en la imagen y realzar las características de interés como los bordes. Para lograr esto se utilizan: *Filtros suavizantes*, para disminuir el ruido generado por diferentes factores, como no uniformidad de color de los granos de café (debido al proceso de maduración), y *Filtros realzantes* para mejorar las características de interés de la imagen, como los bordes de los granos de café.

2.2.1 Filtros suavizantes

Estos filtros atenúan las componentes de alta frecuencia presentes en la imagen, las cuales son responsables de los bordes y los detalles finos, por este motivo son utilizados para la reducción de ruido (González et al., 1992).





Figura 2. Imagen después de aplicar un filtro de mediana de tamaño 3x3.



(a) Tamaño 5x5 $\sigma=0.6$

(b) Tamaño 7x7 $\sigma=1.0$

Figura 3. Imagen después de aplicar un filtro gaussiano.

Filtro de Mediana.

Para calcular la mediana de un conjunto de valores estos se deben arreglar en orden ascendente, el valor que se sitúa en la mitad de dicho arreglo es la mediana del conjunto. Para el caso de una imagen dicho arreglo se toma de un entorno de tamaño 3x3 alrededor del pixel que se analiza. La Figura 2 presenta el resultado de aplicar un filtro de mediana de tamaño 3x3.

Filtro Gaussiano.


Este filtro tiene un mejor desempeño que el filtro de mediana. El filtro gaussiano en dos dimensiones tiene la forma:

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (1)$$

donde σ es la desviación estándar de la distribución y se ha asumido una media igual a cero. En la Figura 3 se observa el efecto de la variación del valor de desviación del filtro gaussiano, se observa la disminución de nitidez de la imagen y por lo tanto la pérdida de los detalles finos y los contornos.

2.2.2 Filtros realzantes

El objetivo principal de estos filtros es destacar los detalles finos de una imagen, una de sus aplicaciones más importante es la detección de bordes. En este trabajo



(a) Usando Filtro de Mediana

(b) Usando Filtro Gaussiano

Figura 4. Sobel aplicado sobre la componente R filtrada.

se utilizarán los filtros de Sobel, Laplaciano de Gaussiano y HighBoost.

Filtro de Sobel.

Este operador se basa en el concepto de gradiente. El gradiente de la función f en el punto de coordenadas (x, y) se define como el vector:

$$\nabla f = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix} = \begin{bmatrix} G_x \\ G_y \end{bmatrix} \quad (2)$$

Tanto la magnitud como la dirección del gradiente son de importancia en la detección de bordes. La magnitud del gradiente está dada por: $|\nabla f| = [G_x^2 + G_y^2]^{1/2}$ y su dirección por: $\alpha(x, y) = \tan^{-1} \left(\frac{G_y}{G_x} \right)$. La Figura 4 muestra el resultado de aplicar el filtro de Sobel a la componente R de las imágenes suavizadas con un filtro de Mediana y un filtro Gaussiano.

Filtro Laplaciano.

El laplaciano de una función bidimensional $f(x, y)$ es una derivada de segundo orden definida por:

$$\nabla^2 f = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2} \quad (3)$$

Este operador es poco utilizado para la detección de bordes debido a que es extremadamente sensible al ruido, produce bordes dobles y no brinda información sobre la dirección del borde. Sin embargo, es frecuentemente utilizado en combinación con un filtro gaussiano, aprovechando sus propiedades de cruce por cero. Esta combinación produce un mejor detector de bordes llamado *Laplaciano de Gaussiano (LoG)*.

Filtro Laplaciano de Gaussiano (LoG).

Este detector de bordes aprovecha la propiedad de suavizado de un filtro gaussiano y la característica de cruce por cero del Laplaciano, mejorando la respuesta del operador Laplaciano gracias a la disminución de ruido producida por el filtro gaussiano. Los parámetros de este detector (pesos de la máscara de convolución), se calculan utilizando la siguiente expresión (Fisher et al., 2001):




Figura 5. LoG aplicado sobre la componente R.




Figura 6. HighBoost aplicado a la componente R filtrada, $A=1.05$. Tamaño ventana=3.

$$G(x, y) = -\frac{1}{\pi\sigma^4} \left(1 - \frac{x^2 + y^2}{2\sigma^2} \right) e^{-\frac{x^2 + y^2}{2\sigma^2}} \quad (4)$$

En la Figura 5 se presenta el resultado de aplicar el filtro de LoG a la componente R de las imágenes suavizadas con un filtro de Mediana y un filtro Gaussiano.

Filtro HighBoost.

Es un filtro que enfatiza las componentes de alta frecuencia de una imagen utilizando la siguiente expresión:

$$HighBoost = (A-1) Original + filtro\ pasa\ alto \quad (5)$$

La respuesta del filtro depende del valor de A . A medida que el valor de A se hace mayor a 1, la imagen resultante retiene mayor información de baja frecuencia, haciendo que se parezca más a la imagen original, y además mejorando los bordes en la imagen. En la Figura 6 se muestra el resultado de aplicar el filtro de HighBoost a la componente R de las imágenes suavizadas con un filtro de Mediana y un filtro Gaussiano.




Figura 7. Transformación del espacio RGB a coordenadas esféricas.

3 SEGMENTACIÓN DE LOS FRUTOS DE CAFÉ

La segmentación es una etapa determinante en un sistema de visión artificial. El objetivo de esta etapa es aislar los objetos de interés, para luego realizar el análisis de sus características. Los algoritmos desarrollados están basados en las propiedades locales de color. Es importante que el algoritmo utilizado para el análisis de estas propiedades permita desacoplar la información de color de la de brillo, por esta razón se utilizó la transformación a coordenadas esféricas SCT (Spherical Coordinate Transform).

3.1 Transformación a coordenadas esféricas (SCT)

Es una técnica de agrupamiento que separa la información de intensidad de la información de color y define un subespacio de trabajo bidimensional. El SCT transforma las coordenadas de un punto en el espacio RGB a coordenadas esféricas. En la Figura 7 se ilustra esta transformación. La información de color se obtiene analizando el espacio bidimensional definido por los ángulos A y B .

El algoritmo de agrupamiento divide el triángulo de color en bloques basado en los límites de los dos ángulos (ver Figura 8). Los pasos que se siguen con este algoritmo son los siguientes:

- (i) Transformar las componentes RGB del píxel a coordenadas esféricas (L , ángulo A , ángulo B).
- (ii) Determinar los valores mínimo y máximo de los ángulos A y B .
- (iii) Dividir el subespacio definido por los valores de los ángulos A y B hallados en el paso anterior, en bloques de igual tamaño.
- (iv) Calcular la media de cada componente RGB para los píxeles en cada bloque.
- (v) Reemplazar los valores originales de las compo-




Figura 8. Triángulo de color del algoritmo SCT dividido en 25 bloques.




Figura 9. Aplicación del algoritmo SCT.

nentes RGB del píxel por las correspondientes medias.

El número de divisiones se escoge de manera que el algoritmo suministre los mejores resultados para la aplicación específica. La aplicación del SCT permite la identificación de diferentes regiones en la imagen que cumplen con el criterio de color establecido. El resultado de aplicar este algoritmo a la Figura 1 se muestra en la Figura 9.

3.2 Algoritmos para la separación de regiones

El paso siguiente en el proceso, fue la separación de regiones pertenecientes a granos diferentes con las mismas características de color, que quedan unidas debido a la proximidad existente entre ellos. Para lograr dicha separación, se calculó la diferencia entre la imagen SCT y la imagen de bordes en el plano R (Figura 10(a)). Por último, a la imagen resultante se le aplica la operación morfológica de erosión. La erosión de A por B, representada por $A \ominus B$, se define por:

$$A \ominus B = x|(B)_x \subseteq A \quad (6)$$




Figura 10. Aplicación de los algoritmos para la separación de regiones.

Es decir, la erosión de A por B es el conjunto de todos los puntos x tales que B, trasladado por x , está contenido en A (Figura 10(b)).

3.3 Etiquetado de regiones

El objetivo de este algoritmo es separar los diferentes objetos presentes en una imagen etiquetándolos con valores diferentes (Bässmann, 1995). En este trabajo fue utilizado para identificar cada grano de café como un objeto distinto en la imagen y para eliminar objetos con un tamaño inferior a 100 píxeles. El algoritmo toma como entrada una imagen binaria en la que se encuentran las regiones de interés. El fondo de la imagen es negro y los píxeles pertenecientes a las regiones son blancos. El proceso de etiquetado consiste en realizar un análisis de conectividad, para determinar si dos o más píxeles están unidos y por lo tanto pertenecen o no a un mismo objeto. A continuación se presenta el algoritmo para etiquetado de regiones:

- (i) Se prueba si el píxel actual no hace parte del fondo. En caso falso ir al paso 5.
- (ii) Se verifica si el píxel es el primero de una nueva región.
- (iii) Se evalúa si alguno de los píxeles vecinos ha sido etiquetado.
- (iv) Si existe más de un píxel vecino etiquetado, se comparan los valores de todos ellos: *i*. Si la etiqueta es la misma, se asigna esta etiqueta al píxel que se está evaluando. *ii*. Si las etiquetas son diferentes, se guarda el dato en una tabla de equivalencias para realizar la corrección después de etiquetar toda la imagen. *iii*. Si el píxel no posee vecinos etiquetados, se etiqueta con un nuevo valor.
- (v) Se procede a analizar otro píxel.

Partiendo del resultado obtenido después de la erosión (Figura 10(b)), se procedió a etiquetar los granos presentes en la imagen. Con el fin de eliminar las




Figura 11. Regiones consideradas como pertenecientes a granos.




Figura 12. Etapas en el desarrollo del fruto del café variedad Colombia.

regiones que hacen parte de hojas, tallo y granos que se encuentran detrás de otros, se decidió aceptar como regiones válidas para el análisis aquellas cuyo tamaño superara el 60% del área típica de un grano.

4 CARACTERIZACIÓN Y CLASIFICACIÓN DE LOS FRUTOS DE CAFÉ

En (Salazar et al., 1993) se estudió el crecimiento y desarrollo del fruto de café. Ellos presentaron una curva evolutiva del peso en función del grado de maduración de los frutos, medido en semanas. Esta curva se presenta en la Figura 12. Con base en la información presentada en la Figura 12 se caracterizaron los frutos de café. La caracterización fue usada posteriormente para la clasificación de los frutos de café, de acuerdo a su grado de maduración.

4.1 Caracterización de los frutos de café

Para la caracterización de frutos de café se analizaron diferentes características de los granos en función de

la etapa de desarrollo de los frutos. Algunas de estas características son: el tamaño, la circularidad y el color.

El tamaño fue normalizado a 255 píxeles, utilizando la siguiente ecuación:

$$Tam. Norm. = \frac{Tam. Actual}{Mayor Tam.} * 255 pixels \quad (7)$$

La medida de circularidad se halló calculando la firma del contorno del grano y encontrando la relación entre el eje máximo y el eje mínimo. Para calcular la firma del contorno se calcula la distancia desde el centroide a cada uno de los puntos del contorno de una región, realizando un giro de 360°. La firma es la representación de esta distancia en el plano ángulo contra distancia.

El análisis de color se realizó para los modelos de color RGB y HSI (Tono, Saturación, Intensidad). Se calcularon los valores de la media, la desviación estándar y simetría para los histogramas de cada componente de estos modelos de color. El histograma de una imagen digital, con niveles de gris en el rango $[0, L-1]$, está definido por:

$$p(r_k) = \frac{n_k}{n} \quad (8)$$

donde r_k es el k -ésimo nivel de gris, n_k es el número de píxeles en la imagen con ese nivel de gris, k es un valor entre $[0, L-1]$ y n es el número total de píxeles de la imagen.

4.2 Clasificación de los frutos de café

El algoritmo de caracterización permite el entrenamiento del sistema, encontrando las funciones de densidad de probabilidad Gaussianas características para cada grado de maduración. Estas curvas son aplicadas a un clasificador bayesiano con el fin de definir el grado de maduración en que se encuentra un grano determinado.

El clasificador Bayesiano.

Está basado en la fórmula de Bayes:

$$P(w_i/x) = \frac{p(x/w_i)P(w_i)}{p(x)}; i = 1, 2, \dots, N \quad (9)$$

donde $P(w_i/x)$ es la probabilidad que la clase sea w_i dado el vector de características x , $p(x/w_i)$ es la probabilidad para x dada la clase w_i , $P(w_i)$ es la probabilidad a priori de la clase w_i , $p(x)$ probabilidad de que se presente el vector de características x , x son los vectores característicos de cada elemento de las N clases w_1, w_2, \dots, w_N (Duda et al., 2001).

La regla de decisión de Bayes dictamina que para un x dado, se puede minimizar la probabilidad de

error si se decide de la siguiente manera: Decidir que x pertenece a w_i si $P(w_i/x) > P(w_j/x)$, para $i \neq j$.

El clasificador de Bayes utiliza el segundo miembro de la fórmula de Bayes. El término $p(x)$ puede ser considerado un factor de escala. De tal manera que la regla de decisión será: Decidir que x pertenece a w_i si $p(x/w_i)P(w_i) > p(x/w_j)P(w_j)$, para $i \neq j$.

Para el caso más general de un vector de características n -dimensional, la probabilidad $p(x/w_i)$, sigue la ley:

$$P(x/w_i) = \frac{1}{(2\pi)^{n/2} |\Sigma_i|^{1/2}} \exp^{-\frac{1}{2}(x-\mu_i)^T \Sigma_i^{-1} (x-\mu_i)} \quad (10)$$

donde μ_i y Σ_i son respectivamente el vector media y la matriz de covarianza de la clase w_i . $|\Sigma|$ y Σ^{-1} denotan el determinante y la inversa de la matriz de covarianza.

5 RESULTADOS OBTENIDOS

A continuación se presentan los resultados en dos subsecciones diferentes: Resultados del proceso de segmentación y Resultados del proceso de clasificación. Esto debido a que aún no se tienen resultados óptimos de segmentación de los frutos de café lo que impide tener una buena caracterización de ellos. Para tener resultados confiables en la clasificación se utilizaron frutos de café segmentados manualmente.

5.1 Resultados del proceso de segmentación de los frutos de café

Con el fin de evaluar el desempeño de los algoritmos, se probaron diferentes métodos de preproceso y se calculó el *Falso Rechazo* y la *Falsa Aceptación*. El *Falso Rechazo* indica el porcentaje de píxeles pertenecientes al grano que no fueron segmentados. La *Falsa Aceptación* indica el porcentaje de píxeles que no pertenecen al grano que fueron segmentados. Ambos porcentajes son calculados con respecto al tamaño del grano medido en píxeles. Los métodos de preproceso utilizados fueron:

- Mediana-Sobel (Umbral 60-120)
- Mediana-Laplaciano de Gaussiano (Umbral 20-80, Sigma 1,5-2)
- Mediana-HighBoost (Ganancia 1.03-1.06)
- Mediana-LoG-LoG (Umbral 20-80, Sigma1 2,3, Sigma2 1,5)
- Gauss (Sigma 0,5-2,5)-Sobel (Umbral 60-90)
- Gauss (Sigma 0,5-1,5)-Laplaciano de Gaussiano (Umbral 20-80, Sigma 2) (Umbral 20-30, Sigma 2,5)
- Gauss (Sigma 0,5-2,5)-HighBoost (Ganancia 1.03-1.06)

- Gauss (Sigma 0,5-1,5)-LoG-LoG (Umbral 40-80, Sigma1 2,3, Sigma2 1,5)

El valor del umbral se incrementó 10 unidades cada vez, el valor de sigma 0,5 unidades y la ganancia del filtro de HighBoost 0.01 unidades. El número total de combinaciones fue de 114.

En la Tabla 1 se muestran los resultados más sobresalientes obtenidos al aplicar el algoritmo a 6 imágenes de laboratorio, en las que se encuentran 23 granos completos.

Table 1. Mejores índices de desempeño del algoritmo.

Combinación	m. FR	σ . FR	m. FA	σ . FA
Med-LoG ✓				
(μ σ_{LoG})				
40_2	26.87	11.75	5.8	5.91
50_2	24.85	13.36	7.09	9.28
60_2	25.26	19.5	5.65	2.56
70_2	26.79	25.04	6.33	5.18
Gauss-Sob				
(μ σ_G)				
60_0.5	32.92	9.08	4.56	4.56
Gauss-LoG				
(μ σ_{LoG} σ_G)				
40_2_1	26.91	12.79	6.09	8.99

La columna 1 presenta las combinaciones que brindaron mejores resultados: Mediana con el Laplaciano de Gaussiano (Med-LoG), Gauss con Sobel (Gauss-Sob) y Gauss con el Laplaciano de Gaussiano (Gauss-LoG). La nomenclatura utilizada indica los valores de los parámetros Sigma del filtro Gaussiano σ_G , Sigma del Laplaciano de Gaussiano σ_{LoG} y el umbral usado para la binarización de la imagen de bordes μ . Las demás columnas indican: el porcentaje promedio del Falso Rechazo ($m.FR$), la desviación del Falso Rechazo ($\sigma.FR$), el porcentaje promedio de la Falsa Aceptación ($m.FA$) y la desviación de la Falsa Aceptación ($\sigma.FA$) respectivamente.

La combinación Mediana con Laplaciano de Gaussiano funcionó mejor que las demás combinaciones, debido a la menor sensibilidad del filtro de mediana a la textura de los granos y a la sensibilidad del Laplaciano de Gaussiano a los contornos. Otra combinación que podría llegar a funcionar con índices de desempeño

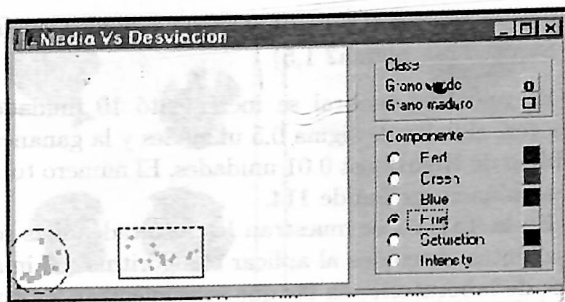


Figura 13. Media contra Desviación de la componente.

superiores al 60% es la de Gauss con Laplaciano de Gaussiano.

5.2 Resultados del proceso de clasificación de los frutos de café

Con el fin de analizar las características de los frutos de café de forma individual, se aislaron 100 granos de café en 100 máscaras diferentes. Se realizó un análisis del histograma de las componentes de color en los espacios HSI y RGB a las máscaras obtenidas; dicho análisis comprende la medida de la media y la desviación del histograma de acuerdo a una función de densidad de probabilidad Gaussiana.

Se encontró que la componente de tono del espacio de color HSI ofrece mayor información discriminante como lo muestra la Figura 13. Los puntos encerrados en el círculo corresponden a frutos maduros y los restantes a frutos verdes. Al observar estas gráficas se advierte que en principio, estas medidas brindan suficiente información discriminante acerca del grado de maduración de un grano, ya que la media del histograma en la componente de tono es inversamente proporcional al grado de maduración.

Posteriormente, se realizó la adquisición de más imágenes, obteniéndose 300 máscaras de granos de café con diferente grado de maduración. Se tomaron en cuenta cuatro posibles etapas de desarrollo de los frutos de café: etapa 1, etapa 2 y etapa 3 y etapa 4, donde etapa 1 corresponde a los granos más verdes y etapa 4 a los granos maduros. Para llevar a cabo la caracterización se utilizaron 184 de las 300 máscaras disponibles obteniéndose los resultados que se muestran en la Figura 14.

Se presentó un solape entre las clases correspondientes a la etapa 1 y a la etapa 2, así que se empleó el tamaño como característica discriminante. Se calculó el tamaño en píxeles de los frutos de café y se graficaron los resultados en el espacio Media de la componente de tono contra Tamaño. Los resultados se muestran en la Figura 15. Como puede observarse




Figura 14. Clasificación de frutos de las cuatro etapas en el espacio: Media de la componente de tono contra Desviación.




Figura 15. Clasificación en el espacio: Media de la componente de tono contra Tamaño.

el tamaño ofrece mayor capacidad discriminante para las etapas 1 y 2.

Una vez determinadas las características más discriminantes, se entrenó un clasificador bayesiano bidimensional, cuyo vector de características fue definido como:

$$x = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$$

donde x_1 es el valor medio del histograma de la componente de tono y x_2 es el tamaño del grano.

Para entrenar este clasificador se utilizaron 80 frutos pertenecientes a la etapa 1, 52 pertenecientes a la etapa 2, 20 frutos de la etapa 3 y 32 de la etapa 4. Los valores de los parámetros obtenidos de este entrenamiento se resumen en la tabla 2:

Una vez diseñado el clasificador se utilizaron los 116 frutos restantes para evaluar su desempeño, la efectividad de esta clasificación se resume en la tabla 3:

Para todas las etapas se obtuvo un desempeño superior al 91%, que es un buen resultado para esta fase del proyecto.

Table 2. Parámetros del clasificador Bayesiano.

Parám.	Clase 1	Clase 2	Clase 3	Clase 4
μ_1	95.78	94.72	73.23	18.29
σ_1	3.09	4.49	14.23	12.39
μ_2	41.82	121.98	160.29	161.19
σ_2	18.72	44.31	24.65	15.11

Table 3. Efectividad del clasificador Bayesiano.

	Efectividad
Etapas 1	92.4%
Etapas 2	97.4%
Etapas 3	94.1%
Etapas 4	91.4%

6 CONCLUSIONES

En este trabajo se han presentado diferentes técnicas de Visión Artificial, como son la segmentación y la clasificación de frutos de café, aplicadas al proceso de producción de café.

Los algoritmos de segmentación desarrollados, permiten detectar los frutos maduros, cuando no aparecen solapes que oculten información. Además, el proceso de segmentación es fuertemente dependiente de la calidad de la imagen de bordes, debido a la condición utilizada para terminar el crecimiento del contorno activo.

El experimento realizado en la etapa de segmentación, muestra que el método de preproceso de Mediana con Laplaciano del Gaussiano detecta en la mayoría de los casos analizados hasta aproximadamente un 80% del grano.

El análisis realizado en la etapa de caracterización ha brindado buenos resultados preliminares que permiten pensar en la posibilidad de utilizar la media del tono y el tamaño de los granos como características discriminantes para determinar el grado de maduración.

La implementación de un algoritmo robusto de bordes y separación de regiones es de gran importancia para lograr una mejor segmentación. Se debe mejorar el proceso de adquisición de las imágenes, haciendo énfasis en la iluminación, especialmente para las aplicaciones en campo.

Finalmente, después de esta primera exploración

se concluye que la Visión Artificial es una herramienta que puede ser utilizada en muchas etapas del proceso del café, como son: el pronóstico de cosecha, la cosecha mecanizada, el proceso de beneficio y la detección de enfermedades y plagas.

REFERENCIAS

- Bässamann, H. Henning. *Ad Oculos Digital Image Processing*. International Thomson computer Press, 1995. Chorafas D. N. *Realidad Virtual*, Ed. Prentice Hall, 1995.
- Duda, R., Hart, P., Stork, D. *Pattern Classification*. Wiley-Interscience, second edition 2001.
- Fisher, A., Perkins, S., Walker A., Wolfart E. *Gaussian Smoothing*. <http://www.dai.ed.ac.uk/HIPR2/gsmooth.htm>, consultada 2001.
- González, R., Woods, R. *Procesamiento Digital de Imágenes*. Addison Wesley, 1992.
- Hayashi, S., Sakaue, O., Kanuma T. *Study on Tomato Harvesting Robot*. In International Symposium on fruit, nut and vegetable production Engineering. California. USA, September 3-10 1997.
- Henao, J. *Automatización de un equipo para aplicar vibraciones circulares al tallo de café*. Tesis de Pregrado, Ingeniería Electrónica, Universidad Nacional De Colombia, Sede Manizales, 2000.
- Jiménez, A.R., Ceres R., Pons, J.L. *A Survey of Computer Vision Methods for Locating Fruit on Trees*. Transactions of the ASAE, 43(6):1991-1920, 2000.
- Oliveros, C. *Propuesta de investigación: Disminución de Costos en la Cosecha del Café Mediante la Mecanización y la Cosecha Manual Asistida*. Centro Nacional de Investigaciones del Café - CENICAFE, Disciplina de Ingeniería Agrícola, second edition, 2000.
- Paulus, I., De Busscher, Schrevers, E. *Use of Image Analysis to Investigate Human Quality Classification of Apples*. Journal of Agricultural Engineering Research, 68(3):341-353, 1997.
- Plá, F., Juste, F., Ferri, F., Vicens, M. *Color Segmentation Based on a Light Reflection Model to Locate Citrus Fruit for Robotic Harvesting*. Computer Electronics in Agriculture, 9(2-3):53-70, 1993.
- Salazar, G., Pulgarín, A., Riaño, H., Bustillo, P. *Crecimiento y Desarrollo del Fruto del Café y su relación con la Broca*. Avances Técnicos. Cenicafe. Número 194, Septiembre 1993.
- Umbaugh, S. *Computer Vision and Image Processing*. Prentice Hall, 1998.