

**IDENTIFICACION DE LAS ETAPAS DE MADURACION DE LA PIÑA
PEROLERA EMPLEANDO TECNICAS DE VISION ARTIFICIAL**

SERGIO LIZCANO JIMÉNEZ

**UNIVERSIDAD PONTIFICIA BOLIVARIANA
ESCUELA DE INGENIERÍAS Y ADMINISTRACIÓN
FACULTAD DE INGENIERÍA ELECTRÓNICA
BUCARAMANGA**

2010

**IDENTIFICACION DE LAS ETAPAS DE MADURACION DE LA PIÑA
PEROLERA EMPLEANDO TECNICAS DE VISION ARTIFICIAL**

SERGIO LIZCANO JIMÉNEZ

**Trabajo de grado presentado como requisito para optar el título de
Ingeniero Electrónico**

**Director
LUIS ÁNGEL SILVA PhD.**

**UNIVERSIDAD PONTIFICIA BOLIVARIANA
ESCUELA DE INGENIERÍAS Y ADMINISTRACIÓN
FACULTAD DE INGENIERÍA ELECTRÓNICA
BUCARAMANGA**

2010

Nota de aceptación:

Firma del jurado

Firma del jurado

Este proyecto va dedicado

A Dios quien ha sido mi fuerza, sabiduría y fortaleza durante toda mi vida.

A mis padres y hermanos quienes han sido mi apoyo incondicional para lograr mis propósitos.

A mis amigos y profesores quienes me brindaron su amistad y ayuda durante mi proceso de formación.

Sergio Lizcano J.

AGRADECIMIENTOS

A mi director de proyecto: Luis Ángel Silva PhD. por su excelente compromiso con el proyecto, disposición para aclarar dudas y aportes para que todo fuera un éxito.

Al docente Omar Pinzón Ardila PhD. por su ayuda desinteresada en la solución de dudas y aportes al proyecto.

Al docente Ing. Fabio Alonso Guzmán por su compromiso con mi proceso de formación como ingeniero y sus valiosos aportes en la ejecución del proyecto.

A mis compañeros y amigos, Ing. Ivan Auriol Muñoz Quiñonez y al Ing. Jhon Alexander Mora por sus aportes en la realización de este proyecto.

A mi primo Hernando Ardila Jiménez y su socio Leonidas Villareal García por sus asesorías en cultivo de la piña y proveer las piñas necesarias para este proyecto.

A todas las personas vinculadas directa o indirectamente con mi formación como profesional. A todos ellos mil gracias.

CONTENIDO

pág.

INTRODUCCION.....	14
1. TECNICAS DE VISION ARTIFICIAL	17
1.1. PROCESAMIENTO DE IMÁGENES.....	18
1.1.1 La imagen.....	18
1.1.2 Adquisición de Imágenes.....	19
1.1.3 El color.....	20
1.1.3.1 Modelo de color.....	21
1.1.4 Transformaciones básicas.....	24
1.1.5 El histograma.....	25
1.1.6 Operaciones morfológicas.....	27
1.1.6.1 Dilatación.....	28
1.1.6.2 Erosión.....	29
1.1.6.3 Apertura y cierre.....	30
1.2. ANALISIS: SEGMENTACION Y EXTRACCION DE CARACTERISTICAS.....	32
1.2.1 Segmentación.....	32
1.2.1.1 Segmentación basada en umbralización.....	33
1.2.2 Extracción de características.....	38
1.3. APLICACION: RECONOCIMIENTO DE PATRONES EN IMÁGENES	39
1.3.1 Técnicas de clasificación estadística.....	40
1.3.1.1 Agrupamiento mediante Clusters.....	42
1.3.1.2 Clasificador de mínima distancia.....	48
1.4. TECNICAS DE VISION ARTIFICIAL APLICADAS AL CONTROL DE CALIDAD DE PRODUCTOS AGRÍCOLAS	49
1.4.1 Adquisición de la imagen.....	50
1.4.2 Pre-procesamiento de la imagen.....	50
1.4.3 Segmentación de la imagen.....	51
1.4.4 Medición de objetos en la imagen.....	51

1.4.5 Clasificación.....	52
1.5. LIBRERIAS OPENCV.....	52
2. GENERALIDADES DE LA PIÑA.....	54
2.1. LA VARIEDAD PEROLERA.....	56
2.2. LA VARIEDAD MANZANA.....	57
2.3. LA VARIEDAD CAYENA LISA.....	58
2.4. CARACTERÍSTICAS FÍSICAS Y QUÍMICAS.....	58
2.5. CALIDAD DEL FRUTO.....	59
3. IDENTIFICACIÓN DE LAS ETAPAS DE MADURACIÓN DE LA PIÑA PEROLERA..	63
3.1. ADQUICISION DE LAS IMÁGENES.....	65
3.2. PRE-PROCESAMIENTO DE LAS IMAGENES	73
3.3. SEGMENTACION DE LAS IMAGENES	81
3.4. EXTRACCION DE CARACTERISTICAS.....	85
3.5. CLASIFICACIÓN.....	88
4. ANALISIS DE RESULTADOS.....	94
4.1. ERROR DE ESTIMACIÓN.....	102
5. CONCLUSIONES.....	105
BIBLIOGRAFIA.....	107

LISTA DE TABLAS

Tabla 1. Características físicas y químicas del fruto de la piña en sus tres variedades....	58
Tabla 2. Composición química de la piña.....	59
Tabla 3. Clasificación de las muestras de evaluación utilizando el algoritmo propuesto ..	94
Tabla 4. Clasificación según expertos para la piña 03.	100
Tabla 5. Clasificación según expertos para la piña 10	100
Tabla 6. Clasificación según expertos para la piña 11.	100
Tabla 7. Clasificación según expertos para la piña 17.	101
Tabla 8. Clasificación según expertos para la piña 18.	101
Tabla 9. Porcentajes de error para cada etapa de maduración.....	103

LISTA DE FIGURAS

Figura 1. Imagen Digital.....	19
Figura 2. Funcionamiento dispositivo CCD	20
Figura 3. Tetraedro de color RGB	22
Figura 4. Modelo de color HSV.	23
Figura 5. El histograma de una imagen	26
Figura 6. Dilatación de una imagen.....	29
Figura 7. Erosión de una imagen	30
Figura 8. Operación apertura	31
Figura 9. Operación cierre	32
Figura 10. Histograma de dos distribuciones y su umbral óptimo.....	35
Figura 11. Representación de una imagen binaria	37
Figura 12. Diagrama de bloques de un clasificador estadístico.....	40
Figura 13. Resultados del agrupamiento según los criterios (a) forma cómo hacen sus crías y (b) el entorno donde viven.....	42
Figura 14. Pasos generalmente utilizados en un sistema de visión artificial.....	50
Figura 15. Fruto de la piña	54
Figura 16. Flor de la piña	55
Figura 17. Colino basal	55
Figura 18. Piña de la variedad Perolera	57
Figura 19. Cambio de color en la piña durante el almacenamiento	61
Figura 20. Diagrama de flujo del algoritmo implementado	64
Figura 21. Imagen e histograma de la componente matiz para dos muestras diferentes en la primera toma de muestras	66
Figura 22. Imagen e histograma de la componente matiz para dos muestras diferentes en la segunda toma de muestras.....	67
Figura 23. Efecto sombra sobre el fondo	68
Figura 24. Recámara utilizada para la tercera toma de muestras	69
Figura 25. Diagrama de la base de datos	70
Figura 26. Seguimiento diario de una piña específica	71
Figura 27. Imagen e histograma de la componente matiz para dos muestras diferentes en la tercera toma de muestras	72
Figura 28. Estructura IplImage.....	74
Figura 29. Conversión del modelo RGB al HSV	75
Figura 30. Planos H, S y V.....	76
Figura 31. Imágenes en el espacio HSV de una piña en sus días de maduración	77
Figura 32. (a) Histograma del plano H, (b) Histograma del plano S	78
Figura 33. Filtro de la mediana del tipo “moving average”.....	79
Figura 34. (a) Histograma sin filtro, (b) Histograma con el filtro aplicado tres veces.....	80
Figura 35. Histograma del plano H utilizado en la segmentación	81
Figura 36. Imagen Binarizada	83

Figura 37. Imagen tratada mediante la operación morfológica de apertura	84
Figura 38. Imagen obtenida del proceso de segmentación	84
Figura 39. La media en cada histograma para una piña específica. (a) La media para H y (b) La media para S	86
Figura 40. Medias de los planos H y S durante los días del proceso de maduración. (a) Medias del plano H y (b) Medias del plano S	87
Figura 41. Espacio de características	89
Figura 42. Agrupamiento de las características y el traslape entre los límites de cada grupo.	90
Figura 43. Agrupamiento de las características cambiando la escala de μH	91
Figura 44. Centroides obtenidos en la fase de entrenamiento	92
Figura 45. Clasificación de la piña 03 según el clasificador.....	95
Figura 46. Clasificación de la piña 10 según el clasificador.....	96
Figura 47. Clasificación de la piña 11 según el clasificador.....	97
Figura 48. Clasificación de la piña 17 según el clasificador.....	98
Figura 49. Clasificación de la piña 18 según el clasificador.....	99
Figura 50. Traslape que aun se presenta entre la etapa 2 y 3	103
Figura 51. Estructura general del algoritmo.	111

LISTA DE ANEXOS

Anexo A. Estructura del algoritmo en C.....	110
---	-----

RESUMEN GENERAL DE TRABAJO DE GRADO

TITULO: IDENTIFICACION DE LAS ETAPAS DE MADURACION DE LA PIÑA PEROLERA EMPLEANDO TECNICAS DE VISION ARTIFICIAL

AUTOR: Sergio Lizcano Jiménez

FACULTAD: Facultad de Ingeniería Electrónica

DIRECTOR: Luis Ángel Silva PhD.

RESUMEN

Los sistemas de visión artificial para la evaluación de calidad de los alimentos han tenido gran aceptación en la industria alimenticia, ya que han aumentado la demanda de objetividad, coherencia y eficiencia en la evaluación de la calidad de los alimentos. Por lo tanto se desarrolló un algoritmo para la identificación de los estados de maduración de la piña Perolera en post-cosecha. Para adquirir las imágenes fue necesario construir una recámara con condiciones de luz homogéneas y un color de fondo uniforme. Se utilizó una cámara CCD para capturar la imagen de la piña. El modelo de color HSV fue utilizado en el procesamiento de las imágenes, ya que emula la forma como los inspectores entrenados perciben el color de los frutos. El histograma de la componente de matiz tiene una distribución bimodal, que corresponde a la fruta y al fondo. La máxima varianza del nivel de gris de la componente matiz, entre la fruta y el fondo determina el umbral óptimo. Una vez la imagen fue segmentada satisfactoriamente, se extrajo el área de interés. Luego, se calculó la media de los histogramas de las componentes matiz y saturación. Por último, mediante técnicas de clasificación estadística de aprendizaje no supervisado, se agruparon los datos utilizando un algoritmo MBSAS y se clasificaron las muestras mediante un clasificador de mínima distancia. En total se utilizaron 319 muestras, 110 para entrenar y 209 para evaluar. Los resultados mostraron que el algoritmo tiene una eficiencia del 96,36%.

PALABRAS CLAVES: PIÑA, VISION ARTIFICIAL, CONTROL DE CALIDAD, ALGORITMO, RECONOCIMIENTO DE PATRONES.

GENERAL SUMMARY OF WORK OF DEGREE

TITLE: IDENTIFICATION OF MATURITY STATES OF PEROLERA PINEAPPLE USING ARTIFICIAL VISION TECHNIQUES

AUTHOR: Sergio Lizcano Jiménez

DEPARTMENT: Facultad de Ingeniería Electrónica

SUPERVISOR: Luis Ángel Silva PhD.

ABSTRACT

The artificial vision systems for food quality evaluation are being used in the food industry because it has increased demands for objectivity, consistency and efficiency in food quality evaluation. Therefore was developed an algorithm for the identification of the maturity stages of Perolera pineapple on post harvest. To acquire the images was necessary make a chamber with homogeneous light conditions and a uniform background color. Was used a camera CCD to capture pineapple image. The HSV color model was used in the image processing because it emulates how the trained inspectors perceive color on the fruits. The intensity histogram of the Hue component in the image had a bimodal distribution for the fruit portion and the background portion. The maximum grey level variance of the Hue component between the fruit and the background determined the optimal threshold. Once the image was segmented successfully, the interest area was extracted. Then, mean of the histograms of the hue and saturation component was calculated. Finally, using statistical classification techniques of unsupervised learning, the data were clustered using a MBSAS algorithm and the samples were classified using a minimum distance classifier. In total were used 319 samples, 110 for learning and 209 for evaluating. The results showed that the algorithm has efficiency 96,36%.

KEYWORDS: PINEAPPLE, ARTIFICIAL VISION, QUALITY CONTROL, ALGORITHM, PATTERN RECOGNITION.

INTRODUCCION

La agricultura ha sido fundamental en el desarrollo del hombre, es por ello que adaptar nuevas tecnologías a este campo no es un fenómeno reciente, data de miles de años. La arqueología ha demostrado que civilizaciones como el antiguo Egipto utilizaban sus más recientes innovaciones para mejorar sus cosechas.

El control de calidad automático en productos agrícolas ha evolucionado en conjunto con la tecnología en la adquisición de imágenes y la velocidad de procesamiento de los actuales computadores. Debido a este fenómeno la visión artificial ha tomado gran importancia en países donde la agricultura juega un papel fundamental para su economía, entre estos están: Estados Unidos, Japón, Irlanda, Canadá, China, Brasil, entre otros.

Según Tillet¹, el potencial de aplicación de las técnicas para el procesamiento de imágenes en la industria agrícola ha sido contemplado desde hace tiempo atrás. Por otra parte Gunasekaran² afirma que la industria alimenticia se encuentra en el “top 10” de las industrias que utilizan técnicas para el procesamiento de imágenes. Por lo tanto, hoy en día muchos países utilizan la visión artificial como una alternativa para mejorar el control de calidad en productos agrícolas, esto les permite ser más competitivos en el mercado globalizado brindando productos de mayor calidad a los consumidores.

Dentro de los trabajos más relevantes del control de calidad aplicado a productos agrícolas y empleando técnicas de visión artificial se destacan: un algoritmo de segmentación para el reconocimiento de manzanas de la variedad *Fuji* en época

¹ TILLET, R. D. Image analysis for agricultural processes. En: Division Note DN 1585. Research Institute. 1990.

² GUNASEKARAN, S. Computer vision technology for food quality assurance. En: Trends in food science & technology, Vol. 7, 1996; p. 245-256.

de cosecha, desarrollado por Kataoka³, *et al*, que permite reconocer manzanas para su posible recolección sobre el árbol.

Clasificación de frutas en función de su calidad externa usando visión artificial desarrollado por Leemans⁴, *et al*. Este trabajo presenta la clasificación de manzanas en cuatro clases en función de los estándares europeos. Los resultados que mostraron fueron un 78% y 72% de efectividad en la clasificación.

Un sistema de visión artificial que evalúa automáticamente el color de las manzanas dentro de cuatro clases conforme a los estándares estipulados en china, desarrollado por Zou⁵, *et al*.

Clasificación de manzanas de la variedad “Empire” y “Golden” basado en la calidad de su apariencia, usando redes neuronales “backpropagation” y clasificadores estadísticos tales como; árbol de decisión, K-nearest neighbour y bayesiano, desarrollado por Kadvir y Guyer⁶.

Un algoritmo de segmentación de frutos maduros y verdes de café en imágenes tomadas en condiciones controladas, basadas en las propiedades del color, realizado por Montes⁷.

Las condiciones geográficas de Colombia permiten el cultivo de una extensa variedad de productos agrícolas. Debido a esta ventaja, en Colombia la mayor

³ KATAOKA, T; BULANON, D. M; HIROMA, T; OTA, Y. A segmentation algorithm for the automatic recognition of Fuji apples at harvest. En: Biosystems Engineering. Vol. 83, No. 4, (dic. 2002); p. 405-412.

⁴ LEEMANS, V; MAGEIN, H. y DESTAIN, M. F. On-line Fruit Grading according to their External Quality using Machine Vision. En: Biosystems Engineering. Vol. 83, No. 4, (dic. 2002); p. 397-404.

⁵ ZOU, X; ZHAO, J; LI, Y. Apple color grading based on organization feature parameters. En: Pattern Recognition Letters. Vol. 28, No. 15, (nov. 2007); p. 2046-2053.

⁶ KADVIR, I. y GUYER, D.E. Comparison of Artificial Neural Networks and statistical classifiers in Apple Sorting using Textural Feature. En: Biosystems Engineering. Vol. 89, No. 3, (nov. 2004);p. 331-334.

⁷ MONTES CASTRILLON, Nubia. Desarrollo de algoritmos de segmentación de frutos maduros y verdes de café en imágenes tomadas en condiciones controladas, basados en las propiedades de color. Trabajo de grado (Ingeniería Electrónica). Manizales: Universidad Nacional de Colombia. Facultad de ingeniería y arquitectura, 2001, 42 p.

demanda en exportaciones está reflejada en el sector alimenticio. Sin embargo existen deficiencias en los procesos de control de calidad de los productos agrícolas, dado a que en un alto porcentaje, estos se realizan de manera empírica y subjetiva por parte de un inspector de calidad, proceso que no garantiza la homogeneidad del producto.

Con el fin de mejorar la homogeneidad en los procesos de control de calidad y la competitividad de los productos agrícolas en Colombia, en este trabajo se presenta una metodología que permite identificar automáticamente las etapas de maduración de la piña en su variedad Perolera. La metodología emplea las técnicas de visión artificial a través de los siguientes pasos: adquisición, pre-procesamiento, segmentación, medición y clasificación. Se emplearon 319 muestras en total. Los resultados muestran una eficiencia del 96,36% para el algoritmo implementado.

Este documento se estructura de la siguiente manera: inicialmente en los capítulos 1 y 2, se presentan las técnicas de visión artificial y las generalidades de la piña. El capítulo 3, muestra la metodología seguida en el proceso de identificación de las etapas de maduración de la piña Perolera. Finalmente, en los capítulos 4 y 5, se presentan los resultados obtenidos en el proceso de clasificación y las conclusiones del presente trabajo.

1. TECNICAS DE VISION ARTIFICIAL

La visión artificial ha sido mejorada mediante la revolución tecnológica actual. Cada día estamos sometidos a nuevas transformaciones tecnológicas y estas a su vez evolucionan las diferentes áreas que dependen de ella. Por su parte la visión artificial es una de las áreas que depende de la tecnología existente para su desarrollo, no obstante se basa en principios matemáticos y físicos para su modelado.

“La visión artificial por computador es la capacidad de la máquina para ver el mundo que le rodea, más precisamente para deducir la estructura y las propiedades del mundo tridimensional a partir de una o más imágenes bidimensionales”⁸.

Esta definición es bastante objetiva y a partir de ella se puede aclarar algunos términos que se utilizarán durante el presente informe. Algunos autores utilizan el término visión por computador, otros utilizan visión artificial, sin embargo en este informe se utilizará el segundo por estandarización.

En visión artificial se diferencian tres procesos importantes: procesamiento, análisis y aplicaciones. Los cuales se describirán en este capítulo.

El procesamiento involucra el manejo de las imágenes como señales digitales, para extraer la información más elemental. El análisis está encaminado a determinar estructuras elementales tales como bordes o regiones, así como la

⁸ PAJARES M, Gonzalo y DE LA CRUZ G, Jesús M. Visión por Computador. Imágenes digitales y aplicaciones. 2da Edición. México: Alfaomega, 2008. p. 2.

relación entre ellas. Y las aplicaciones para dar soluciones a los problemas del mundo real, tales como: reconocimiento, movimiento, reconstrucción 3D, etc.

1.1. PROCESAMIENTO DE IMÁGENES

Según Pajares⁹, las técnicas para el procesamiento de imágenes se clasifican en dos áreas de aplicación: la primera para mejorar la calidad de la imagen para su interpretación y la segunda para el procesamiento de la información suministrada por la imagen de forma automatizada. Todos estos con el propósito de suministrar tanto al ser humano como a las máquinas datos relevantes para su posterior utilización.

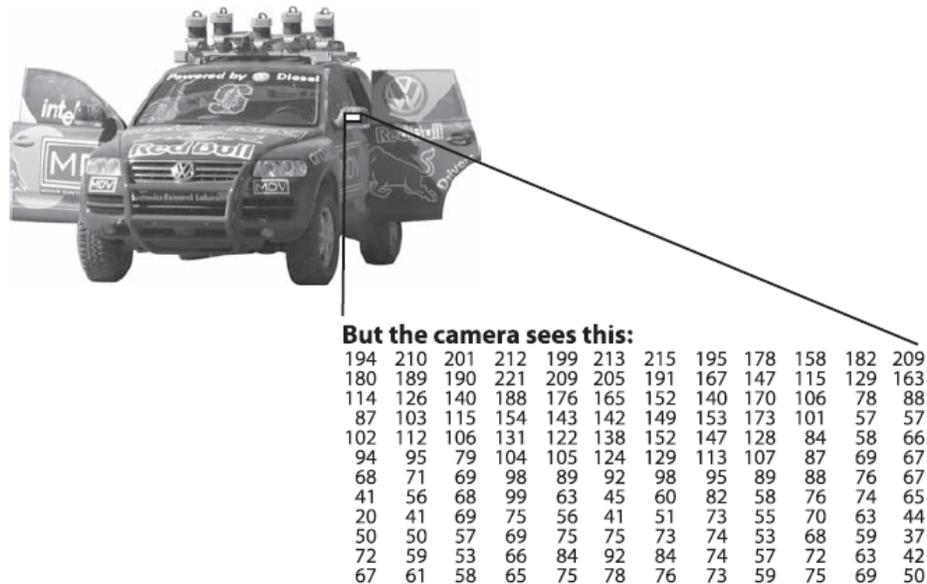
Procesar una imagen implica conocer primero la naturaleza de la misma, sea analógica o digital una imagen es una representación visual de la apariencia física de uno o varios objetos dentro de una misma escena.

1.1.1 La imagen. Se puede expresar matemáticamente como una función de intensidad bidimensional. Cada valor de intensidad se representa con valores enteros del 0 al 255 y a estos valores se le llaman nivel de gris de la imagen. Una imagen digital se muestra como una matriz de números enteros en la cual cada valor entero representa la intensidad de los objetos de la escena en un tiempo discreto.

Para que la imagen pueda ser procesada por el computador debe ser entregada en forma de matriz con una resolución de $M \times N$ elementos. A cada elemento de esta matriz se le denomina píxel y el valor que representa corresponde al nivel de luminosidad (nivel de gris) de ese punto en la escena tomada (Figura 1).

⁹ PAJARES M, Gonzalo y DE LA CRUZ G, Jesús M. Op. Cit., p. 1.

Figura 1. Imagen Digital

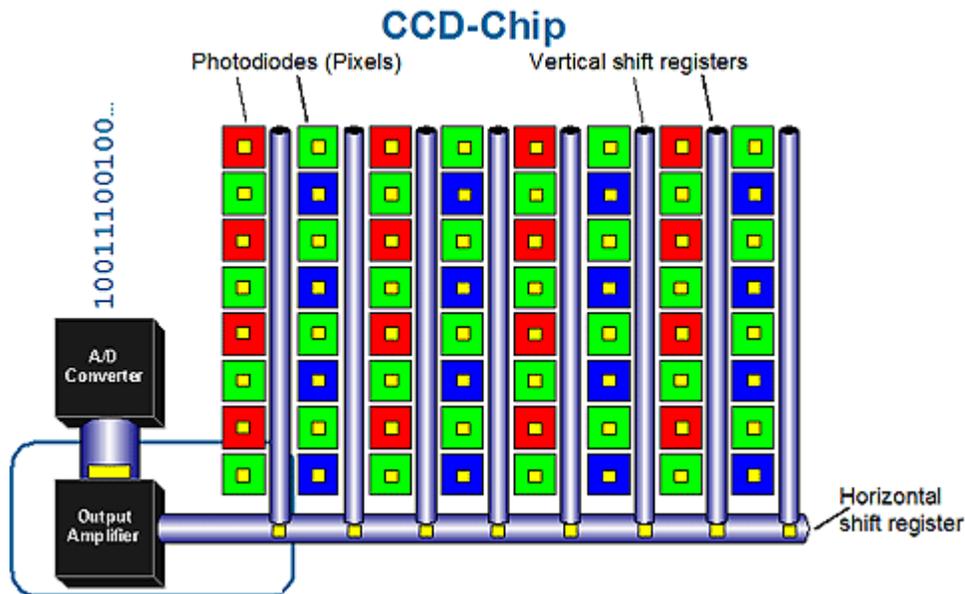


Fuente: BRADSKI, Gary y KAEBLER, Adrian. Learning OpenCV. Computer Vision with the OpenCV Library. USA: O'REILLY, 2008. p. 3.

1.1.2 Adquisición de Imágenes. Es el primer procedimiento que se debe realizar en cualquier sistema de visión artificial. Para adquirir una imagen digital se utilizan dos clases de dispositivos: las cámaras de televisión y los dispositivos de cargas interconectadas o CCD (*Charge Coupled Device* - en inglés). El más relevante para este documento es del tipo CCD, debido a que este dispositivo es el más usado en cámaras digitales comerciales.

Como se observa en la Figura 2, el CCD está compuesto por un arreglo de pequeños foto diodos llamados *photosites* los cuales transforman las intensidades de luz en la escena en señales eléctricas cuantificables que luego son convertidas en señales digitales.

Figura 2. Funcionamiento dispositivo CCD



Fuente: <http://www.axis.com/edu/axis/images/ccd.gif>

1.1.3 El color. Es una importante fuente de información visual al momento de procesar una imagen. La luz que refleja un objeto determina los colores que el ojo humano percibe. Dependiendo de la longitud de onda predominante en el objeto será el color que lo caracterice. De esta manera el color es una representación perceptible de la luz que refleja la superficie de un objeto.

La descripción que el color puede dar de una imagen al momento de analizarla permite la identificación y extracción de objetos de una escena. También permite distinguir características correspondientes en la gama de colores que una imagen puede tener.

“Desde el punto de vista del ojo humano, todos los colores son vistos como combinaciones variables de los tres colores primarios: rojo (R), verde (G) y azul (B). La CIE (*Commission Internationale de L'éclairage - en frances*) asignó en 1931 los siguientes valores de longitudes de onda a los colores primarios:

azul=435,8 nm, verde=546,1 nm, y rojo =700 nm. Los colores primarios pueden mezclarse para producir los secundarios de la luz: magenta (rojo y azul), cian (verde y azul) y amarillo (rojo y verde). La mezcla de los tres colores primarios o secundarios en proporciones iguales produce color blanco”¹⁰.

Hay tres características fundamentales para distinguir un color de otro: el brillo, el matiz y la saturación. La primera es la intensidad de luz que refleja o emite un determinado objeto, el matiz es la longitud de onda que más prevalece en el objeto y la saturación se refiere a la pureza o a la presencia de luz blanca que afecta el matiz.

1.1.3.1 Modelo de color. Facilita el procesamiento de la imagen debido a que organiza los colores en alguna forma estándar. De forma matemática está formado por un sistema de coordenadas en 3-D y un sub-espacio dentro de ese sistema, donde cada color es representado como un punto (Pajares¹¹).

Algunos modelos de color están orientados hacia el hardware y otros hacia aplicaciones en las cuales es necesario manipular el color como en la creación de gráficos a color para animaciones. Los modelos más comunes aplicados al hardware son: el RGB, el CMYK, y el YIQ. Por otra parte, para el procesamiento de imágenes los más relevantes son: el RGB, el YIQ, el HSI y HSV que es una variación del HSI.

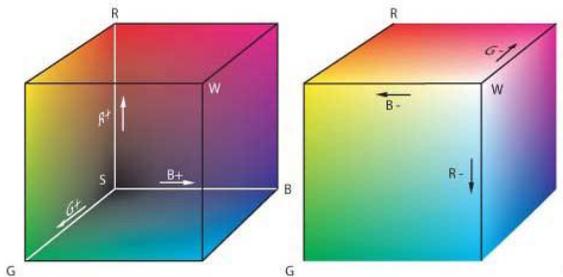
- **El modelo RGB.** Es usado generalmente en monitores a color, video cámaras y cámaras fotográficas digitales. Una imagen en el modelo RGB es representada por 8 bits en cada píxel R, G y B. Por lo tanto se pueden

¹⁰ PAJARES M, Gonzalo y DE LA CRUZ G, Jesús M. Op. Cit., p. 113-114.

¹¹ Ibid., p. 115.

representar 256^3 o 16.777.216 colores. Basado en un sistema de coordenadas cartesianas, este modelo posee un sub-espacio que se puede graficar en forma de tetraedro como lo muestra la Figura 3.

Figura 3. Tetraedro de color RGB

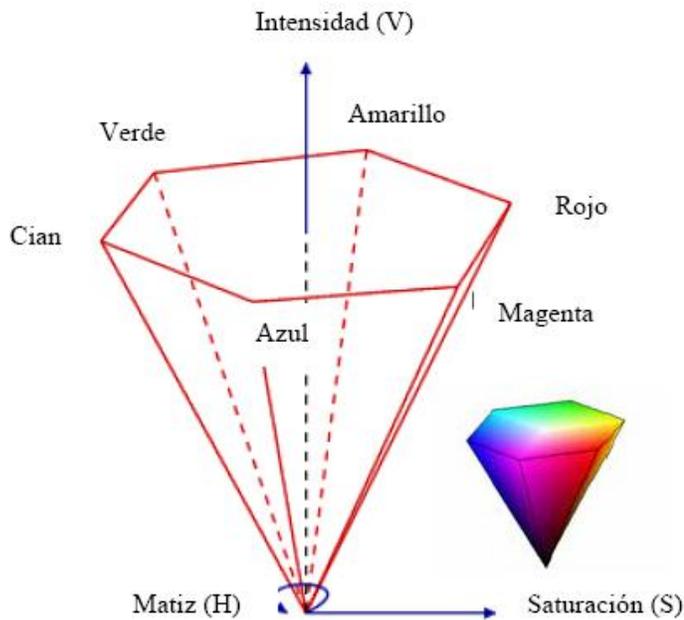


Fuente: <http://www.pce-iberica.es/medidor-detalles-tecnicos/images/medidor-color-pce-rgb-imagen1.jpg>

- **El modelo CMY.** Es el más utilizado en dispositivos que depositan pigmentos de color, como las impresoras y las fotocopiadoras a color. Utiliza fundamentalmente los colores secundarios como el cian, magenta y amarillo. A diferencia de modelo RGB este modelo es sustractivo y además se fundamenta en la absorción de la luz.
- **El modelo HSV.** Está diseñado para imitar la percepción del color visto desde la perspectiva humana. Esto se debe a que los humanos pueden identificar en una imagen el matiz o la pureza del color que esta posee y la cantidad de color diluido con la luz blanca. Este modelo se caracteriza por tener tres componentes: Matiz (Hue), Saturación (Saturation) y Valor (Value). Esta última componente también se le conoce como brillo. El sistema de coordenadas que

este modelo utiliza es cilíndrico, y el sub-espacio de color es una pirámide de base hexagonal (Figura 4).

Figura 4. Modelo de color HSV.



Fuente: GIL, Pablo; TORRES, Fernando y ORTIZ, Francisco G. Detección de objetos por segmentación multinivel combinada de espacios de color. En: XXV Jornadas de Automática. Trabajo Nro. 19. (3:8-10, septiembre: Ciudad Real). Universidad de Castilla – La Mancha, 2004. P. 2.

Algunas de sus más importantes aplicaciones son: “El diseño de sistemas para verificar el grado de madurez de las frutas o la inspección del acabado de color en determinados productos. La idea consiste en utilizar las propiedades del color del mismo modo que lo haría una persona encargada de la misión”¹².

¹² PAJARES M, Gonzalo y DE LA CRUZ G, Jesús M. Op. Cit., p. 118.

Normalmente, es necesario realizar una conversión del modelo RGB a HSV debido a que la mayoría de los dispositivos de captura utilizan el primero. De una manera simple se puede realizar una conversión de la siguiente manera:

$$H = \tan \left[\frac{3(G - B)}{(R - G) + (R - B)} \right]; \quad S = 1 - \frac{\min(R, G, B)}{V}; \quad V = \frac{R + G + B}{3} \quad (1)$$

Donde, H no está definida cuando S=0.

1.1.4 Transformaciones básicas. Para procesar una imagen se debe tener en cuenta dos clases macro de operaciones de trabajo:

- ❖ Operaciones individuales.
- ❖ Operaciones de vecindad.

Las operaciones individuales modifican el valor del píxel de la nueva imagen con respecto a la imagen de entrada. Esto implica tomar el valor del píxel en una determinada posición en la imagen, modificando este valor con alguna operación lineal o no lineal. Luego el resultado de esta operación se ubica dentro de la misma posición del píxel original en la nueva imagen. Este proceso es repetitivo pues es necesario realizarlo píxel por píxel.

Algunas de las operaciones individuales más utilizadas son: operador identidad, operador inverso, operador umbral, adición, sustracción y transformación de dos imágenes punto a punto.

Las operaciones de vecindad transforman el valor de un píxel en base a los valores que poseen los píxeles vecinos o más cercanos. A diferencia de las

operaciones de vecindad, estas operaciones pueden alterar el tamaño de la imagen de salida. Algunas de las transformaciones de vecindad más relevantes son las operaciones de convolución.

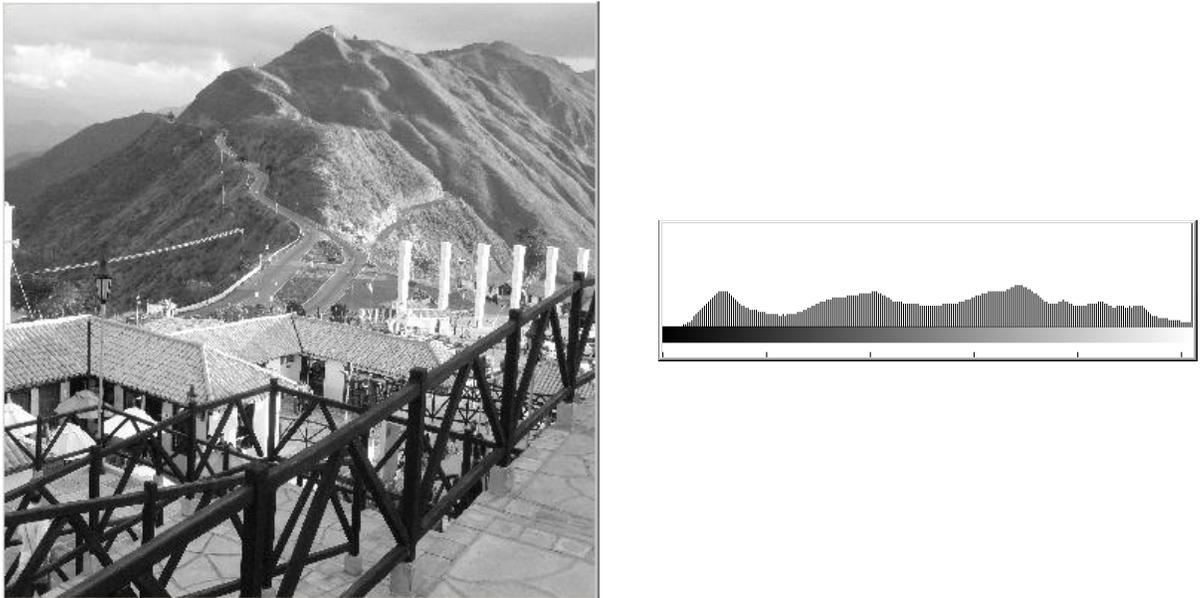
Como resultado de estas operaciones la información en la nueva imagen o imagen de salida estará en función ya sea del valor de cada píxel o de los valores en aledaños de un determinado píxel.

1.1.5 El histograma. Representa la frecuencia relativa de ocurrencias de los valores de gris en la imagen. Gráficamente se puede ilustrar como lo muestra la Figura 5. Matemáticamente hablando para una imagen digital con niveles de gris en el rango de $[0, L-1]$ donde L es el máximo nivel de gris en la imagen, el histograma es una función discreta de la forma:

$$P(n) = \frac{H(n)}{N} \quad (2)$$

Donde $P(n)$ es la probabilidad de ocurrencia de un determinado nivel n , $H(n)$ el número de píxeles en ese nivel de gris y N es el total de píxeles en la imagen.

Figura 5. El histograma de una imagen



Fuente: Autor.

Los histogramas entregan principalmente la descripción global de la imagen o pueden entregar información estadística de la imagen para un posible análisis de la misma.

Algunas de las propiedades estadísticas que un histograma puede entregar acerca de la distribución de los niveles de gris en la imagen son:

- ❖ La *media*: representa el valor medio de los niveles de gris en la imagen además entrega información acerca del brillo general de la misma. La media está definida por,

$$\mu = \sum_{n=0}^{L-1} n * P(n) \quad (3)$$

Si la media es alta entonces la imagen será brillante y viceversa.

- ❖ La *varianza*: mide la dispersión alrededor de la media. Se encuentra definida por,

$$\sigma^2 = \sum_{n=0}^{L-1} (n - \mu)^2 * P(n) \quad (4)$$

En una imagen con contraste alto su varianza será alta y viceversa.

- ❖ La *energía*: proporciona información acerca de la distribución de los niveles de gris. Está definida por,

$$E = \sum_{n=0}^{L-1} (P(n))^2 \quad (5)$$

A mayor número de niveles de gris en la imagen menor será la energía y viceversa.

1.1.6 Operaciones morfológicas. La morfología matemática es una potente herramienta al momento de procesar una imagen, debido a que simplifican las imágenes y preservan las formas elementales de los objetos. La morfología se fundamenta en el análisis y procesamiento de estructuras geométricas.

En visión artificial es común utilizar la morfología para el tratamiento de regiones ya que sus transformaciones permiten: suavizar los bordes de una región, separar o unir determinadas regiones y facilitar el cálculo de regiones en una imagen.

La principal aplicación se da en imágenes binarias pues los principios matemáticos fueron concebidos desde la perspectiva de la posición antes que desde la intensidad.

El conjunto de operaciones morfológicas más importantes para la realización de este proyecto son: dilatación, erosión, apertura y cierre.

1.1.6.1 Dilatación. Es un tipo de transformación morfológica representada por el operador binario \oplus la cual combina dos conjuntos utilizando la adición de conjuntos de Minkowski.

$$X \oplus B = \{d \in E^2: d = x + b \text{ para cada } x \in X \text{ y } b \in B\} \quad (6)$$

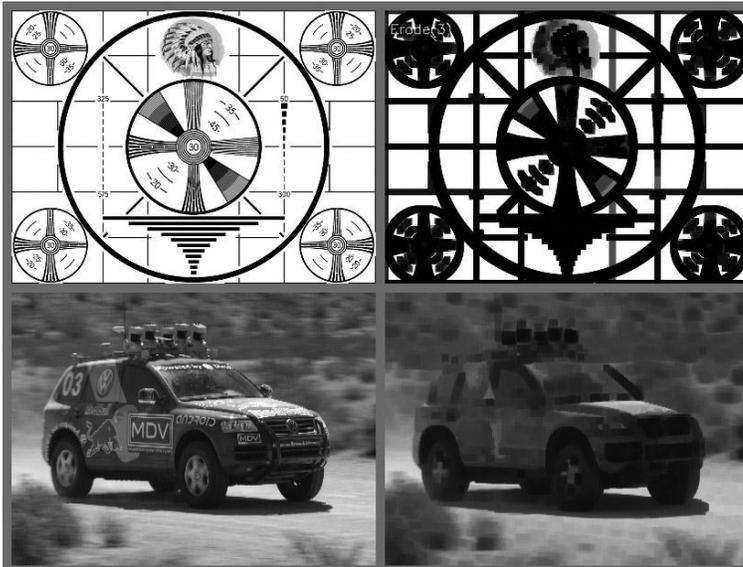
La anterior expresión dice que la dilatación $X \oplus B$ es el conjunto de puntos de todas las posibles adiciones vectoriales de pares de elementos x y b , uno para cada conjunto X y B .

Según Pajares y Cruz¹³, es común utilizar el espacio Euclídeo (E^2) ya que su sistema de subconjuntos es un dominio natural para la descripción de formas planas.

En la Figura 6 se puede apreciar el efecto de expansión en los bordes de la imagen producido mediante la operación dilatación.

¹³ PAJARES M, Gonzalo y DE LA CRUZ G, Jesús M. Op. Cit., p. 246.

Figura 6. Dilatación de una imagen



Fuente: BRADSKI, Gary and KAEBLER, Adrian. Learning OpenCV. Computer Vision with the OpenCV Library. USA: O'REILLY, 2008. p. 119.

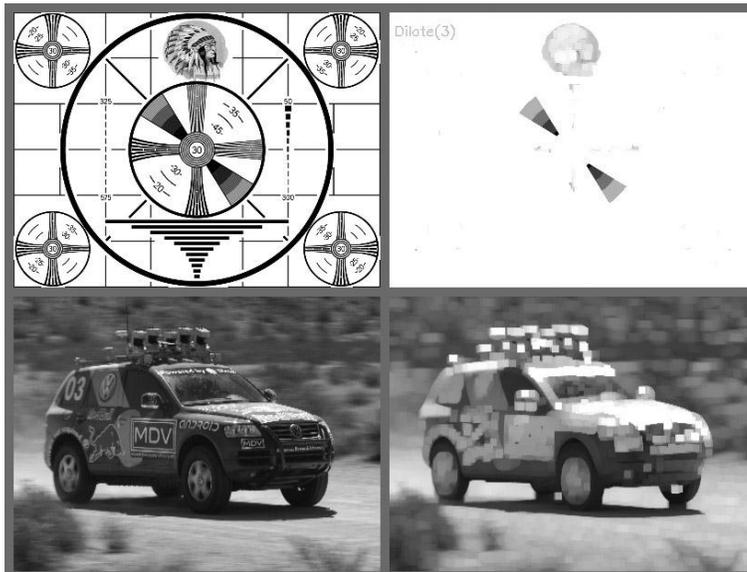
1.1.6.2 Erosión. Es un tipo de transformación morfológica representado por el operador binario \otimes la cual combina dos conjuntos utilizando la substracción de vectores. La erosión es dual y al igual que la dilatación es una operación no invertible.

$$X \otimes B = \{d \in E^2: d + b \in X \text{ para cada } b \in B\} \quad (7)$$

La anterior expresión afirma que para cada punto d del conjunto X , el resultado de la operación está dado por los puntos d tales que todos los posibles $d + b$ están en X .

En la Figura 7 se puede apreciar el efecto de desaparición de los bordes de la imagen producido mediante la operación erosión.

Figura 7. Erosión de una imagen



Fuente: BRADSKI, Gary y KAEBLER, Adrian. Learning OpenCV. Computer Vision with the OpenCV Library. USA: O'REILLY, 2008. p. 118.

1.1.6.3 Apertura y cierre. Tanto la erosión como la dilatación son transformaciones que no se pueden invertir. Debido a esto la nueva imagen será más simplificada y con menos detalles que la imagen original.

Al proceso en el cual se erosiona y posteriormente se dilata se le conoce como *apertura*. Matemáticamente se expresa con el operador \circ y se define,

$$X \circ B = (X \otimes B) \oplus B \quad (8)$$

Si primeramente se realiza una dilatación y luego una erosión a esto se le llama *cierre*. El operador que la representa es \cdot y se define,

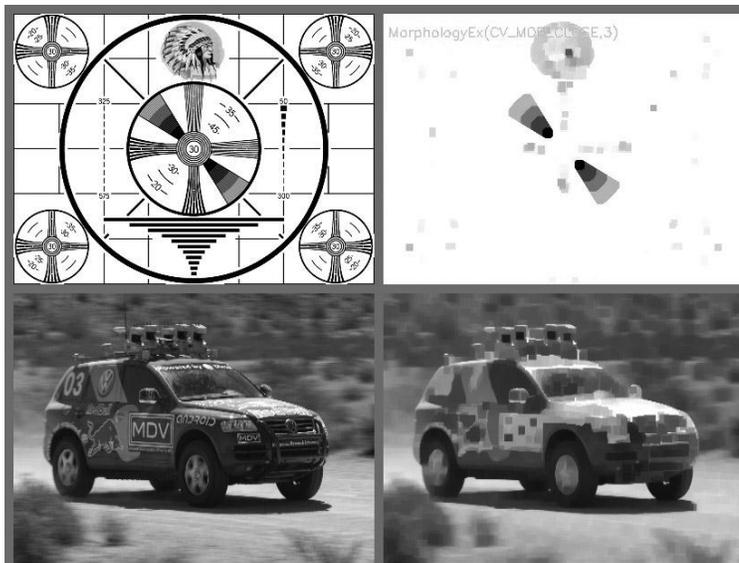
$$X \cdot B = (X \oplus B) \otimes B \quad (9)$$

La operación apertura y cierre se utilizan para suprimir detalles que son más pequeños que el elemento estructural.

La operación cierre cuenta objetos que están próximos entre sí, rellena los pequeños huecos y suaviza el contorno del objeto, mientras que la apertura realiza lo contrario.

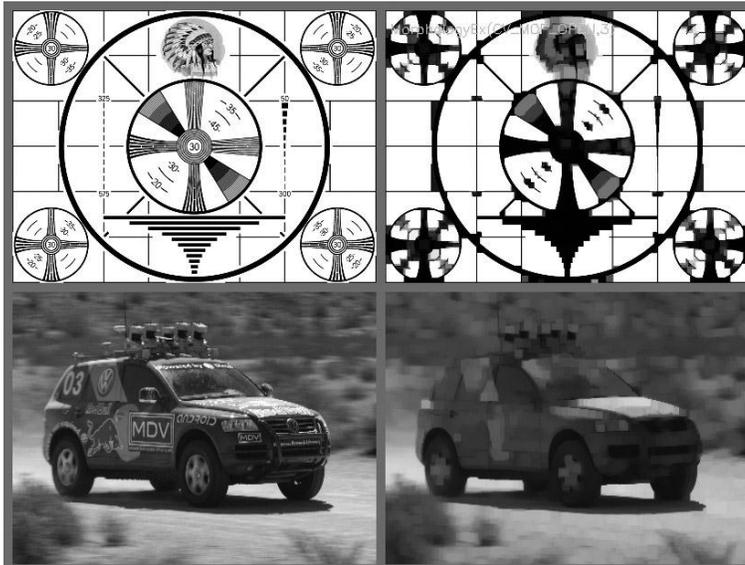
El efecto producido por estas dos operaciones en una imagen se ilustra en las Figuras 8 y 9.

Figura 8. Operación apertura



Fuente: BRADSKI, Gary y KAEBLER, Adrian. Learning OpenCV. Computer Vision with the OpenCV Library. USA: O'REILLY, 2008. p. 122.

Figura 9. Operación cierre



Fuente: BRADSKI, Gary y KAEBLER, Adrian. Learning OpenCV. Computer Vision with the OpenCV Library. USA: O'REILLY, 2008. p. 123.

1.2. ANALISIS: SEGMENTACION Y EXTRACCION DE CARACTERISTICAS

Uno de los procesos más críticos dentro del procesamiento de imágenes es la extracción de regiones de interés o segmentación. Cada imagen está compuesta por varios objetos y estos poseen características que pueden ser medidas y cuantificadas.

1.2.1 Segmentación. Según Fu¹⁴, la segmentación está basada en dos principios fundamentales: discontinuidad y similitud. El primero está enfocado a bordes y el segundo a regiones. Sin embargo, en la práctica la estrategia más adecuada puede ser variante y muy probablemente se comenzará con una y posteriormente

¹⁴ FU, K. S. Syntactic Pattern Recognition, Citado por PAJARES M, Gonzalo y DE LA CRUZ G, Jesús M. Op. Cit., p. 8.

se pasará a la otra. Además, en algunas ocasiones se necesita mejorar la calidad de la imagen original para posteriormente extraer la información adecuadamente.

Según Acharya¹⁵, algunas de las propiedades dentro del objeto que permiten realizar la segmentación adecuadamente son: niveles de gris, contraste, valores espectrales o propiedades de textura.

La segmentación es un procedimiento muy complejo y aun no existe una solución final. Se necesita de una continua investigación que permita día tras día mejorar las técnicas para resolver este problema. Debido a su gran importancia en el procesamiento de imágenes es clave obtener excelentes resultados en el proceso de segmentación y de esta manera poder continuar con los demás procesos.

A continuación se explicarán algunas de las técnicas de segmentación más importantes para la realización de este proyecto.

1.2.1.1 Segmentación basada en umbralización. Es una de las técnicas de segmentación empleadas en aplicaciones de tipo industrial. Es utilizada cuando existe una diferencia clara entre los objetos a extraer y el fondo de la imagen.

El principio fundamental que se utiliza es el de similitud. Para lograr exitosamente esta segmentación es necesario que la imagen posea un fondo uniforme y los objetos sean semejantes.

Al aplicar un umbral a los niveles de gris en la imagen, los píxeles que corresponden al objeto quedarán etiquetados con el número "1", mientras que los

¹⁵ACHARYA, Tinku y RAY, Ajoy K. Image Processing. Principles and Applications. USA: Wiley-Interscience, 2005. p. 131.

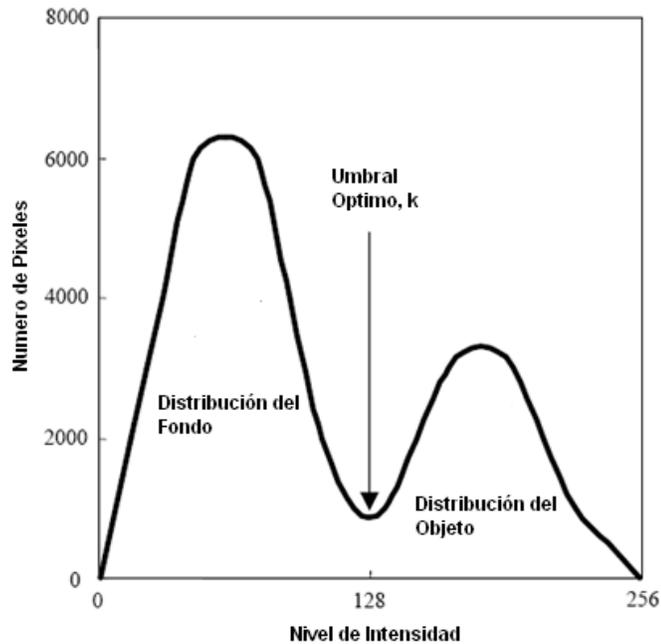
píxeles correspondientes al fondo serán etiquetados con “0”. De forma matemática se puede expresar de la siguiente manera:

$$U(x,y) = \begin{cases} 1 & \text{si } f(x,y) > T \\ 0 & \text{si } f(x,y) \leq T \end{cases} \quad (10)$$

Donde $f(x,y)$ es la función que retorna el nivel de gris del píxel (x,y) y $U(x,y)$ será la imagen binarizada con un umbral T .

1.2.1.2 Segmentación mediante histograma. Como anteriormente se había mencionado el histograma de la imagen representa la frecuencia relativa de ocurrencias de los valores de gris en la imagen. Por lo tanto es posible aplicar el concepto de umbralización al histograma y de esta manera determinar el umbral óptimo que separa cada uno de los objetos dentro de la imagen. Suponiendo que un histograma posee dos picos y un valle entonces el umbral óptimo será el valle que separa las dos distribuciones (Figura 10). Para obtener buenos resultados es necesario tener una iluminación relativamente uniforme.

Figura 10. Histograma de dos distribuciones y su umbral óptimo



Fuente: Autor.

Es posible aplicar esta técnica a multiplex umbrales, pero a medida que el número de umbrales incrementa los resultados son menos fiables. Para identificar el umbral óptimo existen varias estrategias, entre ellas están el método de Otsu.

- **Método de Otsu.** Suponiendo que se obtuvo un histograma bimodal, esto quiere decir que está formado por la suma de dos distribuciones normales o gaussianas y que cada una de ellas se aproxima a uno de los lóbulos. Según lo planteado por Otsu¹⁶, a medida que las gaussianas se asemejan al histograma real, las desviaciones estándar deben disminuir y como consecuencia de ellos

¹⁶ OTSU, Nobuyuki. A threshold selection method from grey-level histograms. En: IEEE Transaction Systems man, Cybernetics. Vol. 8, No. 1, (ene. 1979); p. 62-66.

se debe elegir aquel umbral que minimice la suma de las varianzas de los dos lóbulos del histograma.

Los píxeles de una imagen pueden ser representados por el conjunto de niveles de gris $[1,2,\dots, L]$ donde L es el máximo nivel de intensidad. De la misma manera el número de píxeles en el nivel i puede ser denotado por n_i y N será la suma total de píxeles en la imagen. Los niveles de gris en el histograma son normalizados y considerados como una distribución de probabilidad P_i .

$$P_i = \frac{n_i}{N} \quad (11)$$

Asumiendo que el fondo y el objeto pertenecen a dos clases diferentes C_0 y C_1 . Y que el umbral que las separa es k , las probabilidades de ocurrencia en cada clase serán:

$$\omega_0 = \sum_{i=1}^k P_i \quad y \quad \omega_1 = \sum_{i=k+1}^L P_i \quad (12)$$

Y las medias y varianzas asociadas son:

$$\mu_0 = \sum_{i=1}^k \frac{i * P_i}{\omega_0} \quad y \quad \mu_1 = \sum_{i=k+1}^L \frac{i * P_i}{\omega_1} \quad (13)$$

$$\sigma_0^2 = \sum_{i=1}^k (i - \mu_0)^2 * \frac{P_i}{\omega_0} \quad y \quad \sigma_1^2 = \sum_{i=k+1}^L (i - \mu_1)^2 * \frac{P_i}{\omega_1} \quad (14)$$

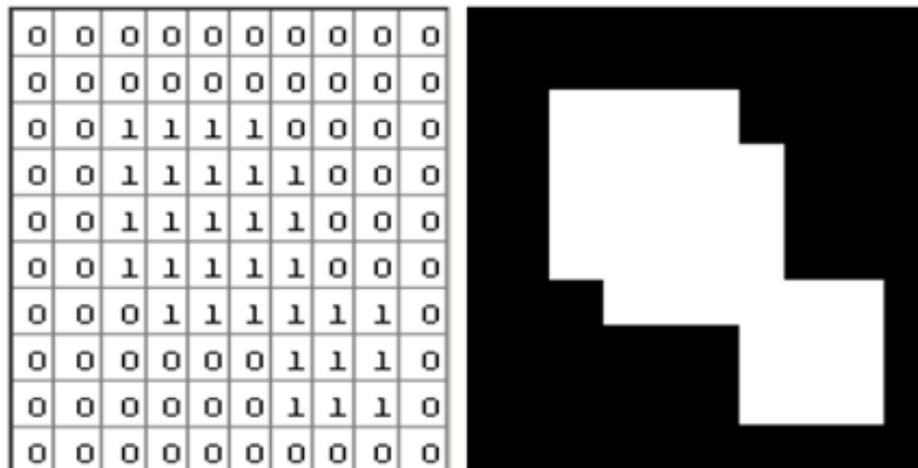
Obteniendo finalmente la varianza ponderada,

$$\sigma_w^2 = \omega_0 * \sigma_0^2 + \omega_1 * \sigma_1^2 \quad (15)$$

De esta manera, el método de Otsu determina el umbral k correspondiente al nivel de gris que proporcione la mínima varianza ponderada entre las dos clases.

1.2.1.3 Binarización de imágenes. Una imagen puede ser binarizada mediante un procedimiento de umbralización. Al ser umbralizada la imagen, los píxeles en la nueva imagen solo pueden tener valores lógicos “0” y “1”. Esta nueva imagen se puede representar mediante un arreglo bidimensional de puntos. A esta nueva imagen se le conoce como imagen binaria. En algunas imágenes el “1” lógico puede representar el objeto y el “0” lógico el fondo mientras que en otras ocasiones puede ser lo contrario (Figura 11).

Figura 11. Representación de una imagen binaria



Fuente: Operaciones Morfológicas en Imágenes Binarias, Universidad Nacional de Quilmes – Ing. en Automatización y Control Industrial, 2005, p. 1-3.

1.2.2 Extracción de características. Las características son aquellos atributos de un objeto que manifiestan cualidades del mismo. Una de las características más importantes es *el color*, sin embargo existen otras como: la textura, el tamaño y la forma, que son igualmente importantes. Existen muchos tipos de características y cada una de ellas debe ser tratada de manera específica con alguna técnica de medición. Estas técnicas son conocidas como *técnicas de extracción de características*.

1.2.2.1 Extracción de características mediante el color. El color es una de las características visuales más empleadas en la descripción de una imagen. Las imágenes caracterizadas por su color se destacan por su robustez, eficacia, bajo requerimiento de almacenamiento y son computacionalmente simples. El color en una imagen es representado mediante un modelo de color, a su vez cada componente del modelo puede ser representada a través de un histograma.

Los descriptores del color en las imágenes pueden ser globales o locales y consisten en una serie de histogramas y colores representados por momentos de color y vectores de coherencia ó correlogramas.

Los momentos de color son medidas que pueden ser usadas para diferenciar imágenes basándose en sus características de color. Una vez calculados, esos momentos proveen una medida de similitud entre las imágenes.

El fundamento de los momentos de color radica en el supuesto de que la distribución del color es una imagen se puede interpretar como una distribución de probabilidad. Estas distribuciones se caracterizan por una serie de momentos únicos. Por lo tanto, se deduce que si el color de una imagen sigue una distribución de probabilidad específica, los momentos de esa distribución pueden

ser utilizados como características para identificar en que color está basada la imagen.

Según Stricker y Orengo¹⁷, existen tres momentos centrales en la distribución del color en una imagen: la media correspondiente al primer momento, la desviación que corresponde al segundo momento y la asimetría al tercer momento.

1.3. APLICACION: RECONOCIMIENTO DE PATRONES EN IMÁGENES

El reconocimiento de patrones es la disciplina cuyo objetivo es la clasificación de objetos dentro de un número de categorías o clases. Estos objetos pueden ser imágenes o formas de onda de señales. Cuando se hace referencia a esos objetos se utiliza el término genérico *patrones*. En el campo de la visión artificial el reconocimiento de patrones es muy importante ya que permite al sistema de visión clasificar las diversas características que se pueden extraer de la imagen y ponerlas en una clase específica.

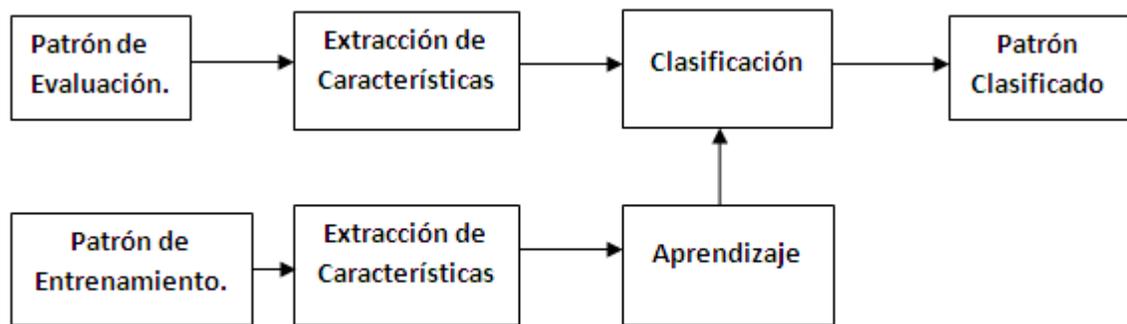
Existen diferentes técnicas usadas en el reconocimiento de patrones. Las más importantes a través de la historia han sido las técnicas estadísticas y sintácticas. Sin embargo hoy día han aparecido nuevas técnicas tales como las redes neuronales que proporcionan una nueva perspectiva (Pajares¹⁸). No obstante, para la realización de este proyecto solo se describirán algunas de las técnicas de clasificación estadística.

¹⁷ STRICKER, M. y ORENGO, M. Similarity of color images. En: SPIE Conference on Storage and Retrieval for Image and Video Databases III. Vol. 2420, (feb. 1995); p. 381-392.

¹⁸ PAJARES M, Gonzalo y DE LA CRUZ G, Jesús M. Op. Cit., p. 353.

1.3.1 Técnicas de clasificación estadística. Estas técnicas clasifican un patrón desconocido en base a principios estadísticos. Un clasificador estadístico opera de dos formas: una en modo aprendizaje (entrenamiento) y la otra en modo clasificación (evaluación). La primera encuentra las características apropiadas que representan los patrones de entrada y entrena el clasificador. Una vez entrenado el clasificador, comienza a operar la segunda parte asignando los patrones de entrada en alguna de las clases definidas por el entrenador. La Figura 12 muestra el diagrama de bloques de un clasificador estadístico.

Figura 12. Diagrama de bloques de un clasificador estadístico



Fuente: Autor.

Según Acharya y Ray¹⁹, las técnicas de clasificación estadística pueden ser catalogadas en dos tipos:

1. Aprendizaje supervisado.
2. Aprendizaje no-supervisado.

¹⁹ ACHARYA, Tinku y RAY, Ajoy K. Op. cit., p. 158

El aprendizaje supervisado se utiliza para estimar una relación desconocida (entrada-salida) a partir de clases ya conocidas. El aprendizaje no-supervisado implica que el número de clases es desconocido con antelación.

A su vez, los algoritmos para la clasificación supervisada pueden ser clasificados en:

- ❖ Paramétricos.
- ❖ No-paramétricos.

En la clasificación supervisada paramétrica, el clasificador es entrenado con un extenso número de *muestras patrón etiquetadas* y los parámetros estadísticos de cada clase son conocidos (media, varianza, entre otros).

El término “muestras patrón etiquetadas” se refiere al conjunto de patrones cuyo número de clases es conocido con anterioridad.

El clasificador de mínima distancia y el clasificador de mínima probabilidad son algoritmos supervisados utilizados con frecuencia.

Por otra parte, cuando los parámetros estadísticos de cada clase no son tomados en consideración, las técnicas de clasificación supervisadas no-paramétricas son las más adecuadas. Algunas de estas técnicas son: K-nearest neighbor, la ventana de Parzen, entre otras.

En el caso de la clasificación no-supervisada las muestras patrón etiquetadas no están disponibles. Por lo tanto es necesario organizar los patrones dentro de un grupo o *clusters* los cuales permitirán encontrar similitudes y diferencias alrededor de los patrones y proveer conclusiones útiles a cerca de ellos.

1.3.1.1 Agrupamiento mediante Clusters. El agrupamiento es uno de las actividades mentales más primitivas de los seres humanos. La información recibida diariamente tiende a ser categorizada dentro de *clusters*.

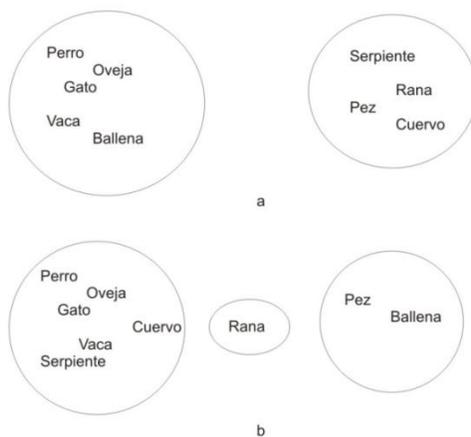
Para organizar un determinado número de patrones dentro de algún cluster será necesario definir un criterio de agrupamiento. Por ejemplo: considerando los siguientes animales; perro, oveja, gato, cuervo, serpiente, pez, rana, vaca, ballena. Agruparlos bajo el criterio de agrupación; (a) forma cómo nacen sus crías y (b) el entorno donde viven.

(a) El perro, oveja, gato, ballena y vaca son mamíferos. El cuervo, serpiente, rana y pez son ovíparos.

(b) El perro, oveja, gato, vaca, serpiente y cuervo son animales terrestres. La ballena y el pez son animales acuáticos. Y la rana es un animal anfibio.

La Figura 13 muestra los diferentes resultados del agrupamiento según los criterios dados.

Figura 13. Resultados del agrupamiento según los criterios (a) forma cómo hacen sus crías y (b) el entorno donde viven.



Fuente: Autor.

El ejemplo anterior muestra que el proceso de asignar objetos a *clusters* puede arrojar diferentes resultados dependiendo del criterio utilizado. De igual manera que el aprendizaje supervisado los patrones deben ser representados en términos de sus características mediante vectores.

Los pasos básicos que se deben seguir para desarrollar una tarea de agrupamiento son los siguientes:

- ❖ Selección de características.
- ❖ Medida de proximidad.
- ❖ Criterio de agrupamiento.
- ❖ Algoritmos de agrupamiento.
- ❖ Validación de resultados.
- ❖ Interpretación de resultados.

La manera como se eligen las características, la medida de proximidad, el criterio de agrupamiento y los algoritmos de agrupamiento puede conducir a resultados totalmente diferentes. A esto se le llama subjetividad.

- **Selección de Características.** Las características deben ser seleccionadas apropiadamente, así como recopilar tanta información como sea posible. Esta información debe ser concerniente a la tarea que se está realizando, siendo la mínima redundancia en la información alrededor de las características uno de los objetivos principales.
- **Medida de proximidad.** Este tipo de medición cuantifica cuan “similar” o “distinto” son dos vectores de características. Es natural asegurar que todas las características seleccionadas contribuyen equitativamente al cálculo de la

medida de proximidad y no hay características que dominen a otras. Por lo tanto deberá ser tomado en cuenta durante el pre-procesamiento.

- **Criterio de agrupamiento.** Este criterio depende de la interpretación entregada por el experto, basado en el tipo de clusters estos son esperados a partir de un grupo de datos dado.
- **Algoritmos de agrupamiento.** Una vez adoptada una medida de proximidad y un criterio de agrupamiento, se debe elegir un esquema de algoritmo adecuado que determinará la estructura de agrupación del conjunto de datos.
- **Validación de resultados.** Una vez se hayan obtenido los resultados provenientes del algoritmo de agrupamiento, se verifica su exactitud.
- **Interpretación de resultados.** En muchos casos, el experto en el campo de aplicación debe integrar los resultados del agrupamiento con otra evidencia experimental y analizar los resultados con el fin de establecer una conclusión correcta.

Los algoritmos de agrupamiento se pueden clasificar en: secuenciales, jerárquicos, basados en la optimización de una función de costo, genéticos, métodos de relajación estocástica y algoritmos basados en transformaciones morfológicas. El algoritmo de agrupamiento empleado en este trabajo es del tipo secuencial el cual se describirá a continuación.

- **Algoritmos secuenciales para el agrupamiento de datos.** Estos algoritmos producen un agrupamiento simple. Estos métodos son sencillos y rápidos. En muchos de ellos, todos los vectores de características son presentados al algoritmo solo una vez o muy pocas veces. El resultado final es usualmente dependiente del orden en el cual el vector es presentado al algoritmo. Estos esquemas tienden a producir formas hiper-esféricas o hiper-elipsoidales en los clusters, dependiendo de la distancia métrica utilizada. Dentro de los algoritmos más utilizados están: algoritmo secuencial básico (BSAS) y una modificación del algoritmo secuencial básico (MBSAS).

➤ **Algoritmo secuencial básico (BSAS).** Primero se debe considerar el caso donde todos los vectores son presentados una sola vez al algoritmo. En este caso el número de clusters es desconocido con anterioridad, por lo que son creados en el desarrollo del algoritmo. La idea básica del algoritmo es la siguiente: a medida que cada vector es considerado, este es asignado a un cluster ya existente o a un cluster creado recientemente, dependiendo de su distancia a los clusters ya formados. Supóngase que m es el número de clusters que el algoritmo ha creado hasta ahora. Entonces el esquema del algoritmo podría ser indicado de la siguiente manera:

- $m = 1$
- $C_m = \{x_1\}$
- For $i = 2$ hasta N
 - Encontrar $C_k: d(x_i, C_k) = \min_{1 \leq j \leq m} d(x_i, C_j)$.
 - If $(d(x_i, C_k) > \theta) \& (m < q)$ entonces
 - $m = m + 1$
 - $C_m = \{x_i\}$
 - sino

- $C_k = C_k \cup \{x_i\}$
- Donde sea necesario, actualizar los representantes²⁰
 - Fin del {If}
- Fin del {For}

Donde C_m es el vector que representa los clusters, N es el tamaño del vector de datos, d es la distancia entre un cluster y un dato, C_k es el cluster al cual la distancia d es la más corta, θ es el umbral que representa una medida de proximidad entre las muestras, y q es el número máximo de clusters que el algoritmo puede formar.

Diferentes opciones de $d(x, C)$ conducen a diferentes algoritmos. Cuando C es representado por un simple vector, $d(x, C)$ se convierte en

$$d(x, C) = d(x, m_C) \quad (16)$$

Donde m_C es el representante de C . En el caso en el cual el vector de medias es usado como un representante, la actualización puede tener lugar de forma interactiva, así

$$m_{Ck}^{new} = \frac{(n_{Ck}^{new} - 1)m_{Ck}^{old} + x}{n_{Ck}^{new}} \quad (17)$$

Donde n_{Ck}^{new} es la cardinalidad de C_k después de la asignación de x a este y $m_{Ck}^{new} (m_{Ck}^{old})$ es el representante de C_k después de la asignación de x a este.

²⁰ Esta línea es usada en el caso donde cada cluster es representado por un simple vector.

Otro factor importante que afecta los resultados del algoritmo de agrupamiento es la elección del umbral θ . Este valor afecta el número de clusters formados por el algoritmo. Si este valor se hace pequeño generará más clusters y si por el contrario este valor se hace grande generará menos clusters.

- **Una modificación del BSAS.** A esta modificación se le conoce como MBSAS el cual es un mejoramiento del BSAS explicado anteriormente. En este los vectores de X tienen que ser presentados dos veces. El esquema del algoritmo consiste en dos fases. La primera fase consiste en la determinación de los clusters, a través de la asignación de algunos de los vectores de X a estos. Durante la segunda fase los vectores sin asignar son presentados por una segunda vez al algoritmo y son asignados al cluster apropiado. El MBSAS puede ser escrito de la siguiente manera:

Determinación de clusters

- $m = 1$
- $C_m = \{x_1\}$
- For $i = 2$ hasta N
 - Encontrar $C_k: d(x_i, C_k) = \min_{1 \leq j \leq m} d(x_i, C_j)$.
 - If $(d(x_i, C_k) > \theta) \& (m < q)$ entonces
 - $m = m + 1$
 - $C_m = \{x_i\}$
 - sino
 - $C_k = C_k \cup \{x_i\}$
 - Donde sea necesario, actualizar los representantes²¹
 - Fin del {If}

²¹ Esta línea es usada en el caso donde cada cluster es representado por un simple vector.

- *Fin del {For}*
Clasificación de patrones
- *For i = 2 hasta N*
 - *If x_i aun no ha sido asignado a un cluster, entonces*
 - *Encontrar $C_k: d(x_i, C_k) = \min_{1 \leq j \leq m} d(x_i, C_j)$*
 - *$C_k = C_k \cup \{x_i\}$*
 - *Donde sea necesario, actualizar los representantes*
 - *Fin del {If}*
- *Fin del {For}*

1.3.1.2 Clasificador de mínima distancia. Las funciones de distancia son usadas a manera de similitud o disimilitud entre dos clases de patrones. El algoritmo clasificador de mínima distancia es computacionalmente simple y comúnmente usado. El clasificador encuentra la distancia evaluando los datos de entrada de todas las medias de los vectores que representan las clases objetivo. Los patrones desconocidos son asignados a la clase que posee la distancia más corta con respecto a las otras.

Suponiendo un problema de N clases. Si la clase C_i contiene solamente un patrón prototipo llamado μ_i que fue seleccionado apropiadamente mediante mediciones y la distancia de un patrón desconocido $X = [x_1, x_2, \dots, x_n]$ de la clase patrón C_i es $d(X, \mu_i)$, entonces el patrón x pertenece a la clase C_k si

$$D_k = \min_i \{d(X, \mu_i)\} \quad (18)$$

Para todo $i = 1, 2, \dots, N$. La función distancia d debe satisfacer tres propiedades: reflexividad, simetría, ley triangular de la desigualdad.

1.4. TECNICAS DE VISION ARTIFICIAL APLICADAS AL CONTROL DE CALIDAD DE PRODUCTOS AGRÍCOLAS

Según Du y Sun²², las técnicas de visión artificial han sido aplicadas cada vez más en el control de calidad de los alimentos en los últimos años. En la industria alimenticia, algunos de los controles de calidad son realizados manualmente por inspectores entrenados siendo estos tediosos, laboriosos, costosos e inherentemente poco confiables debido a su naturaleza subjetiva.

El incremento de la demanda de objetividad, consistencia y eficiencia han hecho necesaria la introducción de las técnicas de visión artificial en el control de calidad de alimentos.

Nuevamente Du y Sun²³, comentan que recientemente la visión artificial se ha desarrollado tan rápidamente, que puede caracterizar cuantitativamente tamaños complejos, formas, color y textura propiedades de los alimentos. La visión artificial juega cada vez más un rol importante en el control de calidad. Debido a que mantiene su precisión y consistencia al eliminar la subjetividad de la inspección manual. También ofrecen flexibilidad en las aplicaciones y pueden ser sustitutos razonables del proceso de toma de decisiones que permite la visión humana.

Como dice Du y Sun²⁴, el análisis mediante técnicas de visión artificial generalmente consiste de cinco pasos como lo muestra la Figura 14. (1) Proceso de adquisición de imagen para convertirla a un formato digital. (2) Operaciones de pre-procesamiento mejorando la imagen con las mismas dimensiones de la imagen original. (3) Operaciones de segmentación de la imagen partiendo una imagen digital en regiones separadas y no traslapadas. (4) Operaciones de

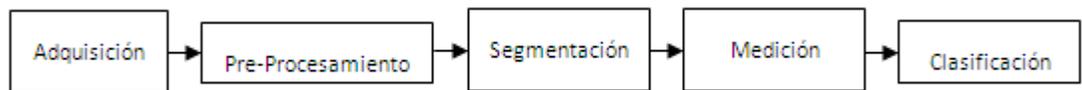
²² DU, Cheng-Jin y Sun, Da-Wen. Recent developments in the applications of image processing techniques for food quality evaluation. *En: Trends in Food Science & Technology*. Mayo, 2004, vol. 15, no. 5, p. 230.

²³ *Ibid.*, p. 230.

²⁴ *Ibid.*, p. 231.

medición de objetos para medir y extraer las características de estos, tales como tamaño, forma, color y textura. (5) Procedimientos de clasificación para identificar objetos y clasificarlos en diferentes grupos.

Figura 14. Pasos generalmente utilizados en un sistema de visión artificial



Fuente: Autor.

1.4.1 Adquisición de la imagen. La iluminación es un prerequisite importante en la adquisición de una imagen. La calidad de la imagen capturada puede ser bastante afectada por las condiciones de iluminación. Una imagen de alta calidad puede ayudar a reducir el tiempo y la complejidad de los siguientes pasos, ya que pueden disminuir el costo de un sistema de un sistema de visión artificial. Para cada una de las diferentes aplicaciones existe una estrategia de iluminación diferente.

Según los estudios de Du y Sun²⁵, varios sensores tales como cámaras CCD (*Charge Couple Device* – en inglés), ultrasonido, imágenes por resonancia magnética (MRI), tomografía computarizada (TC) y tomografía eléctrica son usados ampliamente para obtener imágenes de productos agrícolas.

1.4.2 Pre-procesamiento de la imagen. Las imágenes capturas en el paso anterior son permisibles a varios tipo de ruido. Este ruido puede degradar la

²⁵ DU, Cheng-Jin y Sun, Da-Wen, Op. cit, p. 231.

calidad de una imagen y subsecuentemente no proveerá la información adecuada para las siguientes etapas del sistema. Con el fin de mejorar la calidad de una imagen, es necesario realizar operaciones para remover o disminuir las degradaciones sufridas durante el proceso de adquisición de las mismas.

Para el pre-procesamiento de imágenes orientado al control de calidad de alimentos pueden utilizarse dos diferentes técnicas: pre-procesamiento píxel a píxel (individual) y pre-procesamiento local o basado en múltiples puntos (vecindad).

1.4.3 Segmentación de la imagen. La Segmentación de imágenes inicia separando una imagen en los objetos que la componen, que es una ardua tarea porque la imagen posee bastante información visual. Según Du y Sun²⁶, las técnicas de segmentación de imagen desarrolladas para el control de calidad de alimentos pueden ser divididas dentro de cuatro diferentes enfoques: basada en umbralización, basada en región, basada en gradiente y basada en clasificación.

Observando la literatura actual sobre segmentación de imágenes estas indican que las técnicas más utilizadas en aplicaciones industriales son; segmentación basada en umbralización y la basada en región. Las basadas en gradiente y en clasificación son usadas con menos frecuencia.

1.4.4 Medición de objetos en la imagen. Una vez se haya segmentado satisfactoriamente la imagen. Los objetos en ella pueden ser descritos y representados para su posterior análisis midiendo las características individuales de cada uno.

²⁶ DU, Cheng-Jin y Sun, Da-Wen, Op. cit, p. 235.

Como lo expresa Du y Sun²⁷ en su artículo, en general, un objeto segmentado puede ser representado en función de sus rasgos característicos externos o internos. Muchos rasgos pueden ser usados para describir un objeto, que son comparados con la información de objetos conocidos para clasificar un objeto dentro de alguna de las categorías. Generalmente, estos rasgos son los más sencillos de medir y contribuyen sustancialmente hacia la clasificación de los más adecuados. Las mediciones que pueden ser realizadas en los objetos de las imágenes para la evaluación de la calidad de los alimentos pueden ser agrupadas en cuatro clases: tamaño, forma, color y textura.

1.4.5 Clasificación. Se encarga de identificar los objetos por sus cualidades dentro de uno de los conjuntos finitos de clases, que envuelve los rasgos de la medida comparada de un objeto con aquellos de un objeto conocido o de otros criterios conocidos y determinar si el nuevo objeto pertenece a una categoría particular de objetos. Una amplia variedad de orientaciones han sido adoptadas para esta tarea dentro del control de calidad de los alimentos. Estadística, lógica difusa y redes neuronales, son tres métodos importantes de clasificación. Ellos, tienen un objetivo común, que es, simular la conducta humana de toma de decisiones, y tienen la ventaja de ser coherentes y claros.

1.5. LIBRERIAS OPENCV

OPENCV (*Open Source Computer Vision library* – en inglés) es una de las librerías de código abierto desarrolladas por Intel. Estas librerías proporcionan un alto nivel de funciones para el procesamiento de imágenes. Estas librerías permiten a los programadores crear robustas aplicaciones para visión artificial. Estas facilitan en gran parte el aprendizaje e implementación de distintas técnicas

²⁷ DU, Cheng-Jin y Sun, Da-Wen, Op. cit, p. 238.

de visión por computador tanto a los docentes como para los investigadores. Las librerías son multiplataforma, y puede ser usada en Mac OS X, Windows y Linux.

Las librerías OpenCV poseen grandes ventajas con respecto a otras herramientas para realizar procesamiento de imágenes algunas de ellas son: su rapidez por ser una herramienta enfocada para aplicaciones en tiempo real, su amplia variedad de funciones, soporte a nivel mundial por ser (opensource) software libre, y muchas otras más.

Tal como lo muestra Bradski y Kaebler²⁸ en su libro, OpenCV nos permite entre muchas otras cosas: operaciones básicas para el procesamiento de imágenes, análisis estructural, análisis en movimiento, reconocimiento del modelo, reconstrucción 3D, calibración de la cámara, interfaz grafica y adquisición.

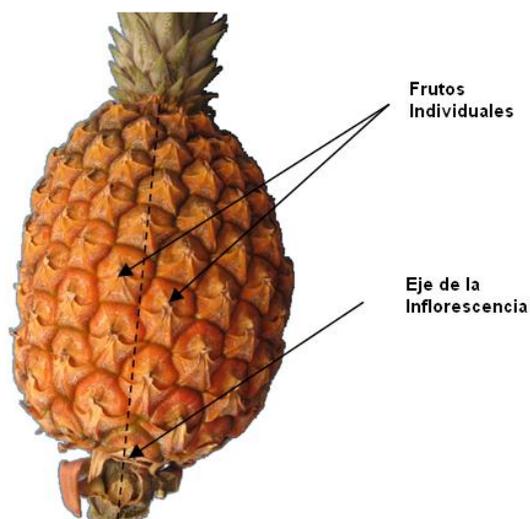
²⁸BRADSKI, Gary y KAEBLER, Adrian. Learning OpenCV. Computer Visión with the OpenCV Library. USA: O'REILLY, 2008, p. 1-5.

2. GENERALIDADES DE LA PIÑA

La piña o “*ananás comosus*” es originaria de Sudamérica específicamente de Brasil por ello su nombre “ananás” que es de origen portugués. Los españoles fueron los que más adelante adoptaron el nombre que comúnmente se le conoce “piña”.

“La piña posee un fruto múltiple denominado sorosis, cuya parte carnosa está constituida por la fusión de los tejidos de los frutos individuales y del eje de la inflorescencia (Figura 15). De cada una de las flores se desarrollan los frutos individuales que aparecen hacia el exterior en forma de escudetes los cuales constituyen la corteza dura y cerosa del fruto (Figura 16).”²⁹

Figura 15. Fruto de la piña



Fuente: Autor.

²⁹ PULIDO, P., et al. Desarrollo del fruto e índices de cosecha de la piña nativa (*Ananás comosus*) c.v. India producida en el piedemonte amazónico. Colombia: Instituto Amazónico de Investigación Científicas SINCHI en cooperación con la Universidad Nacional de Colombia, Universidad de los Andes y Universidad de la Amazonia., 2001. p. 62.

Figura 16. Flor de la piña



Fuente: Autor.

Según el documento de Pulido³⁰, la piña generalmente es propagada mediante colinos basales y axilares (Figura 17), los cuales son sembrados como máximo 20 días después de ser retirados de la planta madre. Sin embargo, se recomienda la utilización de los colinos producidos en la base del fruto (colinos basales), los cuales deberán ser seleccionados de acuerdo a su robustez, tamaño y forma.

Figura 17. Colino basal



Fuente: Autor.

³⁰ PULIDO, P., et al. Desarrollo del fruto e índices de cosecha de la piña nativa (*Ananas comosus*) c.v. India producida en el piedemonte amazónico, Op. Cit. p. 60.

En su documento Pulido³¹ afirma, los mayores productores de piña son Hawái, Brasil, México, Costa Rica, Colombia, entre otros. En Colombia los cultivos se distribuyen principalmente en los departamentos de Santander, Valle del Cauca y, Risaralda, siendo las variedades más cultivadas la Perolera, la Manzana y la Cayena Lisa.

2.1. LA VARIEDAD PEROLERA

Según Carvajal³², esta variedad posee hijos sin espinas, cuando el fruto madura es de color amarillo-naranja, con ojos profundos, corona única y forma cilíndrica cuando pesan alrededor de 2 Kg. La pulpa es amarilla, recomendable para su uso en fresco. Es una variedad muy apetecida por su sabor y calidad. Es la más cultivada y es bastante resistente al transporte. Tiene contenido medio de fibra y forma cónica (Figura 18).

³¹ PULIDO, P., et al. Desarrollo del fruto e índices de cosecha de la piña nativa (Ananás comosus) c.v. India producida en el piedemonte amazónico, Op. Cit. p. 60.

³² CARVAJAL, L. M. Producción, transformación y comercialización de pulpas de frutas tropicales [online]. Medellín (Antioquia): Universidad de Antioquia. Facultad de química farmacéutica, 2000. Available from internet: <<http://huitoto.udea.edu.co/FrutasTropicales/pina.html>>

Figura 18. Piña de la variedad Perolera



Fuente: Autor.

2.2. LA VARIEDAD MANZANA

“Es una mutación de la variedad Perolera, seleccionada y multiplicada de cultivos de Cerritos, (Risaralda). Al igual que la Perolera, sus hojas no presentan espinas en los bordes. El fruto es de color rojo intenso cuando madura, de ahí su nombre, tiene ojos menos profundos que la Perolera; presenta un número alto de bulbitos en la corona lo cual dificulta su manejo y mercadeo. Los colinos tanto de la corona como basales, axiales e hijuelos, presentan coloración cobriza, lo que permite diferenciarlos fácilmente de la Perolera. La pulpa de la fruta es de color rosado pálido. Presenta poca resistencia a la manipulación”³³.

³³ CARVAJAL, L. M. Producción, transformación y comercialización de pulpas de frutas tropicales [online].

2.3. LA VARIEDAD CAYENA LISA

“Las hojas tienen los bordes lisos, fruto alargado y cilíndrico con un peso promedio de 2.4 Kg. poco contenido de fibra y alto porcentaje de jugo. Cáscara lisa y pulpa blanco- amarillenta. Su cultivo en Colombia es escaso y limitado para el Valle del Cauca y el Viejo Caldas, donde se cultiva con miras a la exportación y a la agroindustria, principalmente. Sus hojas presentan espinas en la parte superior y algunas en la base. Su fruto es de color amarillo oro cuando está madura y presenta corona sencilla, aún cuando es común encontrar coronas múltiples y fasciadas. Su pulpa es de color amarillo brillante, con un alto contenido de sólidos solubles y de ojos muy profundos. Al igual que la piña Manzana presenta poca resistencia a la manipulación”³⁴.

2.4. CARACTERÍSTICAS FÍSICAS Y QUÍMICAS

Algunas de sus características físicas y químicas más importantes de las tres variedades se pueden observar en la Tabla 1. En ella se puede apreciar que la variedad Perolera es más pesada, sin embargo el porcentaje de pulpa es menor que las demás.

Tabla 1. Características físicas y químicas del fruto de la piña en sus tres variedades

Características	Perolera	Manzana	Cayena Lisa
Peso	2,02 Kg	1,95 Kg	1,97 Kg
Porcentaje de Pulpa	61,89%	67,30%	65,93%
Porcentaje de Corteza	34,05%	29,55%	31,88%
Porcentaje de Jugo	49,60%	52,78%	50,13%
Acidez	0,52%	0,56%	0,58%
Fibra	0,56%	0,51%	0,49%

Fuente: Primer simposio internacional de piñicultura. Memorias. 1999

³⁴ CARVAJAL, L. M. Producción, transformación y comercialización de pulpas de frutas tropicales [online].

Además, como se muestra en la Tabla 2, la composición química de la piña tiene grandes ventajas con respecto a otros frutos, debido a su gran contenido de agua, calcio, fósforo y vitamina C, lo cual la hace apetecible tanto en el mercado regional como el internacional.

Tabla 2. Composición química de la piña

Agua (%)	85,1	Hierro (mg)	0,40
Proteínas (%)	0,1	Tiamina (mg)	0,90
Grasas (%)	13,5	Riboflavina (mg)	0,03
Cenizas (%)	0,1	Niacina (mg)	0,20
Calcio (mg)	21,00	Vitamina C (mg)	12,00
Fósforo (mg)	10,00	Calorías (mg)	51,00

Fuente: HINCAPIE, Gerardo. Manejo Post Cosecha de la Piña. Programa Post Cosecha, convenio SENA-REINO UNIDO. 1993. p. 160.

2.5. CALIDAD DEL FRUTO

En gran parte del país la piña es comercializada como fruto fresco. “No obstante, el fruto presenta potencial para ser utilizado agroindustrialmente en la elaboración de pulpas, néctares y productos deshidratados (osmodeshidratación y secado por convección de aire caliente)”³⁵.

³⁵ PULIDO, P., et al. Desarrollo del fruto e índices de cosecha de la piña nativa (*Ananás comosus*) c.v. India producida en el piedemonte amazónico, Op. Cit. p. 62-63.

Para Arias y Toledo³⁶, la calidad de la piña depende de la sanidad y aspecto del fruto. La fruta no debe presentar daños ocasionados por quemaduras solares, por enfermedades o por insectos.

“El punto en el cual un fruto se considera listo para la cosecha depende de su destino final ya sea para enlatado, exportación o mercado local”³⁷. La fruta para enlatado y mercado local tienen que cosecharse madura mientras que para exportación y comercialización lejos de la región de origen es apropiado etapas anteriores.

Según se desprende del documento de Arias y Toledo³⁸, la madurez se determina por los días después de la floración o por el color de la cáscara que cambia de verde oscuro (Etapa 1) a un verde claro (Etapa 2) y después a un amarillo-naranja (Etapa 3). El cambio de color se inicia en la base perpendicular del fruto y poco a poco se va extendiendo hacia la corona a medida que avanza la maduración, hasta que todo el fruto tiene un color homogéneo como se observa en la Figura 19.

³⁶ ARIAS V., Ciro y TOLEDO H., Julio. Manual de manejo postcosecha de frutas tropicales (Papaya, piña, plátano, cítricos) [online]. Roma (Italia): Organización de las Naciones Unidas para la Agricultura y la alimentación (FAO), 2000. Available from internet: < <http://www.fao.org/inpho/content/documents/vlibrary/ac304s/ac304s00.htm>>

³⁷ Ibid. “índice de madurez de la piña”

³⁸ Ibid. “índice de madurez de la piña”

Figura 19. Cambio de color en la piña durante el almacenamiento



Fuente: PULIDO, P., et al. Desarrollo del fruto e índices de cosecha de la piña nativa (*Ananás comosus*) c.v. India producida en el piedemonte amazónico. Colombia: Instituto Amazónico de Investigación Científicas SINCHI en cooperación con la Universidad Nacional de Colombia, Universidad de los Andes y Universidad de la Amazonia., 2001. p. 68.

Además, en este documento se plantea que, el cambio de color puede ser un buen indicador de la madurez de la fruta. Sin embargo existen dos factores que pueden alterar el color: la influencia de los tratamientos antes de la cosecha con productos que liberan etileno y los lugares donde la diferencia de temperatura entre el día y la noche es pequeña.

“Durante la sobre-maduración el fruto emite un fuerte aroma, tornándose la pulpa cada vez más transparente e iniciándose el proceso de fermentación. El fruto fermentado es inapropiado para el consumo en fresco y solo puede ser utilizado para la obtención de vinagre. Una clasificación en base a la coloración de las brácteas (ojos) del fruto es la siguiente:

M1: Iniciación Coloración.

M2: Pintona

M3: 100% Coloración”³⁹.

³⁹ ARIAS V., Ciro y TOLEDO H., Julio. Op. cit. “índice de madurez de la piña”

El fruto de la piña bajo condiciones de almacenamiento presenta un periodo de vida útil que varía según la variedad del fruto. Sin embargo durante el almacenamiento la piña presenta cambios de color en la corteza. Estos cambios permiten conocer el momento adecuado para su consumo, para su transporte entre otros, dependiendo de las necesidades del cliente.

En Santander, la piña representa el tercer producto agrícola más importante para la región, su fruto se comercializa en casi todo el país y en países vecinos como Venezuela.

La variedad Perolera es la de mayor relevancia para la región ya que es muy apetecida por su sabor y calidad. También es bastante resistente al transporte lo que permite al agricultor tener mayor tranquilidad y confianza al momento de comercializarla fuera de la región.

3. IDENTIFICACIÓN DE LAS ETAPAS DE MADURACIÓN DE LA PIÑA PEROLERA

En este capítulo se describen los pasos que se utilizaron para identificar las etapas de maduración de la piña en su variedad *Perolera*. Inicialmente las imágenes fueron adquiridas mediante una cámara digital en condiciones controladas. Luego, se aplicó a los histogramas de cada una de ellas un filtro “*moving average*” para eliminar ruido proveniente de la adquisición. Seguidamente, se procedió a segmentar la imagen para obtener el área de interés utilizando la componente matiz de la imagen y posteriormente extraer sus características empleando la media de los histogramas de las componentes matiz y saturación, las cuales, fueron utilizadas en los procesos de entrenamiento y clasificación de patrones. El procedimiento descrito anteriormente se muestra en el diagrama de flujo de la Figura 20.

Figura 20. Diagrama de flujo del algoritmo implementado

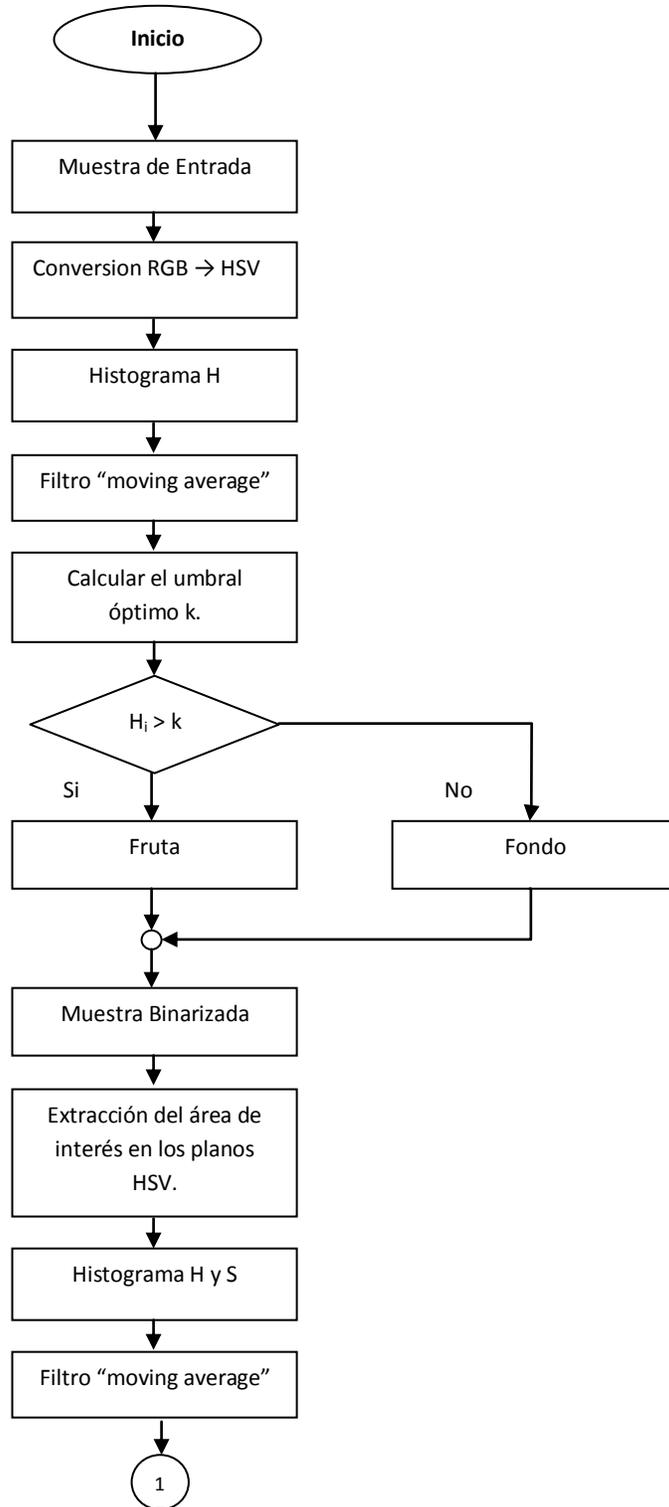
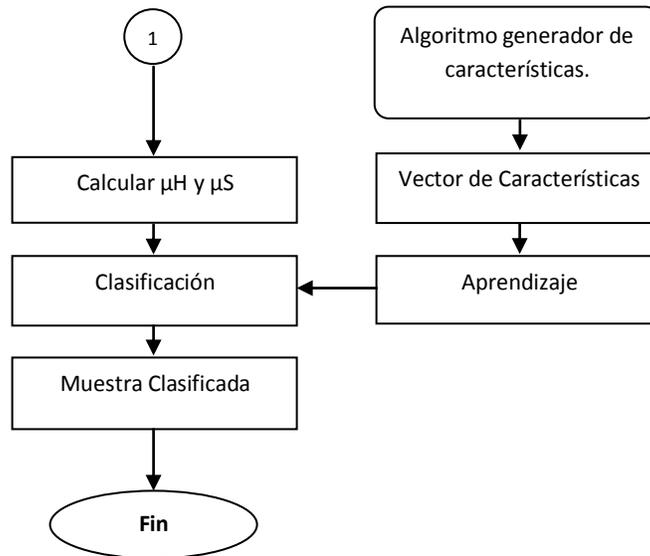


Figura 20. (Continuación).



Fuente: Autor.

3.1. ADQUISICIÓN DE LAS IMÁGENES

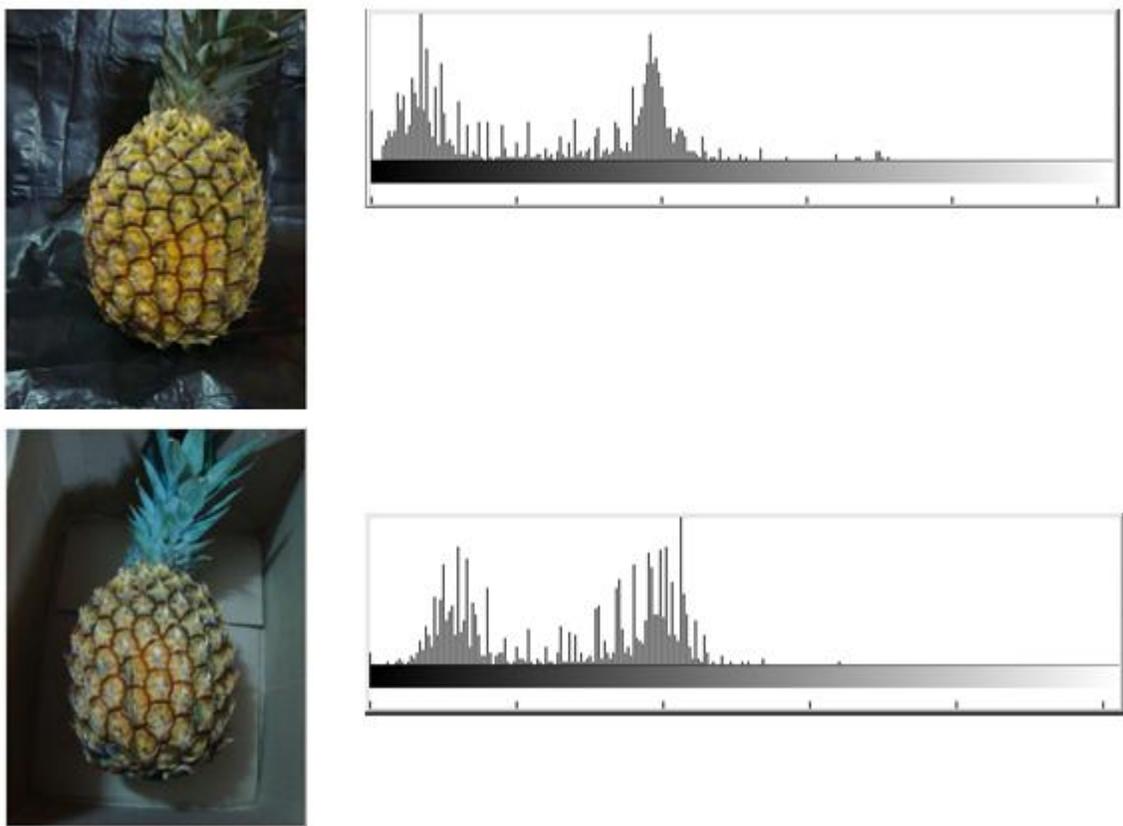
Las imágenes fueron tomadas mediante una cámara fotográfica digital Canon Power Shot A590 con una resolución de 1536x2048 píxeles.

Durante el proyecto se tomaron aproximadamente 1500 fotografías las cuales se les denominaron *muestras*. Inicialmente se desarrolló un algoritmo que permite leer y pre-procesar cada una de las muestras. Básicamente carga la imagen, la convierte del espacio RGB a HSV, extrae el histograma de la componente matiz y grafica su histograma en pantalla.

Como se puede apreciar en la Figura 21, el histograma para dos muestras diferentes generó datos poco entendibles, esto debido a que el fondo no es

homogéneo y a efectos producidos por la dispersión de la luz. Además, dado que el sistema de iluminación estaba formado por un bombillo fluorescente, el ruido inducido por éste no permitía observar los detalles más importantes en el histograma.

Figura 21. Imagen e histograma de la componente matiz para dos muestras diferentes en la primera toma de muestras

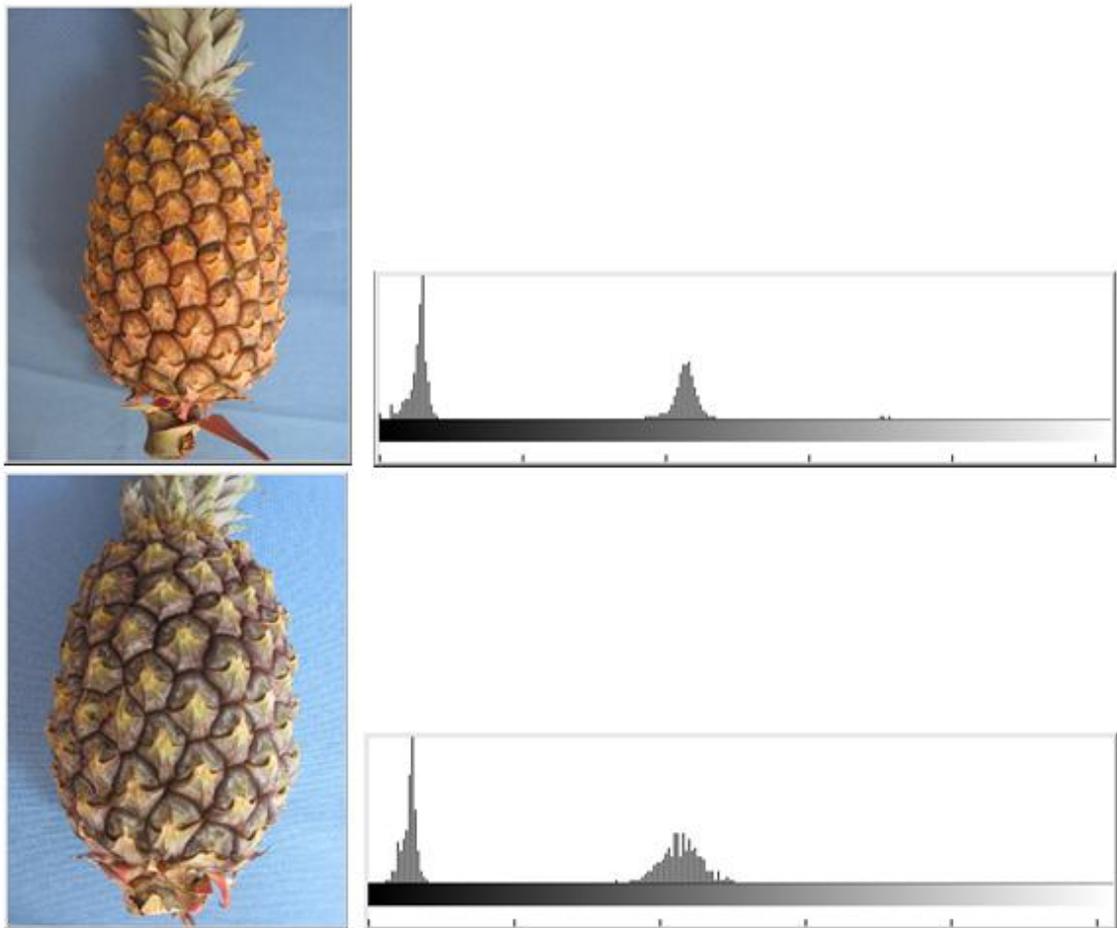


Fuente: Autor.

Debido a los problemas presentados, se decidió realizar una segunda toma de muestras. Para estas muestras se colocó un paño de tela color azul como fondo y se tomaron bajo la incidencia de luz solar. Los resultados de estos cambios se

pueden apreciar en la Figura 22. En ellos se observa una mejor distribución del histograma, donde se diferencia claramente lo que corresponde al fruto y al fondo.

Figura 22. Imagen e histograma de la componente matiz para dos muestras diferentes en la segunda toma de muestras.

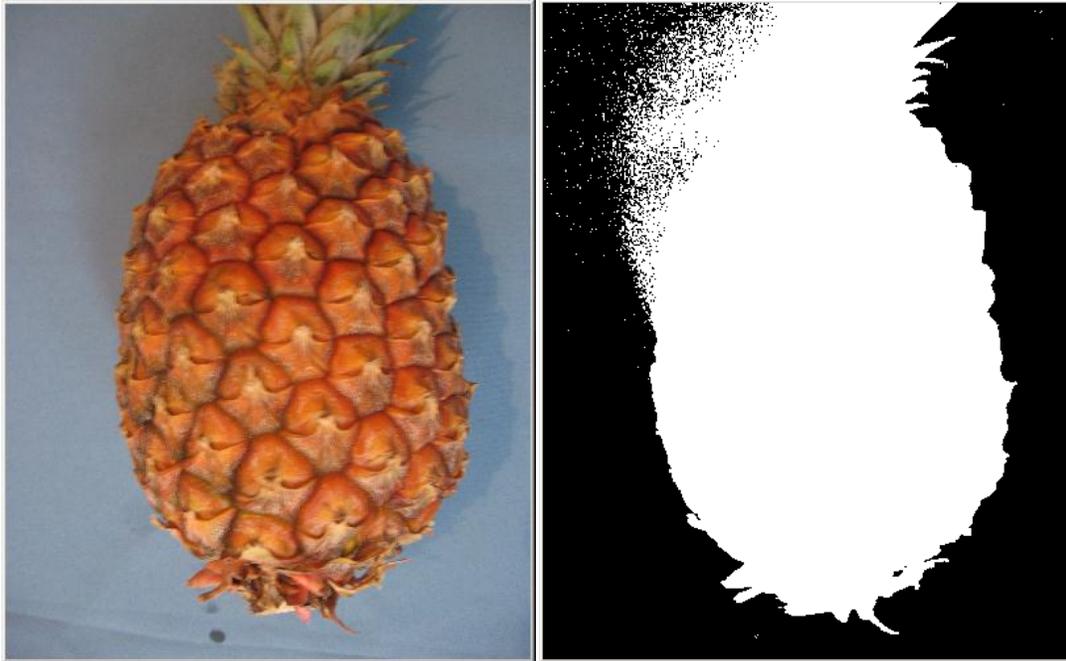


Fuente: Autor.

Sin embargo, en el momento de segmentar algunas imágenes, se observó un fenómeno denominado por algunos autores como “*efecto sombra*”, el cual es

producido por la incidencia de luz en el fruto sumado con el color del fondo (Figura 23).

Figura 23. Efecto sombra sobre el fondo



Fuente: Autor.

Para la tercera toma de muestras se revisaron algunos documentos y se decidió realizar una recámara con condiciones de iluminación homogénea. También se optó por traer 10 piñas cortadas directamente de piñales, ya que las primeras muestras fueron tomadas utilizando piñas compradas en el mercado local y estas estaban tratadas previamente con productos que liberan etileno.

Las nuevas piñas debían tener las mismas condiciones iniciales de maduración y no ser tratadas con productos que liberan etileno, los cuales aceleran el proceso natural de maduración del fruto.

La recámara fue construida con madera y cartón paja. Sus dimensiones son 60x60x60 cm y el interior está pintado de color negro con fondo azul. Una bombilla halógena de color blanco natural fue colocada de manera estratégica en el interior y se hizo una ranura a través de la cual se ajusta el lente de la cámara. Además, se colocó un espejo en la parte posterior de la recámara con el fin de reflejar luz en el área superior de la piña. En la Figura 24 se puede apreciar diferentes vistas de la recámara construida.

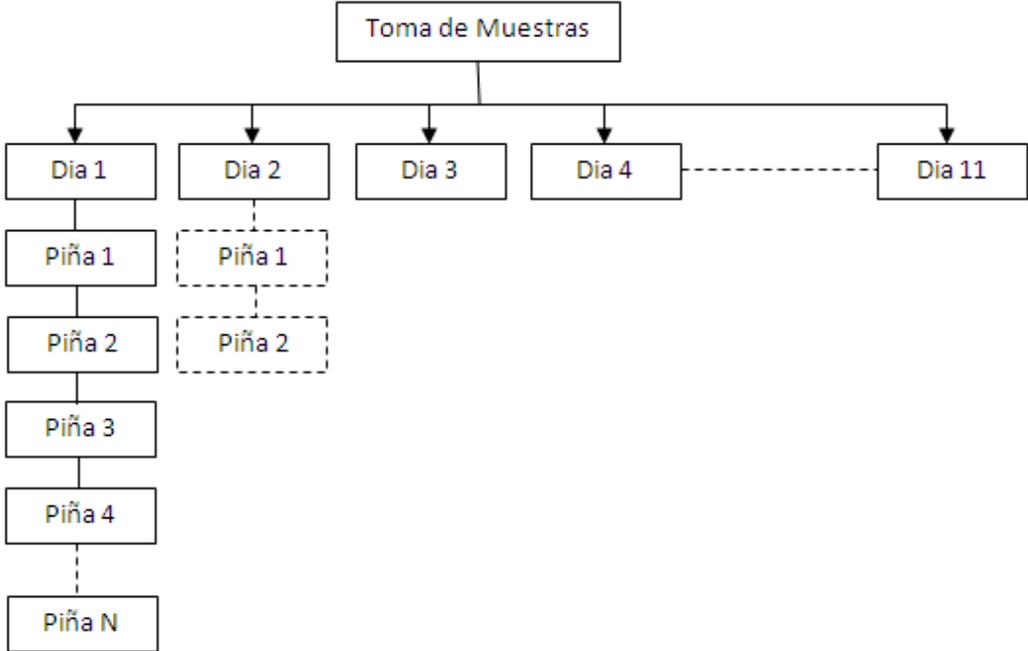
Figura 24. Recámara utilizada para la tercera toma de muestras



Fuente: Autor.

Durante el tiempo en que las piñas fueron madurando, se tomaban muestras diariamente de cada una de ellas. Estas muestras se almacenaban en una base de datos organizada como se muestra en la Figura 25.

Figura 25. Diagrama de la base de datos



Fuente: Autor.

Durante 11 días, las piñas fueron cambiando de color, pasando por cada etapa de maduración tal como se aprecia en Figura 26.

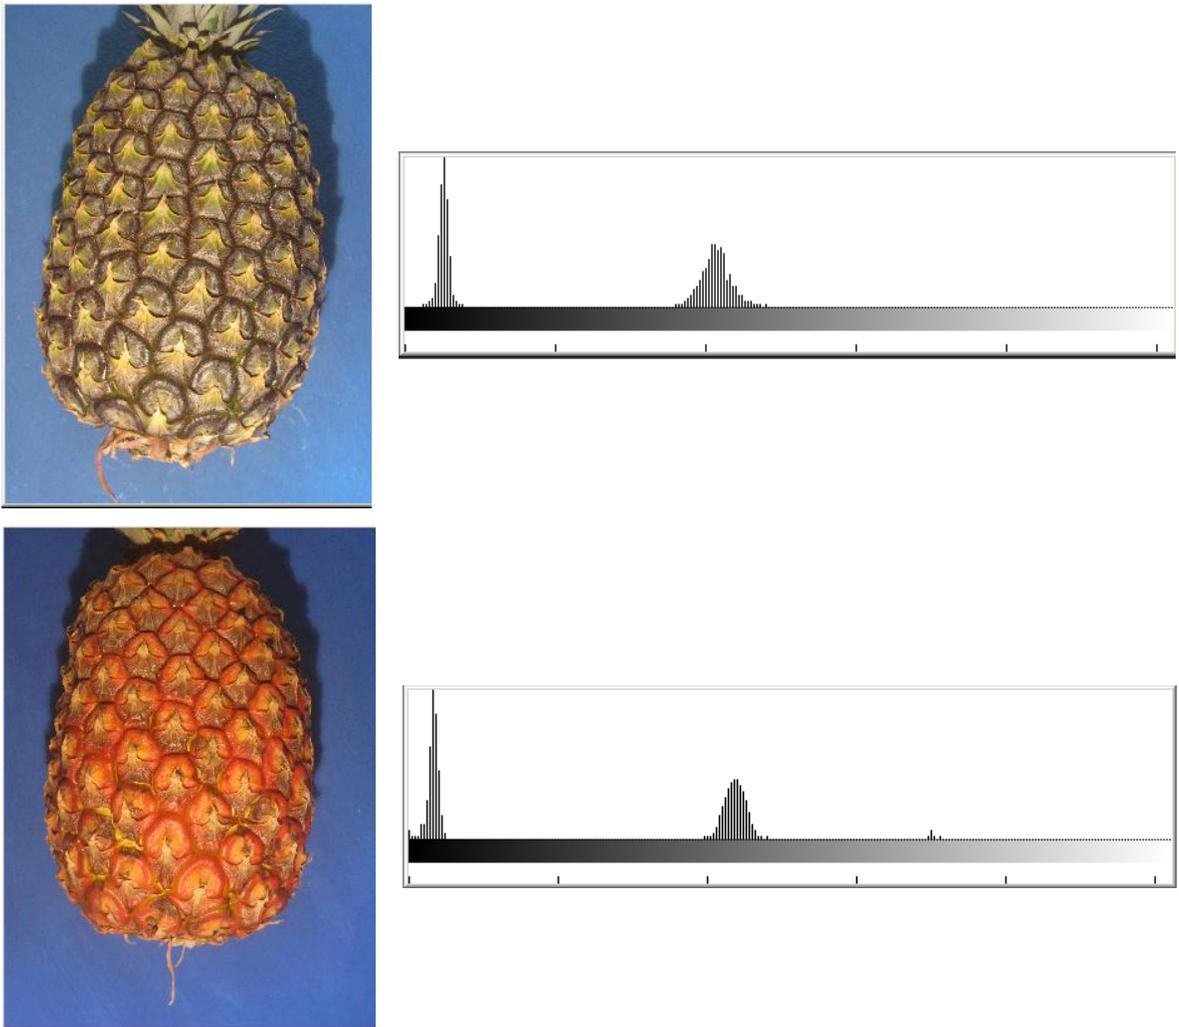
Figura 26. Seguimiento diario de una piña específica



Fuente: Autor.

Las condiciones de iluminación homogénea permitieron obtener histogramas óptimos para el proceso de segmentación. Los resultados se pueden observar en la Figura 27.

Figura 27. Imagen e histograma de la componente matiz para dos muestras diferentes en la tercera toma de muestras



Fuente: Autor.

Las muestras obtenidas en la tercera toma, se utilizaron como muestras de entrenamiento para el clasificador de patrones. Por lo que fue necesario realizar una cuarta toma de muestras con el fin de validar el clasificador.

3.2. PRE-PROCESAMIENTO DE LAS IMAGENES

En el pre-procesamiento, los histogramas de las imágenes son tratados mediante filtros, ya que durante el proceso de adquisición las imágenes pueden ser afectadas por ruido u otras perturbaciones. Se decidió aplicar el filtro a los histogramas en lugar de a las imágenes; porque estos son el objeto de trabajo durante todo el proceso.

Hasta el momento se había realizado un algoritmo para conocer la viabilidad de las muestras durante la segmentación. Por lo tanto, se modificó y estructuró el algoritmo anterior por un nuevo algoritmo el cual carga la imagen en el programa, convierte la imagen del espacio RGB a HSV, se obtienen los planos H, S y V de forma individual junto con sus histogramas y por último se aplica un filtro para suavizar dichos histogramas.

Para cargar la imagen desde un archivo al programa se utilizó una función llamada *cvLoadImage()* de las librerías OpenCV, la cual busca la imagen desde la ruta del proyecto y la convierte en una estructura de datos. Esta imagen puede estar en varios formatos (BMP, DIB, JPEG, JPE, PNG, PBM, PGM, PPM, SR, RAS y TIFF). Las librerías manejan la imagen como una estructura de datos llamada *IplImage* (Figura 28) la cual contiene los elementos necesarios para manipular la imagen durante la ejecución del algoritmo.

Figura 28. Estructura IplImage

```
typedef struct _IplImage {
    int          nSize;
    int          ID;
    int          nChannels;
    int          alphaChannel;
    int          depth;
    char         colorModel[4];
    char         channelSeq[4];
    int          dataOrder;
    int          origin;
    int          align;
    int          width;
    int          height;
    struct _IplROI*  roi;
    struct _IplImage* maskROI;
    void*        imageId;
    struct _IplTileInfo* tileInfo;
    int          imageSize;
    char*        imageData;
    int          widthStep;
    int          BorderMode[4];
    int          BorderConst[4];
    char*        imageDataOrigin;
} IplImage;
```

Fuente: BRADSKI, Gary y KAEBLER, Adrian. Learning OpenCV. Computer Vision with the OpenCV Library. USA: O'REILLY, 2008. p. 42.

Las imágenes capturadas mediante cámaras digitales normalmente se encuentran en el modelo de color RGB. Sin embargo, se optó por utilizar el modelo HSV debido a que imita la manera como los inspectores de calidad en productos agrícolas determinan el estado de madurez de los mismo, mediante los cambios en el matiz y pureza del color.

Para lograr transformar las imágenes al espacio HSV se utilizó la función `cvCvtColor()` de las librerías OpenCV, la cual toma una imagen RGB de entrada y

la transforma en una imagen HSV de salida. Luego otra función llamada *cvCvtPixToPlane()* permite extraer los planos individualmente, estos planos se crean como imágenes de un solo canal, de datos enteros sin signo y 8 bits. En la Figura 29 se puede observar la transformación de RGB a HSV en una imagen, mientras que en la Figura 30 se muestran los planos individualmente.

Figura 29. Conversión del modelo RGB al HSV



Fuente: Autor.

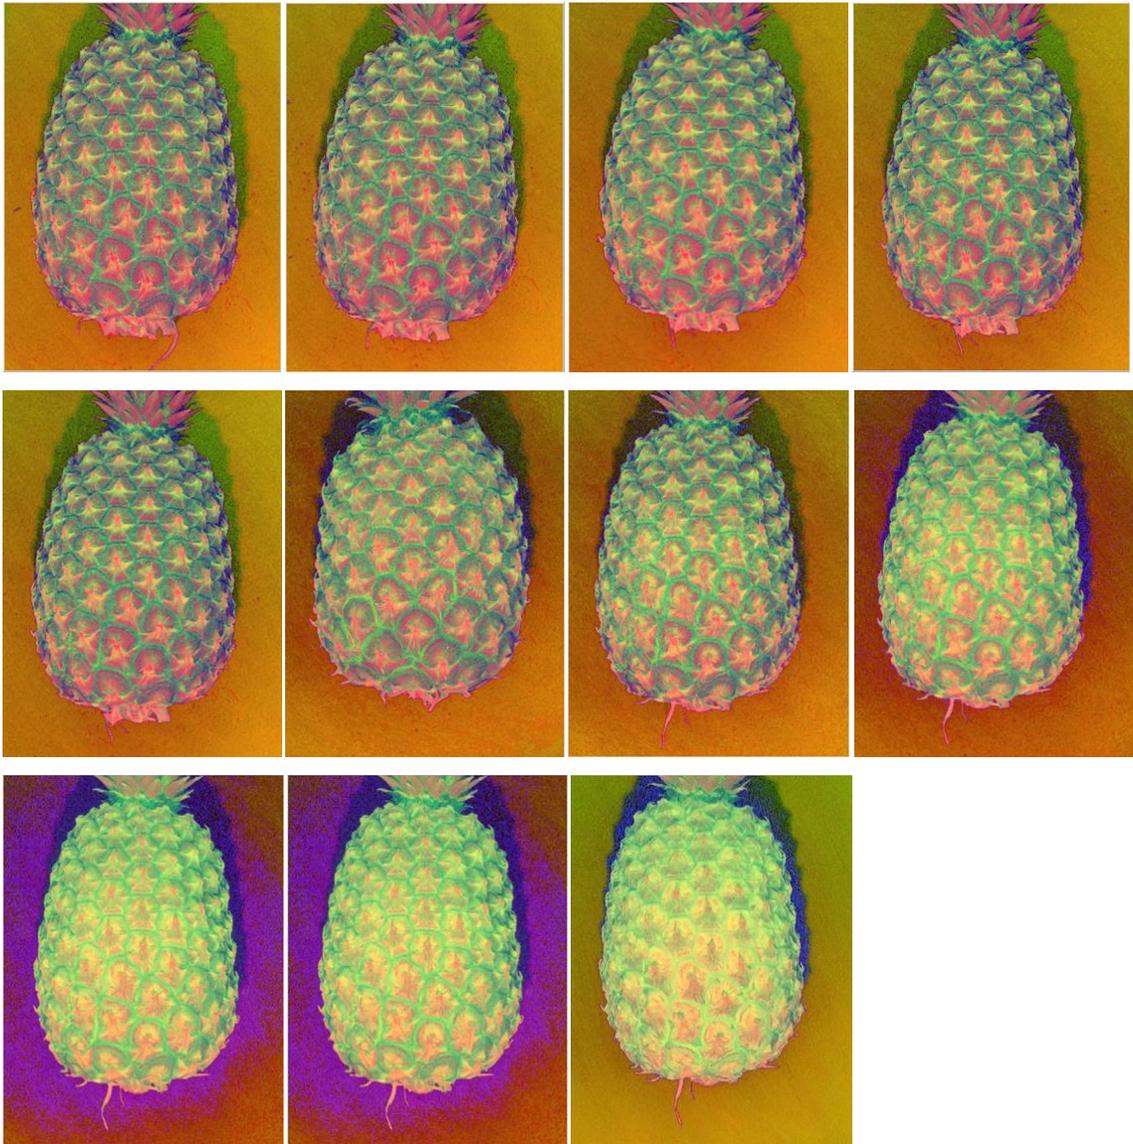
Figura 30. Planos H, S y V



Fuente: Autor.

Posteriormente se realizó el seguimiento por día durante el proceso de maduración. Los cambios en el color presentados en el producto durante este proceso se muestran en las imágenes de la Figura 31. Estas imágenes, permiten observar los cambios en el color que a simple vista no son evidentes para el modelo RGB y que mediante el modelo HSV es posible apreciarlos.

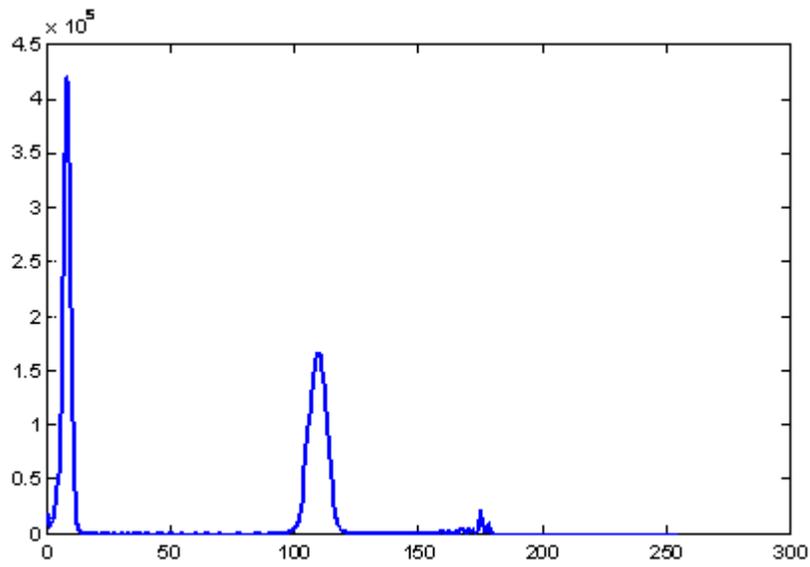
Figura 31. Imágenes en el espacio HSV de una piña en sus días de maduración



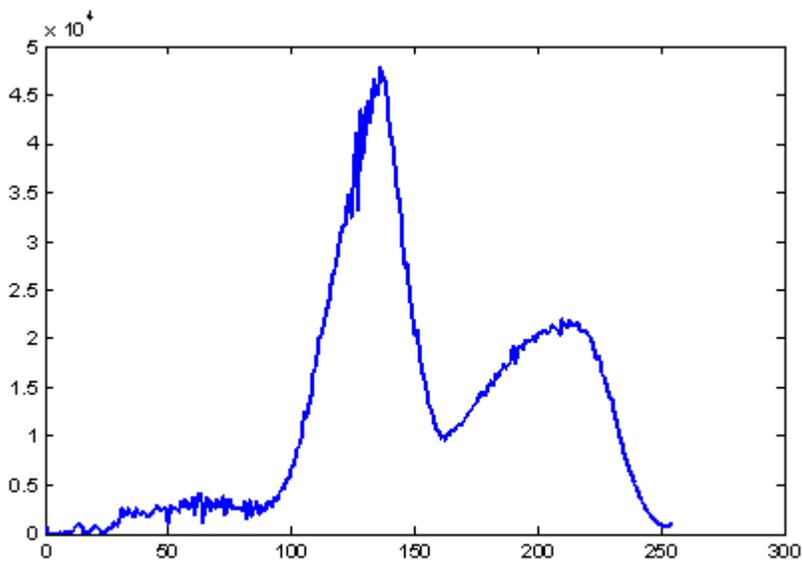
Fuente: Autor.

Una vez obtenida la imagen en el modelo HSV, se hallaron los histogramas tanto del plano H como del plano S, mediante la función *cvCalcHist()* de las librerías OpenCV. Los histogramas obtenidos para una muestra determinada son presentados en la Figura 32.

Figura 32. (a) Histograma del plano H, (b) Histograma del plano S



a



b

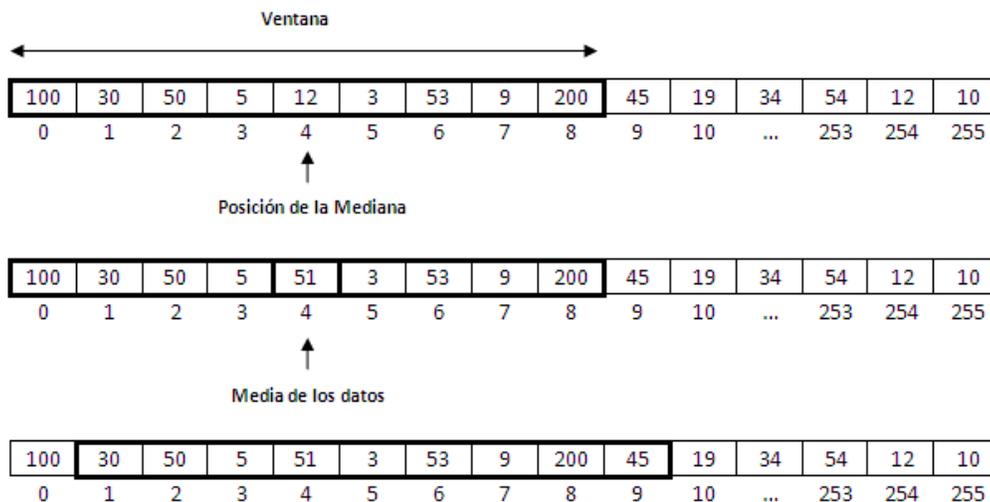
Fuente: Autor.

Como se observa en los histogramas obtenidos, las distribuciones estadísticas están afectadas exteriormente por ruido, el cual se manifiesta en las variaciones bruscas del mismo. Con el fin de eliminar este ruido, se empleó un filtro “*moving average*”, el cual se implementó mediante la función `cvSmoothHist()`, desarrollada por el autor, haciendo uso del siguiente pseudocódigo:

1. Seleccionar un valor de ventana (necesariamente debe ser impar) en este caso 9.
2. Los datos del histograma se colocan en un vector.
3. Se ubica el primer elemento del vector y se halla la media correspondiente a los valores que encierra la ventana.
4. El resultado de la operación anterior se ubica en el sitio correspondiente a la mediana de ese conjunto de datos.
5. Se desplaza la ventana al siguiente elemento del vector.

A manera de ejemplo, la ejecución de este filtro se muestra en la Figura 33.

Figura 33. Filtro de la mediana del tipo “moving average”

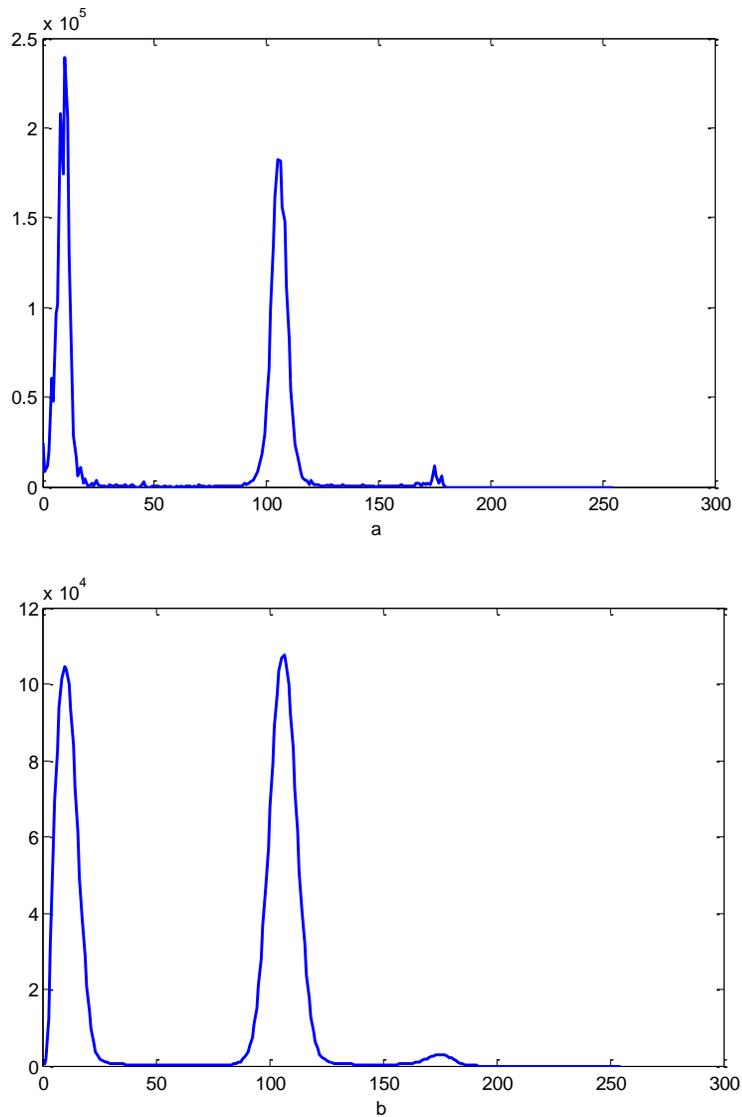


Fuente: Autor.

Una característica importante de este tipo de filtro es que al aplicarlo varias veces sobre el mismo histograma, se suavizan cada vez más sus curvas y no altera significativamente sus niveles de gris.

Para obtener un histograma suavizado se aplico tres veces el filtro. Los resultados se observan en la Figura 34.

Figura 34. (a) Histograma sin filtro, (b) Histograma con el filtro aplicado tres veces

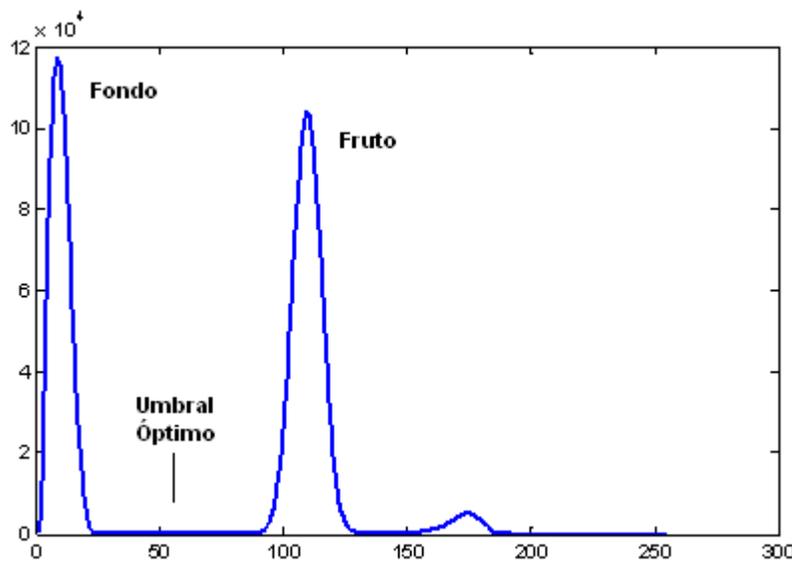


Fuente: Autor.

3.3. SEGMENTACIÓN DE LAS IMAGENES

Este proceso comenzó mediante una estrategia de segmentación inicial, la cual consistía en la umbralización de algún plano en el modelo de color HSV (establecido anteriormente como el modelo de trabajo). Una vez definido este plano, la imagen es binarizada y finalmente se extrae la región de interés. El comportamiento de las distribuciones en los histogramas determinó que la umbralización del histograma perteneciente al plano H era la mejor estrategia de segmentación, ya que se aprecia claramente la distribución normal que representa los píxeles pertenecientes al fondo y la distribución que representa los píxeles pertenecientes al fruto, tal como se observa en la Figura 35. Sin embargo, existe una pequeña distribución correspondiente a pequeños grupos de píxeles del fondo, los cuales poseen valores por encima del umbral óptimo.

Figura 35. Histograma del plano H utilizado en la segmentación



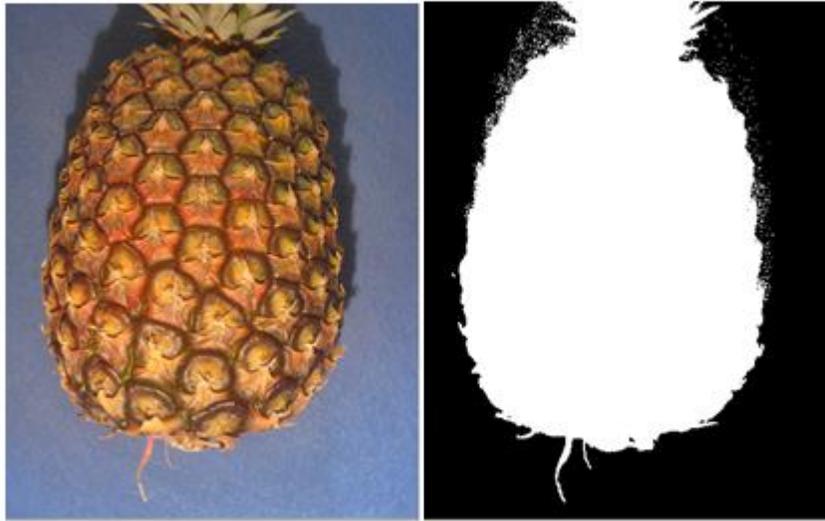
Fuente: Autor.

Una de las posibles formas de hallar el umbral óptimo es mediante el método de Otsu. Este método permite hallar el umbral óptimo entre dos distribuciones gaussianas de forma automática y además es muy empleado en las aplicaciones industriales por su rapidez de ejecución y fiabilidad. Para aplicar este método, se desarrolló función denominada $cvOtsu()$, diseñada por el autor. Este algoritmo se explica en el siguiente pseudocódigo:

1. Se halla la distribución de probabilidad de todos los niveles de gris del histograma tal como lo indica la ecuación 11.
2. Se obtiene la probabilidad de ocurrencia y la media de las dos clases en general.
3. Se halla la probabilidad de ocurrencia de cada una de las clases individualmente. La clase que corresponde al fondo y la que corresponde al fruto (Ecuación 12).
4. Si la probabilidad de las dos clases es diferente de cero entonces se calcula la media correspondiente a cada una de las clases (Ecuación 13).
5. Empleando la ecuación 15, se calcula la varianza ponderada para cada nivel de gris.
6. Finalmente, un condicional identifica la varianza máxima de la cual se obtiene el umbral óptimo de Otsu mediante el nivel de gris al cual pertenece dicha varianza.

Una vez hallado el umbral óptimo, se procede a crear una imagen binarizada mediante la cual se extrae el área de interés de la imagen original. Todos los píxeles que están por encima del umbral óptimo se etiquetan como "1" y los que están por debajo de este umbral son etiquetados como "0". La imagen binarizada como resultado de este proceso se muestra en la Figura 36.

Figura 36. Imagen Binarizada



Fuente: Autor.

En la imagen anterior, se aprecia claramente el área correspondiente a la piña. Sin embargo existen pequeñas áreas que corresponden a grupos de píxeles que poseen valores por encima del umbral óptimo. Con el fin de eliminar estas áreas no deseadas, se procedió a utilizar la transformación morfológica de apertura. Utilizando la función *cvErode()* y luego *cvDilate()* de las librerías OpenCV, se obtuvo una nueva imagen binarizada mejorada, la cual es adecuada para extraer el área de interés de la imagen original. Los resultados obtenidos se pueden apreciar en la Figura 37.

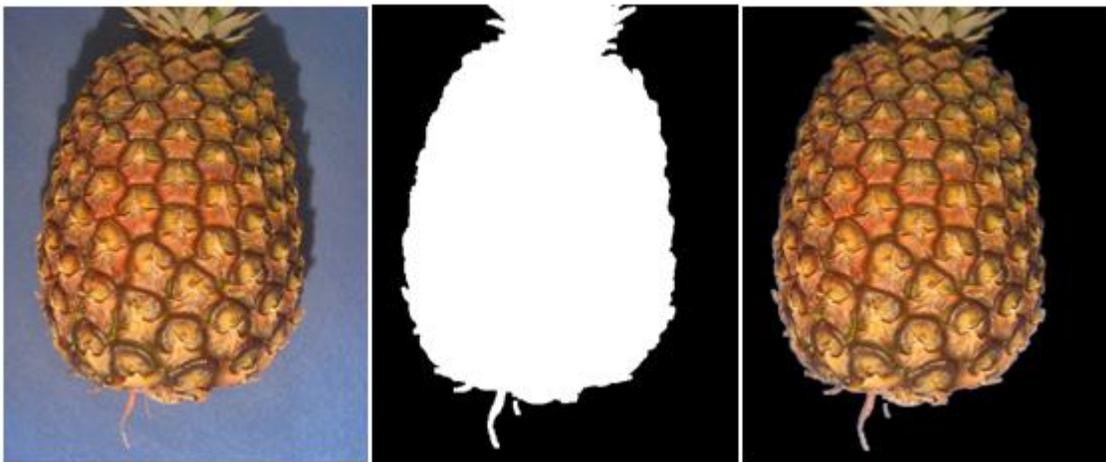
Figura 37. Imagen tratada mediante la operación morfológica de apertura



Fuente: Autor.

Finalmente, se extrajo el área de interés de la imagen utilizando la imagen binarizada mejorada. Los resultados de este procedimiento se observan en la Figura 38.

Figura 38. Imagen obtenida del proceso de segmentación



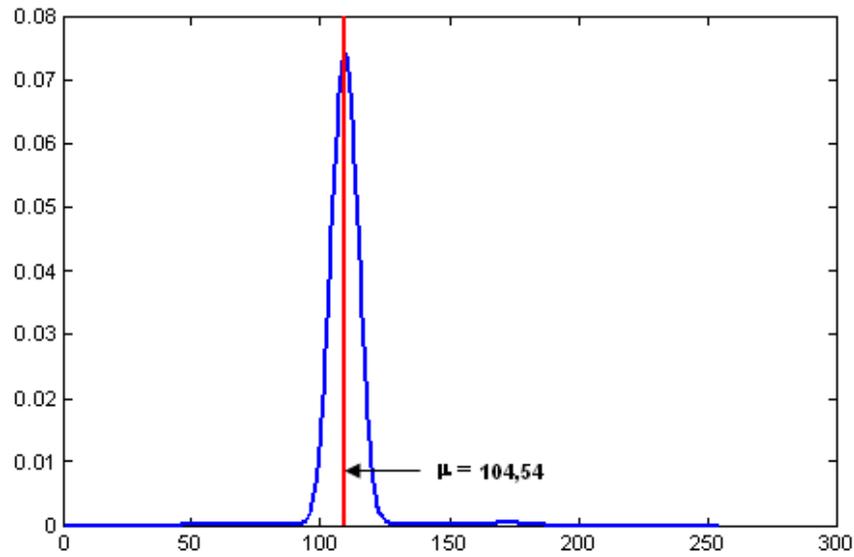
Fuente: Autor.

3.4. EXTRACCIÓN DE CARACTERÍSTICAS

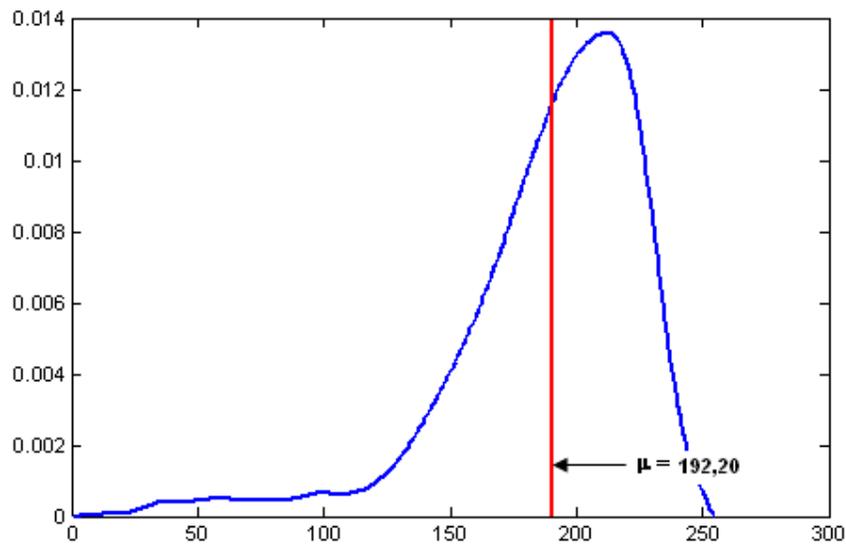
El color es fundamental para evaluar la maduración de los frutos, es por ello que se utilizó como característica fundamental para ser extraída. El modelo HSV es utilizado en esta parte del proceso ya que mediante el análisis de los histogramas de las componentes matiz y saturación es posible extraer características importantes que definen el color del fruto.

Los momentos de color son una de las técnicas más utilizadas en el análisis de los histogramas para determinar el color predominante en una imagen. La media de un histograma corresponde al primer momento del color en esa distribución. Para el histograma de la componente matiz, la media indica el color dominante en la imagen y para el histograma de la componente saturación la media revela la cantidad de blanco que afecta la pureza del color. La media en cada histograma fue hallada mediante la Ecuación 3. Sin embargo, fue necesario normalizar los histogramas, debido a que la sumatoria de las probabilidades de ocurrencia debía ser "1" para poder aplicar la ecuación. En la Figura 39 se puede observar la ubicación de la media en el histograma para una muestra específica.

Figura 39. La media en cada histograma para una piña específica. (a) La media para H y (b) La media para S



a

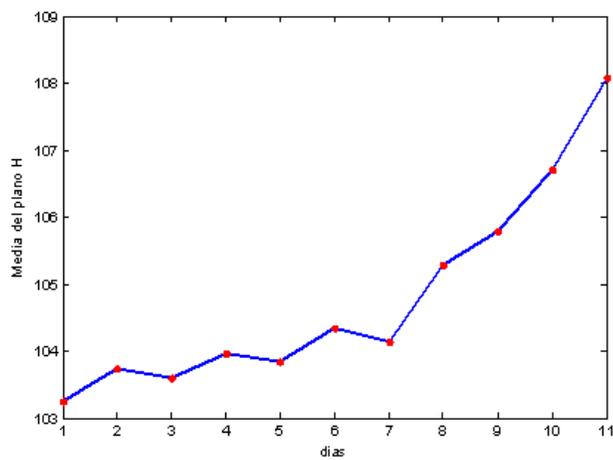


b

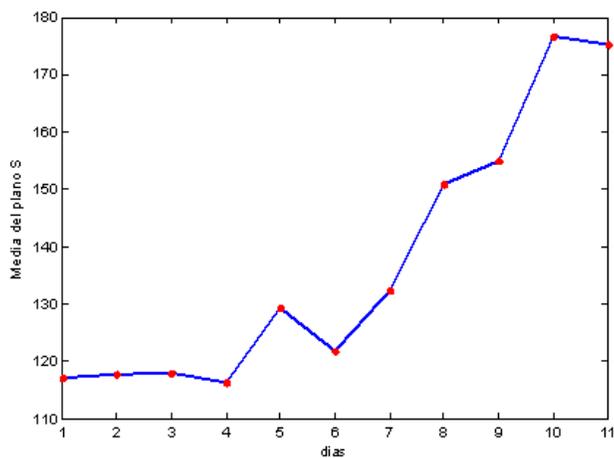
Fuente: Autor.

Una vez obtenida la media en cada histograma, se realiza el seguimiento de cada piña en todo su proceso de maduración, utilizando las imágenes almacenadas en la base de datos. Como se observa en la Figura 40, la media en cada componente de color aumenta en forma exponencial a medida que la piña madura.

Figura 40. Medias de los planos H y S durante los días del proceso de maduración. (a) Medias del plano H y (b) Medias del plano S



a



b

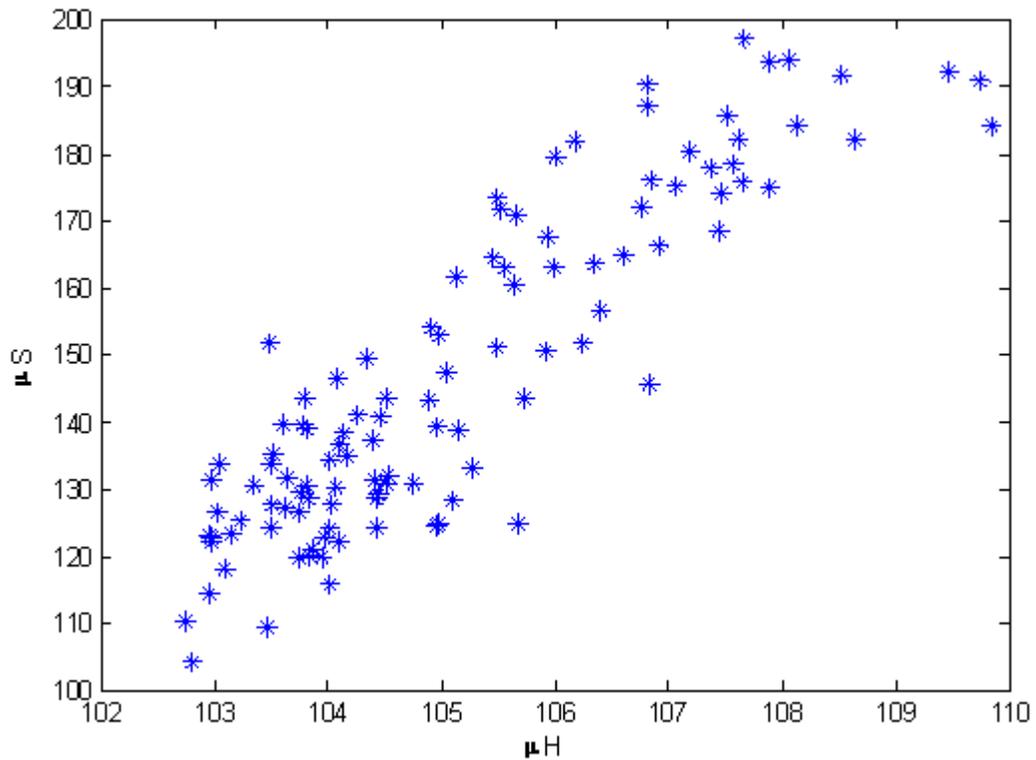
Fuente: Autor

3.5. CLASIFICACIÓN

Este procedimiento permite clasificar las características obtenidas anteriormente y asignarlas dentro de una clase específica, que para este trabajo, corresponden a las tres etapas presentes en el proceso de maduración de la piña: verde, pintona y madura. Es preciso aclarar, que aunque se conoce el número de clases, son desconocidos los parámetros estadísticos de cada una de ellas (media, varianza, correlación entre clases). Es por ello que se utiliza el agrupamiento mediante clusters.

Como se explicó anteriormente las características extraídas de cada muestra corresponden a la media de los planos H y S. Las características para todas las muestras de entrenamiento son graficadas en el plano cartesiano como se observa en la Figura 41. A este plano se le denomina espacio de características, en el cual para cada punto, la abscisa corresponde a la media del plano H mientras la ordenada corresponde a la media del plano S. Una vez obtenido el espacio de características es necesario agruparlas mediante el algoritmo MBSAS (*Modified Basic Sequential Algorithmic Scheme* – en inglés) planteado en el numeral 1.3.1.1 de este documento.

Figura 41. Espacio de características



Fuente: Autor.

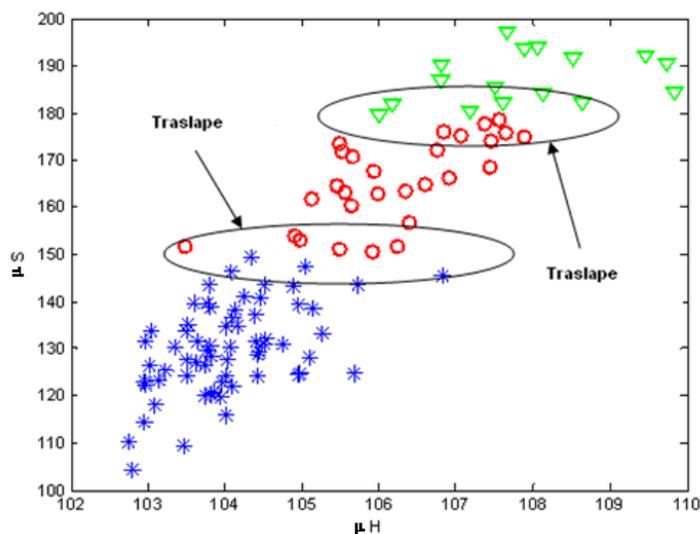
El algoritmo MBSAS es el encargado del aprendizaje y consta de dos fases: la primera fase consiste en la determinación de los clusters, a través de la presentación de los vectores de características (medias de matiz y saturación) de cada imagen, y en la segunda fase los vectores sin asignar son presentados por una segunda vez al algoritmo y son asignados al cluster apropiado empleando como criterio la mínima distancia. Por último, se recalculan los centroides correspondiente a cada cluster.

El número de muestras de entrenamiento fueron 110 y sus características organizadas en dos vectores, uno para las medias de matiz y el otro para las

medias de saturación. Una vez obtenidos estos vectores se presentan al algoritmo de agrupamiento MBSAS.

Dentro del desarrollo del algoritmo es necesario definir un parámetro de proximidad entre las clases; el cual establece si una muestra pertenece o no a una clase determinada. Si el parámetro de proximidad hallado para una muestra dada es mayor que un valor previamente establecido, el algoritmo de agrupamiento es obligado a formar un nuevo cluster o clase. En este caso, el parámetro de proximidad se determinó a manera de ensayo y error, obligando al algoritmo a formar únicamente tres clusters, correspondientes a las etapas de maduración que se desean evaluar. Aplicando el algoritmo de agrupamiento previamente descrito, se obtuvo los resultados mostrados en la Figura 42. Las muestras de color azul corresponden a la primera clase (piña verde), las de color rojo corresponden a la segunda clase (piña pintona) y las muestras de color verde pertenecen a la tercera clase (piña madura).

Figura 42. Agrupamiento de las características y el traslape entre los límites de cada grupo.



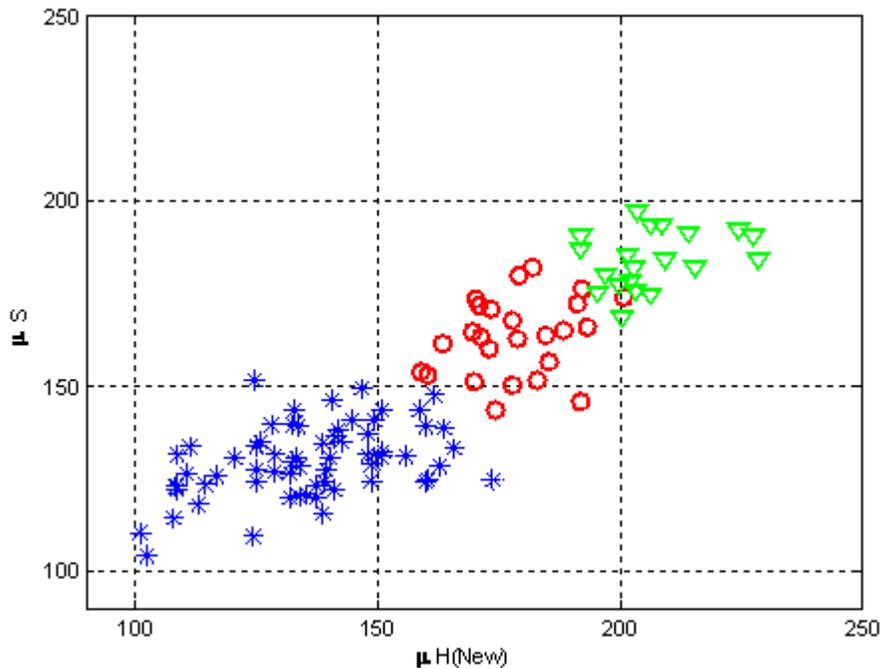
Fuente: Autor.

En la Figura 42, se observa que el criterio de agrupamiento afecta la asignación de las muestras cercanas a los límites de cada clase, a esto se le conoce como traslape. Esto se debe a que los datos en el eje μH están muy cercanos entre sí (intervalo entre 102 - 110) comparados con los datos de eje μS (intervalo entre 100 - 200). Para dar una mejor distribución de las clases fue necesario escalar los datos de μH empleando una escala logarítmica dado que los datos aumentan en forma exponencial tal como se observó en la Figura 40. El escalado utiliza la siguiente expresión:

$$\mu H_{New} = 100 \ln(\mu H_i - 100), \quad \text{donde } i = 1,2,3 \dots 110 \quad (19)$$

En la Figura 43, se puede observar claramente la mejora en la distribución de los datos así como en su agrupación.

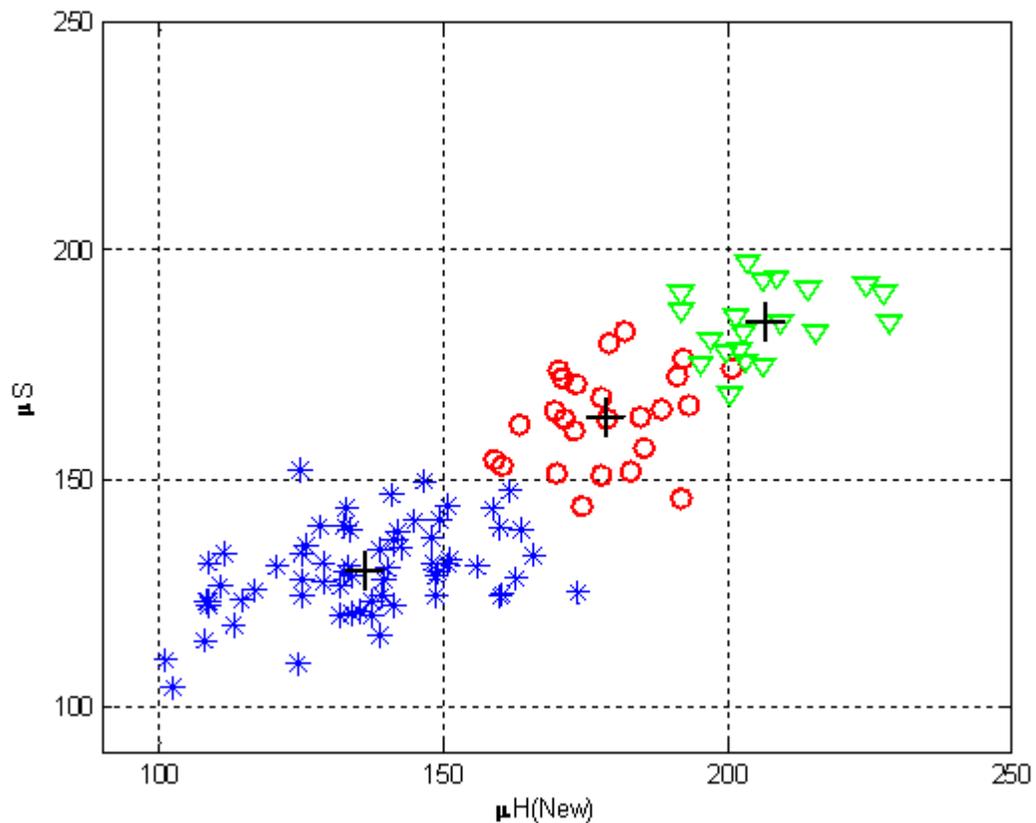
Figura 43. Agrupamiento de las características cambiando la escala de μH



Fuente: Autor.

Una vez asignados cada dato a un cluster específico, se recalcula el centroide del cluster afectado. Esto lo realiza la segunda fase del algoritmo MBSAS. Los tres centroides obtenidos en la fase de entrenamiento se muestran en la Figura 44. Estos centroides definen las tres etapas de maduración de la piña y serán utilizados posteriormente por el clasificador de mínima distancia Euclídea.

Figura 44. Centroides obtenidos en la fase de entrenamiento



Fuente: Autor.

El clasificador encuentra la distancia mínima Euclídea entre las características de cada muestra de evaluación y los centroides obtenidos por el entrenador. Una vez

hallada la distancia mínima Euclídea, se determina a cual cluster pertenece esta muestra y se define el estado de maduración en que se encuentra.

El siguiente pseudocódigo explica el procedimiento descrito anteriormente.

Para cada una de las muestras de evaluación:

1. Se encuentra la distancia mínima Euclídea entre los centroides entregados por el entrenador y la media de los histogramas H y S de la muestra de evaluación.
2. Se determina a cual cluster pertenece.
3. Se imprime en pantalla la etapa de maduración a la cual pertenece.

Las etapas de maduración se definieron de la siguiente forma:

- ❖ **Etapa 1:** iniciación de coloración.
- ❖ **Etapa 2:** cuando esta pintona.
- ❖ **Etapa 3:** se considera madura.

4. ANÁLISIS DE RESULTADOS

En este capítulo se presentan los resultados obtenidos y su correspondiente análisis. Las muestras de evaluación fueron clasificadas y etiquetadas según la etapa de maduración a la que pertenecen. Los resultados entregados por el clasificador fueron analizados por tres expertos los cuales clasificaron 5 piñas tomadas aleatoriamente de las muestras de evaluación. Estos resultados fueron tabulados y analizados para dar una estimación del error en cada etapa de maduración.

Las muestras de evaluación fueron 209 para un total de 19 piñas, cada fruto fue clasificado por el algoritmo propuesto y los resultados fueron tabulados en la Tabla 3.

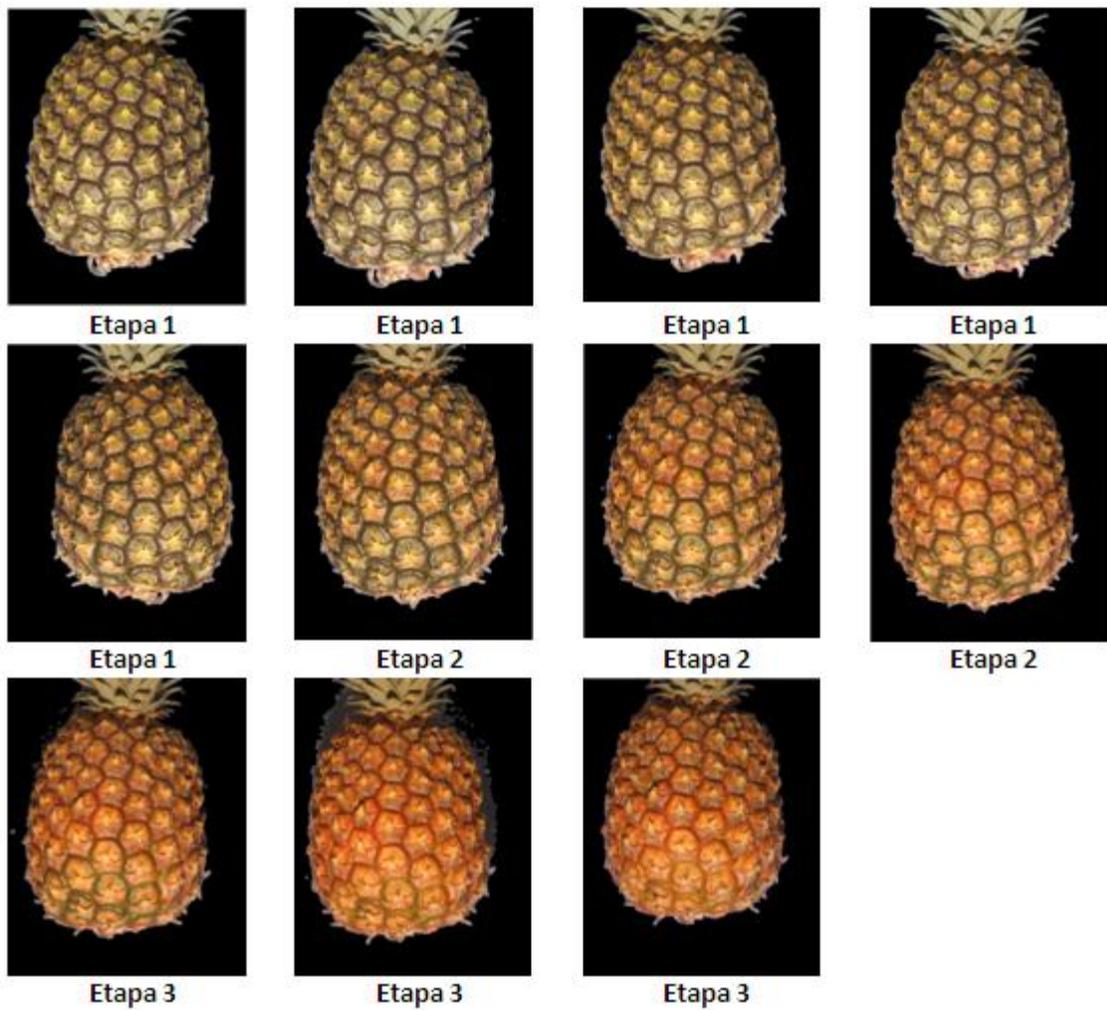
Tabla 3. Clasificación de las muestras de evaluación utilizando el algoritmo propuesto

Nro. Piña	Día 01	Día 02	Día 03	Día 04	Día 05	Día 06	Día 07	Día 08	Día 09	Día 10	Día 11
01	1	1	1	1	1	1	1	2	2	3	3
02	1	1	1	1	2	2	2	2	2	3	3
03	1	1	1	1	1	2	2	2	3	3	3
04	1	1	1	1	1	2	2	2	3	3	3
05	1	1	1	1	2	2	3	3	3	3	3
06	1	1	1	1	1	1	1	1	2	2	2
07	1	1	1	2	2	2	2	2	2	2	2
08	1	1	1	1	1	1	1	2	3	3	3
09	1	1	1	1	2	1	2	2	2	2	2
10	1	1	1	1	1	2	2	3	3	3	3
11	1	1	1	1	1	2	2	2	3	3	3
12	1	1	1	1	1	2	1	2	3	3	3
13	1	1	1	1	2	2	2	3	3	3	3
14	1	1	1	1	1	1	2	2	2	3	3
15	1	1	1	1	1	2	2	2	2	3	3
16	1	1	1	1	1	2	2	2	3	3	3
17	1	1	1	1	1	1	2	2	3	3	3
18	1	1	1	1	1	1	2	3	3	3	3
19	1	1	1	1	1	2	2	3	3	3	3

Fuente: Autor.

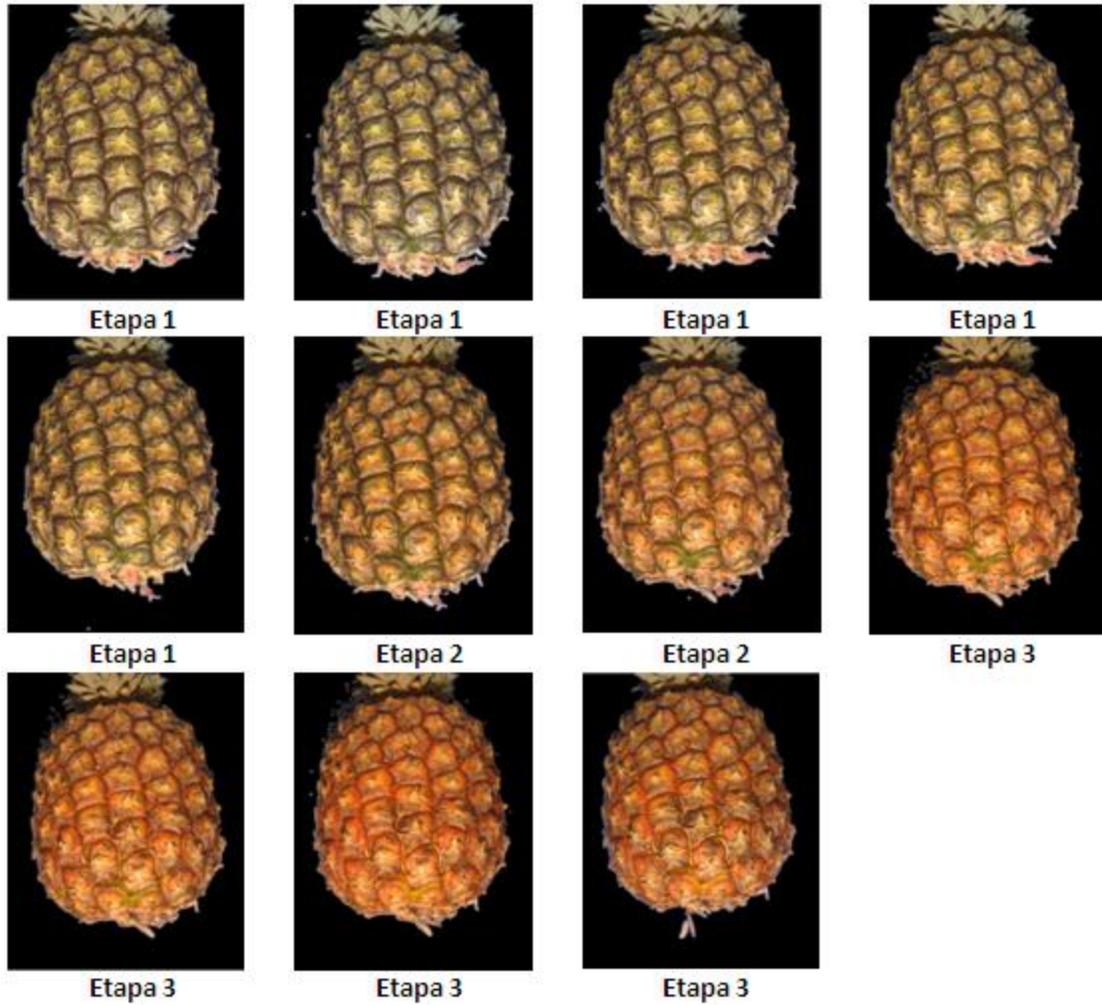
Las muestras para cinco piñas fueron extraídas aleatoriamente y clasificadas por el algoritmo propuesto. Los resultados de esta clasificación se pueden observar en las Figuras 45, 46, 47, 48 y 49.

Figura 45. Clasificación de la piña 03 según el clasificador.



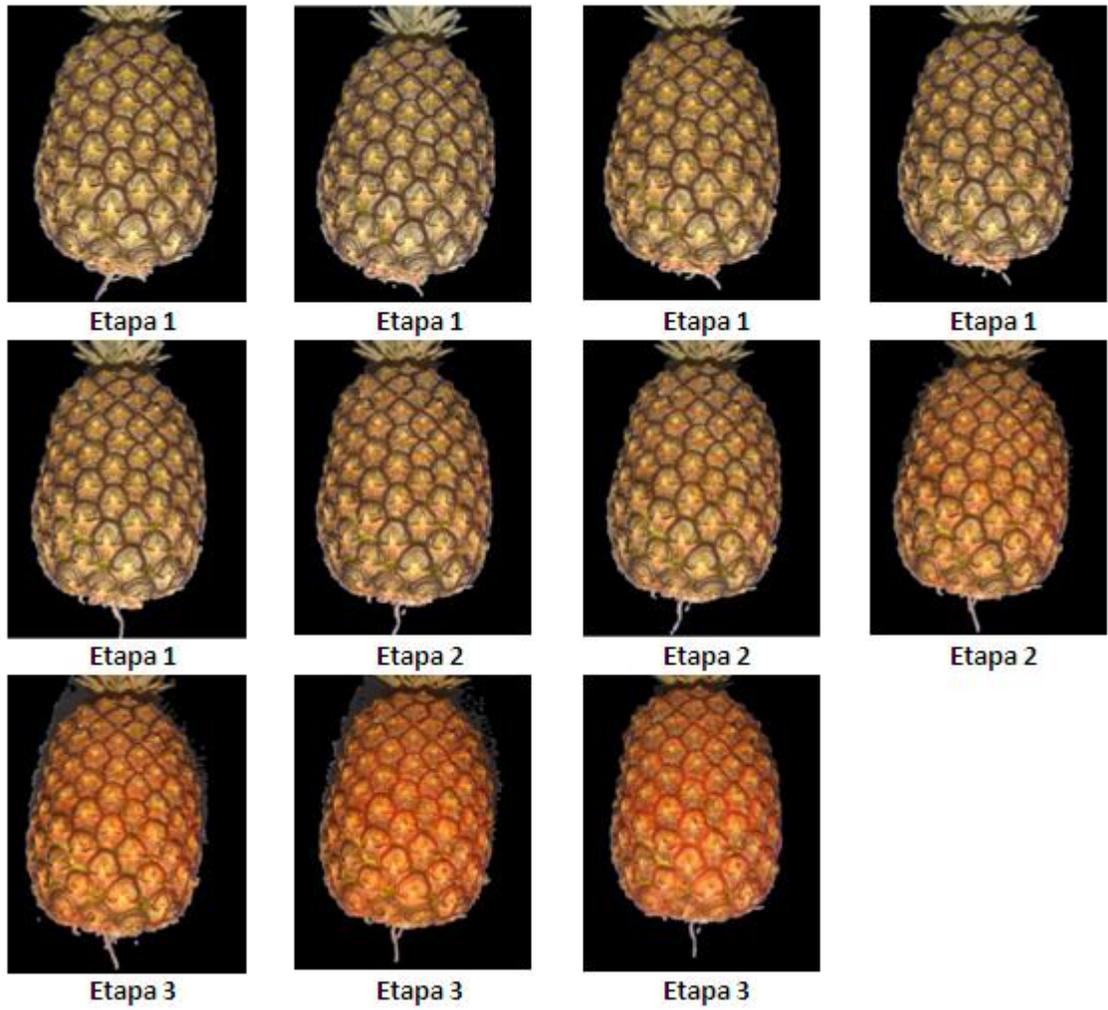
Fuente: Autor.

Figura 46. Clasificación de la piña 10 según el clasificador.



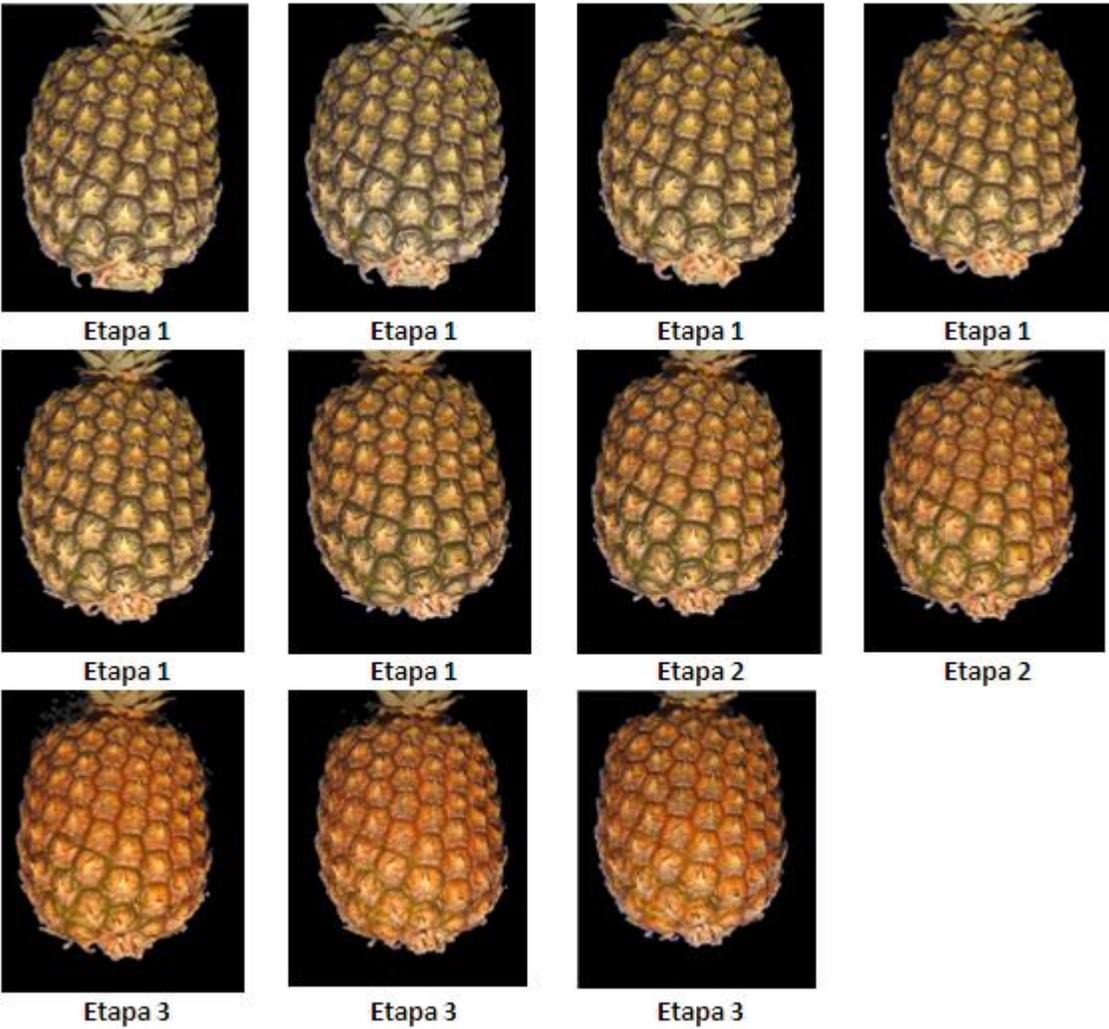
Fuente: Autor.

Figura 47. Clasificación de la piña 11 según el clasificador.



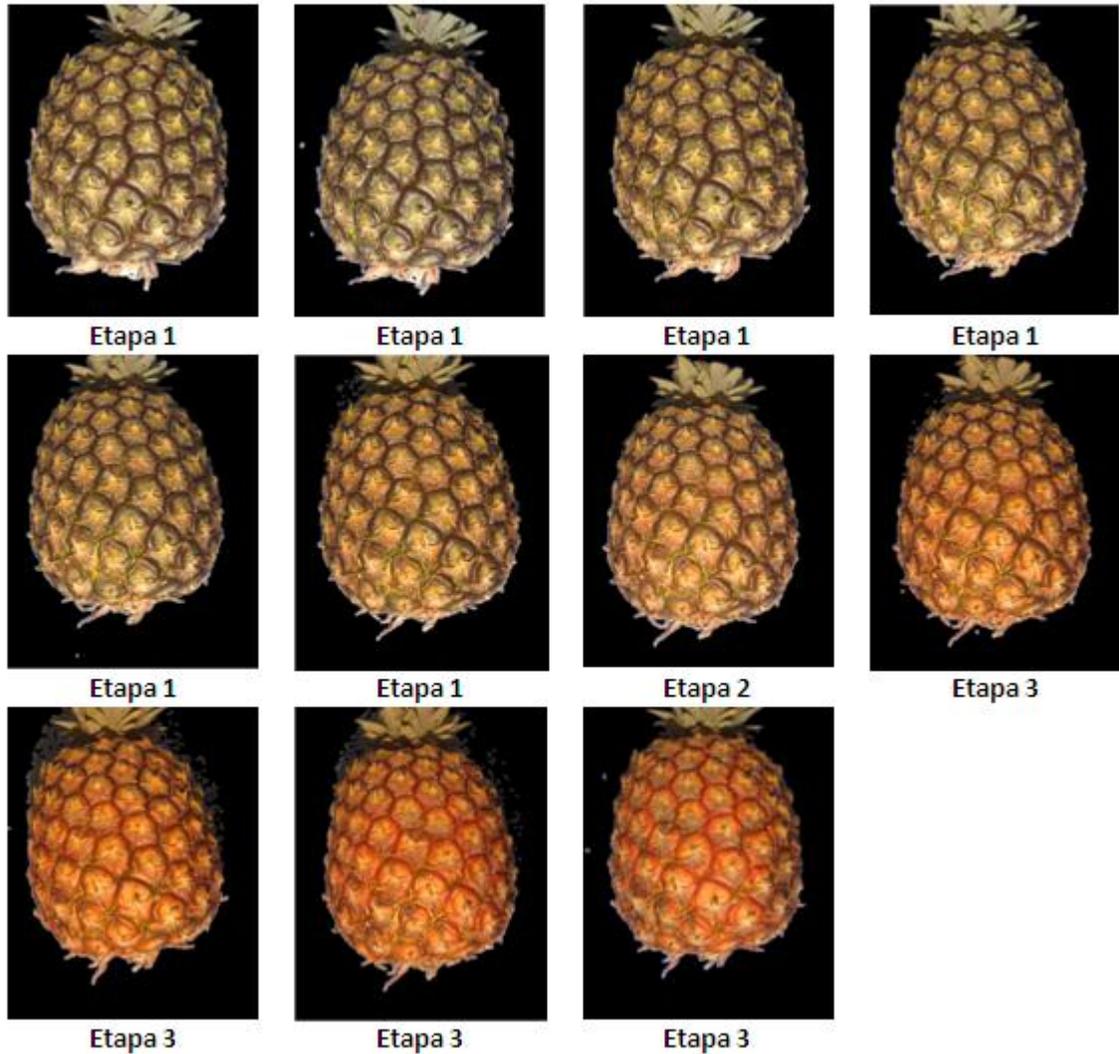
Fuente: Autor.

Figura 48. Clasificación de la piña 17 según el clasificador.



Fuente: Autor.

Figura 49. Clasificación de la piña 18 según el clasificador.



Fuente: Autor.

Los resultados dados por el clasificador para las muestras seleccionada aleatoriamente fueron presentados a tres expertos, los cuales tienen más de 10 años de experiencia en el cultivo y comercialización de la piña. Ellos, basados en su experiencia, determinaron a cual etapa de maduración pertenecía cada una de

las muestras. El criterio de clasificación de los expertos contrastado con los resultados del clasificador se presenta en las Tablas 4, 5, 6, 7 y 8.

Tabla 4. Clasificación según expertos para la piña 03.

Días	1	2	3	4	5	6	7	8	9	10	11
Clasificador	1	1	1	1	1	2	2	2	3	3	3
Experto Nro. 1	1	1	1	1	1	2	2	2	3	3	3
Experto Nro. 2	1	1	1	1	1	2	2	2	3	3	3
Experto Nro. 3	1	1	1	1	1	2	2	2	3	3	3

Fuente: Autor.

Tabla 5. Clasificación según expertos para la piña 10

Días	1	2	3	4	5	6	7	8	9	10	11
Clasificador	1	1	1	1	1	2	2	3	3	3	3
Experto Nro. 1	1	1	1	1	1	2	2	2	3	3	3
Experto Nro. 2	1	1	1	1	1	2	2	2	3	3	3
Experto Nro. 3	1	1	1	1	1	2	2	2	3	3	3

Fuente: Autor.

Tabla 6. Clasificación según expertos para la piña 11.

Días	1	2	3	4	5	6	7	8	9	10	11
Clasificador	1	1	1	1	1	2	2	2	3	3	3
Experto Nro. 1	1	1	1	1	1	2	2	2	3	3	3
Experto Nro. 2	1	1	1	1	1	2	2	2	3	3	3
Experto Nro. 3	1	1	1	1	1	1	2	2	3	3	3

Fuente: Autor

Tabla 7. Clasificación según expertos para la piña 17.

Días	1	2	3	4	5	6	7	8	9	10	11
Clasificador	1	1	1	1	1	1	2	2	3	3	3
Experto Nro. 1	1	1	1	1	1	1	2	2	3	3	3
Experto Nro. 2	1	1	1	1	1	1	2	2	3	3	3
Experto Nro. 3	1	1	1	1	1	2	2	2	3	3	3

Fuente: Autor.

Tabla 8. Clasificación según expertos para la piña 18.

Días	1	2	3	4	5	6	7	8	9	10	11
Clasificador	1	1	1	1	1	1	2	3	3	3	3
Experto Nro. 1	1	1	1	1	1	1	2	2	3	3	3
Experto Nro. 2	1	1	1	1	1	1	2	2	3	3	3
Experto Nro. 3	1	1	1	1	1	1	2	3	3	3	3

Fuente: Autor.

Como se observa en la Tabla 4, tanto los expertos como el clasificador determinan que la piña 03 está clasificada correctamente. Sin embargo en la Tabla 5, los expertos afirman que en el día 8 la piña 10 aun está en la etapa 2 mientras que el clasificador la ubica en la etapa 3.

En la Tabla 6, el experto 3 asegura que para el día 6 la piña 11 está en la etapa 1, mientras que el clasificador y los otros expertos la ubican en la etapa 2.

En la Tabla 7, el mismo experto afirma que en el día 6 la piña 17 aun se encuentra en la etapa 2, sin embargo los otros dos expertos y el clasificador la ubican en la etapa 1.

Para la piña 18, los expertos 1 y 2 determinan que en el día 8 aun está en etapa 2, sin embargo en la Tabla 8, se observa que el experto 3 está de acuerdo con el clasificador.

De acuerdo a estos resultados, se concluye que los expertos tienen criterios diferentes en determinadas muestras. En la mayoría de los casos, los expertos tienen sus diferencias en la clasificación en los límites de transición de cada etapa de maduración.

4.1. ERROR DE ESTIMACIÓN

Con el fin de medir la fiabilidad del clasificador y teniendo como base el criterio de los expertos, se realizó una estimación del error para cada etapa de maduración, usando la siguiente expresión:

$$\%Error = \left| \frac{Nro. MTC - Nro. MCC}{Nro. MTC} \right| * 100\% \quad (20)$$

Donde,

MTC – muestras totales por etapa clasificadas por el algoritmo propuesto.

MCC – muestras por etapa clasificadas por el algoritmo propuesto y que coinciden con el criterio de los expertos.

A partir de los datos mostrados en las Tablas 4, 5, 6, 7, y 8, los porcentajes de error para cada etapa de maduración se presentan en la Tabla 9.

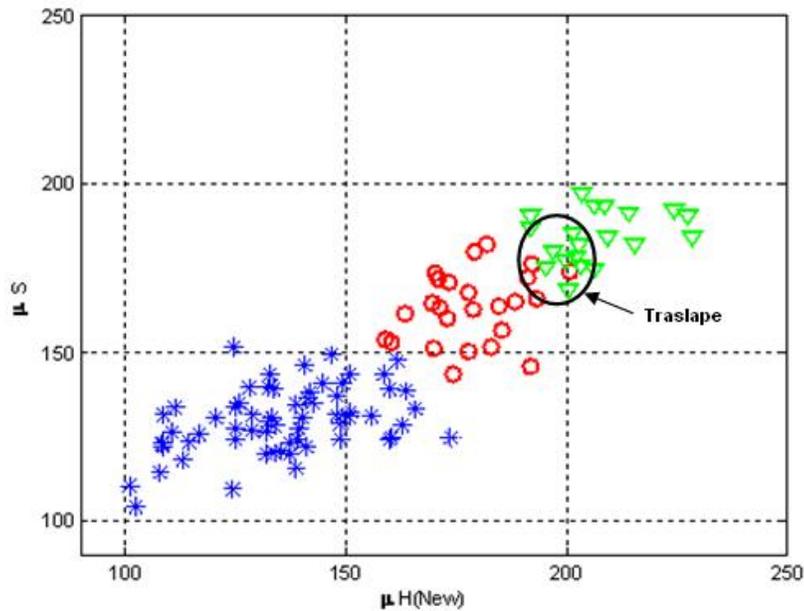
Tabla 9. Porcentajes de error para cada etapa de maduración.

Etapa	Nro. <i>M</i> Total	Nro. <i>M</i> Erradas	% Error
1	27	0	0
2	11	0	0
3	17	2	11,76
Total	55	2	3,63

Fuente: Autor.

El mayor porcentaje de error se da en la etapa 3. Para poder determinar que causaba este error se observa nuevamente el espacio de características. En este se aprecia claramente que aun se presenta un pequeño traslape entre los límites de las etapas 2 y 3, como se muestra en la Figura 50.

Figura 50. Traslape que aun se presenta entre la etapa 2 y 3



Fuente: Autor.

El algoritmo en general presenta un error de clasificación de 3,64%. Por lo tanto, su eficiencia es de 96,36%. Esto garantiza que los resultados obtenidos por el clasificador son realmente eficientes y confiables.

5. CONCLUSIONES

Se desarrolló un algoritmo que segmenta las imágenes de la piña *Perolera* mediante umbralización del histograma de la componente matiz del espacio de color HSV, extrae las medias de la componente matiz y saturación como características de cada patrón, agrupa los datos automáticamente en clusters y finalmente un clasificador de mínima distancia Euclídea permite identificar tres etapas de maduración de la piña en su variedad *Perolera*.

La segmentación por umbralización emplea un umbral óptimo hallado automáticamente mediante el método de Otsu, usando una función desarrollada por el autor.

Fue necesario aplicar un filtro de la mediana del tipo “moving average” para suavizar los histogramas, esto debido a la presencia ruido en el exterior de las distribuciones estadísticas. Sin embargo, este filtro se aplicó al histograma y no directamente a la imagen debido que los histogramas son el objeto de trabajo durante todo el proceso.

Las características utilizadas para clasificar las muestras fueron el primer momento del color (media) de los histogramas de las componentes matiz y saturación. Se utilizó un algoritmo MBSAS para agrupar las características y entrenar el algoritmo.

La efectividad del algoritmo fue del 96,36%, sin embargo en la etapa 3 se presentó un error más alto que en las demás, debido al traslape que aun se presenta entre las etapas 2 y 3. El cual puede ser corregido en trabajos futuros, mediante la correlación entre las clases.

La metodología empleada en este trabajo puede ser extendida a diferentes productos agrícolas de la región para realizar control de calidad en forma automática.

BIBLIOGRAFÍA

ACHARYA, Tinku y RAY, Ajoy K. Image Processing. Principles and Applications. USA: Wiley-Interscience, 2005. 452 p.

ARIAS V., Ciro y TOLEDO H., Julio. Manual de manejo postcosecha de frutas tropicales (Papaya, piña, plátano, cítricos) [online]. Roma (Italia): Organización de las Naciones Unidas para la Agricultura y la alimentación (FAO), 2000. Available from internet: <<http://www.fao.org/inpho/content/documents/vlibrary/ac304s/ac304s00.htm>>

BRADSKI, Gary y KAEBLER, Adrian. Learning OpenCV. Computer Vision with the OpenCV Library. USA: O'REILLY, 2008, 555 p.

CARVAJAL, L. M. Producción, transformación y comercialización de pulpas de frutas tropicales [online]. Medellín (Antioquia): Universidad de Antioquia. Facultad de química farmacéutica, 2000. Available from internet: < <http://huitoto.udea.edu.co/FrutasTropicales/pina.html>>

DU, Cheng-Jin y Sun, Da-Wen. Recent developments in the applications of image processing techniques for food quality evaluation. En: Trends in Food Science & Technology. Mayo, 2004, vol. 15, no. 5, p. 230-249.

GUNASEKARAN, S. Computer vision technology for food quality assurance. En: Trends in food science & technology, Vol. 7, 1996; p. 245-256.

KADVIR, I. y GUYER, D.E. Comparison of Artificial Neural Networks and statistical classifiers in Apple Sorting using Textural Feature. En: Biosystems Engineering. Vol. 89, No. 3, (nov. 2004); p. 331-334.

KATAOKA, T; BULANON, D. M; HIROMA, T; OTA, Y. A segmentation algorithm for the automatic recognition of Fuji apples at harvest. En: Biosystems Engineering. Vol. 83, No. 4, (dic. 2002); p. 405-412.

LEEMANS, V; MAGEIN, H. y DESTAIN, M. F. On-line Fruit Grading according to their External Quality using Machine Vision. En: Biosystems Engineering. Vol. 83, No. 4, (dic. 2002); p. 397-404.

MONTES CASTRILLON, Nubia. Desarrollo de algoritmos de segmentación de frutos maduros y verdes de café en imágenes tomadas en condiciones controladas, basados en las propiedades de color. Trabajo de grado (Ingeniería Electrónica). Manizales: Universidad Nacional de Colombia. Facultad de ingeniería y arquitectura, 2001. 42 p.

OTSU, Nobuyuki. A threshold selection method from grey-level histograms. En: IEEE Transaction Systems man, Cybernetics. Vol. 8, No. 1, (ene. 1979); p. 62-66.

PAJARES M, Gonzalo y DE LA CRUZ G, Jesús M. Visión por Computador. Imágenes digitales y aplicaciones. 2da Edición. México: Alfaomega, 2008. 768 p.

PULIDO, P., et al. Desarrollo del fruto e índices de cosecha de la piña nativa (Ananás comosus) c.v. India producida en el piedemonte amazónico. Colombia: Instituto Amazónico de Investigación Científicas SINCHI en cooperación con la Universidad Nacional de Colombia, Universidad de los Andes y Universidad de la Amazonia., 2001. 21 p.

STRICKER, M. y ORENGO, M. Similarity of color images. En: SPIE Conference on Storage and Retrieval for Image and Video Databases III. Vol. 2420, (feb. 1995); p. 381-392.

THEODORISIS, Sergios y KOUTROUMBAS, Konstantinos. Pattern Recognition. Fourth Edition. USA: Academic Press, 2008. 984 p.

TILLET, R. D. Image analysis for agricultural processes. En: Division Note DN 1585. Research Institute. 1990.

ZOU, X; ZHAO, J; LI, Y. Apple color grading based on organization feature parameters. En: Pattern Recognition Letters. Vol. 28, No. 15, (nov. 2007); p. 2046-2053.

ANEXO A

ESTRUCTURA DEL ALGORITMO EN C

El algoritmo principal está organizado en cuatro subrutinas:

- ❖ ManejoDatos
- ❖ ProcesamientoImagen
- ❖ Entrenador
- ❖ Clasificador

Cada una con su respectivo archivo de encabezado y de código fuente.

El programa principal se denomina *main.cpp*, al cual deben ser vinculadas estas cuatro subrutinas para correr el algoritmo general.

ManejoDatos contiene los *path* que direccionan la ubicación de las piñas que se desean evaluar.

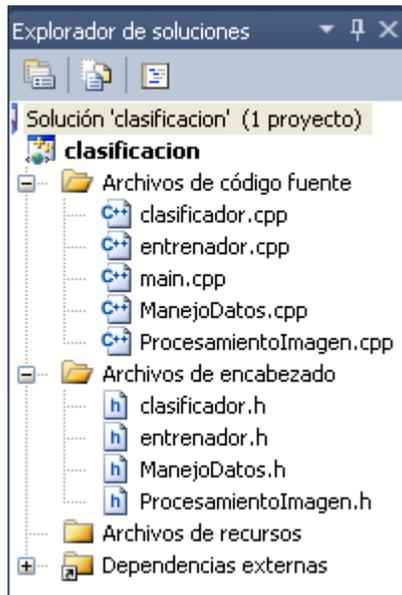
ProcesamientoImagen contiene las funciones necesarias para procesar las imágenes.

Entrenador contiene la función que agrupa y genera los centroides como resultado del proceso de entrenamiento.

Clasificador contiene la función que clasifica la muestra en una determinada etapa de maduración.

Dentro de la carpeta Anexos (incluida en el CD), se encuentra el fichero Clasificación; en este se localiza el *main* del programa junto con los archivos de encabezado y de código fuente de cada subrutina. Los cuales deben ser vinculados al algoritmo tal como se muestra en la Figura 51.

Figura 51. Estructura general del algoritmo.



Fuente: Autor.

Adicionalmente, se entrega los vectores de características en un archivo `.txt` que debe ser vinculado en la subrutina `entrenador`.