



Artículo original / Original article

Mejoramiento del proceso de detección de defectos visuales en castañas, con fines de exportación

Improving the process of detecting visual defects in chestnuts for export purposes

Claudia Cervantes-Jilaja ¹

¹ Universidad Nacional de San Agustín, Arequipa, Perú

Recibido: 23/10/2024

Aceptado: 15/11/2024

Publicado: 30/01/2025

*Autor de correspondencia: ccervantesji@unsa.edu.pe

Resumen: Una importante actividad económica en países como Perú, Bolivia y Brasil es el comercio de frutos secos, como las castañas. Antes de su exportación, se requiere control de calidad que incluye la evaluación del estado de madurez, detección e identificación de defectos, daños o enfermedades. Este proceso se basa en características externas del producto, utilizando descriptores de color, forma, tamaño y textura. Se propone automatizar la detección e identificación de defectos visuales en objetos como las castañas. Se divide en dos regiones (oscura y clara) debido a la similitud de colores entre el objeto y los defectos. La detección se realiza mediante el análisis de textura en cada región, utilizando el algoritmo Detectar Defecto (Alg. 2 y 3) y el descriptor de Primer Orden (Alg. 5). Para identificar los defectos específicos, se aplican descriptores de color, tamaño y textura a través de la Segmentación por Color y Tamaño (Alg. 4). La propuesta fue implementada y probada en una base de datos, logrando una tasa de eficiencia del 97.90% y un tiempo de procesamiento de 17 a 25 ms por imagen, superando al algoritmo del proyecto (Proy.PIPEA_134, 2013), que alcanzó una eficiencia del 91.06% y 43 ms de procesamiento.

Palabras clave: automatización; descriptor de primer orden; detección e identificación; espacios de color; visión computacional

Abstract: An important economic activity in countries such as Peru, Bolivia, and Brazil is the trade of nuts, such as chestnuts. Before export, quality control is required, including the assessment of ripeness and the detection and identification of defects, damage, or diseases. This process is based on the product's external characteristics, using color, shape, size, and texture descriptors. The aim is to automate the detection and identification of visual defects in objects such as chestnuts. The product is divided into two regions (dark and light) due to the color similarity between the object and the defects. Detection is performed through texture analysis in each region, using the Detect Defect algorithm (Alg. 2 and 3) and the First-Order descriptor (Alg. 5). To identify specific defects, color, size, and texture descriptors are applied through Color and Size Segmentation (Alg. 4). The proposal was implemented and tested on a database, achieving an efficiency rate of 97.90% and a processing time of 17 to 25 ms per image, outperforming the algorithm of the project (Proy.PIPEA_134, 2013), which reached an efficiency of 91.06% and 43 ms of processing.

Keywords: automation; color spaces; detection and identification; first-order descriptor; computer vision

1. Introducción

En el campo de la agroindustria, muchos investigadores han intentado resolver el proceso de control de calidad que incluye el estado de maduración, detección e identificación de defectos y la clasificación en base al tamaño o color; basándose en las características externas del fruto como el color, tamaño, textura, forma o peso, para ser utilizado en el análisis de imágenes y la visión artificial (Qureshi et al., 2024; Ganiron, 2014; Narendra & Hareesh, 2014; Ripas-Mamani et al., 2016). Por ejemplo, la empresa Compac Sorting Equipment (Compac, 2016) dispone de máquinas de clasificación de manzanas, duraznos, peras, etc; estas se clasifican en base a su peso, tamaño y la detección de defectos; al igual que la empresa Vision Robotics Corporation (VRC) (VRC, 2016) que tiene un robot con visión artificial para la preparación del cultivo de viñedo; sin embargo estas máquinas no da detalles de cómo se obtiene la información, ya que sólo muestran los resultados.

El problema se hace más difícil cuando hay que determinar ciertas enfermedades o defectos en el producto, como hongos, manchas y gusanos en las frutas, imperfecciones y agujeros en las patatas, mangos o castañas, entre otros. Ganiron (2014) determina la calidad del mango (exportación, local o rechazado) a través de la detección de defectos que obtiene en base al tamaño, perímetro, redondez y porcentaje de defectos encontrados en el mango; otra manera de detectar defectos lo muestra Guzmán (2015) en el mejoramiento de imágenes digitales para la clasificación de defectos de granos de Café, a través del algoritmo basado en la teoría de Retinex multiescala con restauración de color (MSRCR) que mejora subjetivamente la visualización de imágenes con iluminación deficiente conservando las características de color y para clasificar los defectos utiliza descriptores de color y textura para las matrices de coocurrencia de color (CGLCM) que presenta las características relacionadas: al contraste (contraste), orden (energía) y la estadística descriptiva o también llamado descriptor de primer orden (correlación), junto con support vector machine (SVM); al mejorar la imagen la clasificación de defectos de café obtiene un 78.15% frente a un 70.92% sin pre-procesamiento; también se encuentra la detección de defectos visuales en castañas (Proy.PIPEA_134, 2013) aplicada en la base de datos cuyos defectos son cáscara, ojos, manchadas, rancias y desportillas, en el que se utilizó descriptor de color y tamaño para la identificación de los defectos mediante la segmentación por espacios de color (RGB, HSV, HLS, YCrCb, Lab, Luv y XYZ) y una umbralización multiumbral presentando una eficiencia de 91.8%. Por otro lado Mayhua (2015) utiliza descriptores de forma para la clasificación automática de defectos en la producción de tejidos en Lana de Alpaca de tipo punto (aguja rota, hueco, nudo y punto corrido) donde extrae las características de forma como: número de regiones defectuosas, relación entre el largo del defecto y el tamaño de la imagen, excentricidad, circularidad y solidez; estas características son las entradas que utiliza la red neuronal ARTMAP difusa donde el método de aprendizaje realizado es off-line, por lo que después de la fase de entrenamiento los pesos de la red neuronal quedaran fijos para la etapa de prueba, obteniendo un 92.77% en la clasificación de defectos de tejidos en lana de alpaca de tipo punto.

Tanto los trabajos de clasificación de defectos de granos de Café Verde (Guzmán, 2015) y de Tejidos en Lana de Alpaca (Mayhua, 2015) no distinguen la presencia o ausencia del defecto, ya que ellos trabajan con imágenes que presentan defectos y solo se realiza la identificación o clasificación; a diferencia de ellos la detección de defectos en castañas (Proy.PIPEA_134, 2013) identifica todos los defectos que puede presentar una castaña, en caso que no presente ningún defecto entonces lo clasifica como una castaña sin defectos. Por lo tanto, la propuesta presentada en esta tesis se enfoca en la detección e identificación de los defectos visuales en un objeto, implementado en la detección de defectos visuales en castañas mediante los descriptores de color, tamaño y textura aplicado a la base de datos del proyecto (Proy.PIPEA_134, 2013), donde los productos de exportación deben ser productos sin defectos (productos comerciales de primera calidad) y los que tienen defectos pueden ser comercializados después de un procedimiento específico, esos defectos pueden ser: ojos (son eliminados para obtener productos comercializables de segunda calidad), cáscara (son re-procesadas después de la eliminación de la

cáscara), desportilladas (productos comercializables de tercera calidad) y rancias-manchadas (son descartadas del consumo humano).

2. Materiales y métodos

2.1. Área de estudio y cobertura del estudio

Este estudio se fundamenta en la base de datos generada por el proyecto “Desarrollo de componentes mecatrónicos basados en visión artificial inteligente para la optimización del proceso de selección de castañas” (Proy.PIPEA_134, 2013), ejecutado por la Universidad Nacional de San Agustín en colaboración con la empresa El Bosque E.I.R.L, bajo la Cátedra CONCYTEC en TIC’s – UNSA (2010–2013). El algoritmo original del proyecto logró una eficiencia del 91.79% y un tiempo de procesamiento de 43 milisegundos por imagen.

Para la presente investigación, se utilizó dicha base de datos como muestra experimental, sirviendo como insumo para la validación del algoritmo propuesto, el cual mejora el desempeño en cuanto a precisión y eficiencia temporal en la detección de defectos visuales en castañas..

2.2. Tipo y diseño de investigación

Esta investigación se enmarca en un enfoque aplicado, dado que busca resolver un problema específico vinculado al control de calidad en la exportación de castañas mediante herramientas tecnológicas. El nivel es exploratorio, ya que investiga diversas técnicas de visión computacional para la identificación automática de defectos en frutos secos, aportando nuevos enfoques metodológicos al área. El diseño es experimental, ya que se manipulan variables independientes (imágenes de entrada y técnicas de procesamiento) para observar su efecto sobre variables dependientes (detección de defectos, tiempo de procesamiento). Se controlaron las condiciones experimentales para garantizar la validez de los resultados, permitiendo establecer relaciones causales entre la implementación algorítmica y la mejora en desempeño.

2.3. Metodología de investigación

Se empleó una metodología basada en los siguientes enfoques:

- Observación directa, para identificar las características visuales relevantes en la superficie de la castaña (color, textura, forma).
- Análisis estructurado, para evaluar los factores que afectan la eficiencia en la detección de defectos, considerando normativas como las establecidas por la FAO.
- Experimentación científica, mediante la cual se definieron las condiciones técnicas y computacionales necesarias para validar la propuesta algorítmica.

2.4. Técnicas e instrumentos de análisis

Técnicas

- Observación sistemática: para la identificación visual de defectos en castañas.
- Entrevistas estructuradas: dirigidas a miembros del equipo original del proyecto (Proy.PIPEA_134, 2013).
- Revisión documental: consulta de literatura científica, tesis, artículos académicos y fuentes web confiables para sustentar el estado del arte y la propuesta metodológica.

Instrumentos

- Base de datos del proyecto original, con imágenes de castañas con y sin defectos.
- Computadora portátil equipada con los entornos de desarrollo necesarios para ejecutar, evaluar y validar el algoritmo propuesto.

2.5. Viabilidad del estudio

Viabilidad técnica

La implementación fue desarrollada con herramientas de software libre, incluyendo OpenCV y C++ para el procesamiento de imágenes, y QtCreator como entorno de desarrollo para la interfaz gráfica. Se propuso un algoritmo que permite:

- Detectar defectos en función de la textura del objeto.
- Identificar defectos u objetos a partir de variaciones de color.

Viabilidad económica

El uso de software de código abierto redujo significativamente los costos asociados al desarrollo, eliminando la necesidad de licencias comerciales. Además, el algoritmo propuesto mejora el rendimiento en términos de tiempo de procesamiento, reduciéndolo de 43 ms (referencia del proyecto original) a 17–25 ms, dependiendo del caso. Esta mejora incrementa la productividad y sugiere viabilidad para una futura implementación en tiempo real.

3. Resultados y discusión

3.1. Base de datos

La base de datos utilizada durante los experimentos fue tomada del proyecto “Desarrollo de componentes mecatrónicos basados en visión artificial inteligente para la optimización del proceso de selección de castañas” (Proy.PIPEA_134, 2013; Database - Chestnut, 2017). Se utilizaron 1451 imágenes divididas en castañas sin defectos (258 imágenes) y castañas con defectos como: Cáscara (200 imágenes), ojos (250 imágenes), manchadas (303 imágenes), rancias (200 imágenes) y desportilladas (240 imágenes).

Las propiedades de las imágenes son:

- Imágenes a color
- Dimensión: 640 x 480 pixeles
- Formato “.jpg”

La base de datos (Tabla 1) está compuesta por imágenes de entrenamiento (40%) para poder obtener los parámetros óptimos para la detección e identificación de defectos y el 60% son Imágenes sin entrenamiento (Virgen) para la detección e identificación de defectos en castañas.

Tabla 1. Base de datos con imágenes entrenadas y sin entrenar

Tipo de Defectos	Total	Imágenes de Entrenamiento	Imágenes sin Entrenamiento
Castaña sin Defectos	258	103	155
Def. Ojos	250	100	150
Def. Cascara	200	80	120
Def. Manchada	303	121	182
Def. Rancia	200	80	120
Def. Desportillada	240	96	144
Total de Imágenes	1451	580	871

3.2. Implementación de la propuesta al mejoramiento del proceso de detección de defectos visuales en castañas

3.2.1. Preprocesamiento

El preprocesamiento consiste en la separación de las líneas de producción y determinar la presencia o ausencia de castaña. Para la separación de las líneas de producción, la imagen es

dividida en dos regiones de interés (ROI), es decir recorta la imagen en un tamaño definido por la posición (x,y) y la dimensión (ancho, alto) como muestra la Figura 1 obteniendo finalmente las dos líneas de producción.

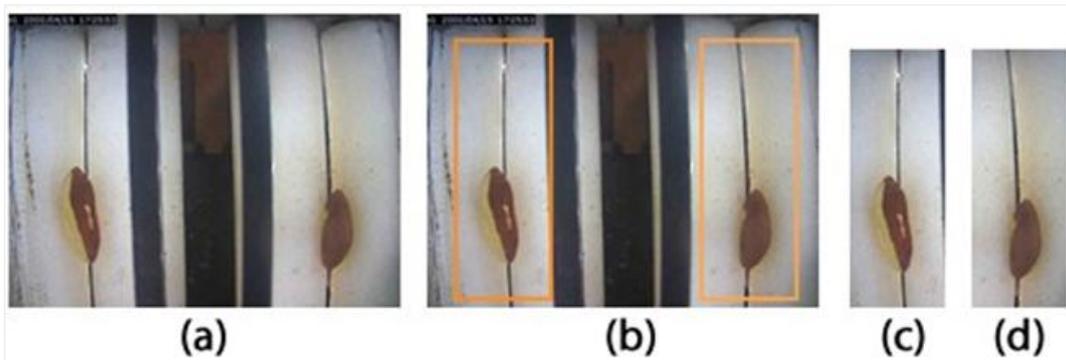


Figura 1. Separación de líneas de producción, (a) Imagen Original, (b) Regiones de interés (ROI), (c) Línea de producción 1 y (d) Línea de producción 2

Para determinar la presencia de Castaña en cada Línea de Producción, se realizó un descarte por áreas de la imagen umbralizada donde el área según la base de datos utilizada debía ser mayor de 2700 píxeles para determinar la presencia de la castaña. La Tabla 2 muestra el procesamiento para determinar si presenta o no castaña la línea de producción, este consiste en convertir la imagen en escala de gris y aplicar una umbralización con threshold binario invertido de 138, agregándole operadores morfológicos de: apertura (4), cierre (10) y erosión (2) para la eliminación de la línea entre los rodillos y de algunos ruidos; donde finalmente se obtiene el área mayor de la región de interés.

Tabla 2. Presencia de Castaña en cada Línea de Producción

ROI	Escala de Gris	Umbralización	Op. Apertura	Op. Cierre	Op. erosión	Área (px)
						8019px
						272px

3.3. Segmentación

Una vez que se determinó la presencia de una castaña en la línea de producción, se procede a segmentar la castaña; para este proceso se utiliza el espacio de color RGB, específicamente el canal R, el cual ayuda a diferenciar la castaña del resto de la imagen, como muestra la Figura 2b. Posteriormente se realiza una umbralización de threshold binario invertido con un umbral de 99, el cual separa mejor la castaña del fondo de la imagen (rodillos), hasta obtener la misma área que la castaña de la imagen original, como muestra la Figura 2c.

Sin embargo, se observa que presenta una línea entre los rodillos que no pudo ser eliminada durante la umbralización (Figura 2c), esta línea causa algunos errores debido al color oscuro que presenta, confundiendo con los defectos de “ojos o manchada”; para ello, se utilizó operadores morfológicos de: apertura (4), cierre (10) y erosión (2) utilizando elipse como elemento estructural (Figura 2d), la cual permite eliminar la línea ubicada entre los rodillos y rellenar regiones huecas.

Una vez obtenida la imagen umbralizada con poco o nada de la línea entre los rodillos, se realiza un descarte por áreas, donde se tomara aquellas áreas que se encuentra entre el área mínima de 2700 y un área máxima de 15000 eliminado así áreas fuera de este rango obteniendo la Figura 2e; posteriormente se realiza la fusión entre la imagen obtenida luego del descarte por áreas y la imagen original (Figura 2f) y finalmente se realiza un recorte del área como muestra la Figura 2g obteniendo así la imagen segmentada de la castaña. A continuación se muestran las Figuras 2 y 3 con el proceso de segmentación de la castaña.

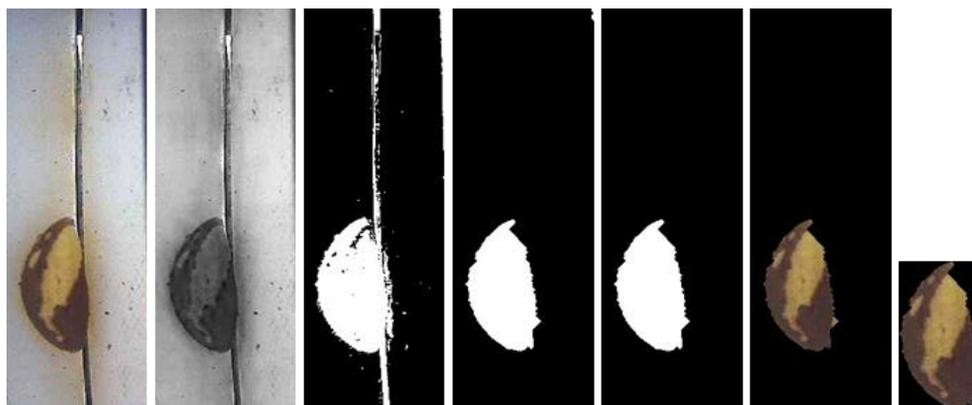


Figura 2. Segmentación de una Castaña sin defectos: (a) Imagen Original (RGB) (b) Canal R del espacio RGB, (c) Umbralización, (d) Operadores Morfológicos, (e) Descarte por Áreas (f) Imagen Fusionada (entre (e) y (a)) y (g) Imagen recortada que se convierte en la imagen Segmentada

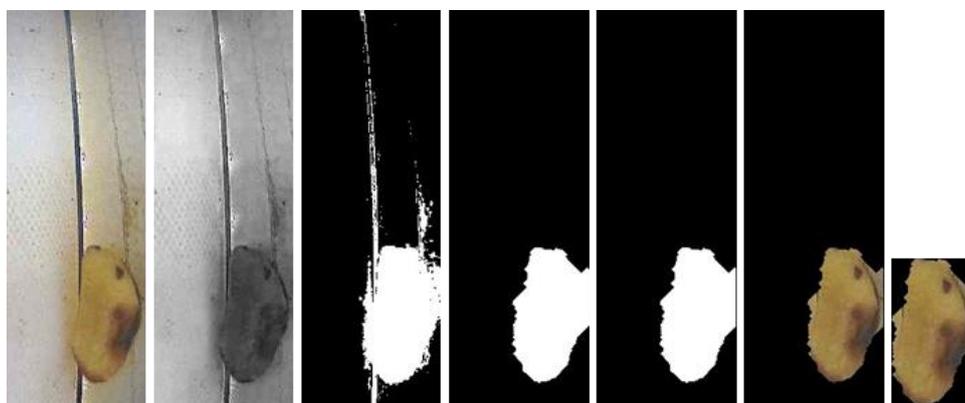


Figura 3. Segmentación de una Castaña con defecto “Ojos”: (a) Imagen Original (RGB) (b) Canal R del espacio RGB, (c) Umbralización, (d) Operadores Morfológicos, (e) Descarte por Áreas (f) Imagen Fusionada (entre (e) y (a)) y (g) Imagen recortada que se convierte en la imagen Segmentada

3.4. Presenta defectos el objeto

Este proceso determinó si la castaña presenta o no algún defecto, clasificándolo como Primera si no presenta defectos. En este proceso, la imagen segmentada de la castaña es dividida en dos regiones (epidermis y pulpa), posteriormente cada región es dividida en pequeños recuadros donde son analizados a través del Descriptor de Primer Orden (Alg. 5) de textura, indicando en que región se encuentra el defecto si es en la epidermis o en la pulpa de la castaña.

3.5. Divide el objeto en dos regiones (oscura y clara)

Este proceso separa la castaña en dos regiones la primera contendrá la parte oscura llamada Epidermis presenta un color café claro, café oscuro o negro; mientras que la otra región se llamará Pulpa presenta un color amarillo claro uniforme aunque en algunas áreas presenta una coloración de amarillo-anaranjado, amarillo-oscuro y también algunas áreas blancas.

Para dividir la castaña se aplica el algoritmo Dividir Objeto en dos Regiones (Alg. 1), el cual presenta los siguientes parámetros: mediana, umbral, erosiónRegClara y erosiónRegOscura, que son necesarios para poder dividir la castaña en dos regiones.

Se realizó pruebas para encontrar el valor de cada parámetro, para el parámetro del filtro de la mediana (mediana) se probó con los valores de (3, 5, 7, 9 y 11) donde el valor de 3 no muestra cambios con respecto a la escala de gris, hay que tener en cuenta que la castaña presenta defectos claros y oscuros de textura lisa o rugosa; sin embargo, los valores 5 y 7 muestran las regiones de los defectos más diferenciados siendo el valor 7 el mejor ya que se aprecia la textura lisa y rugosa; a diferencia de 9 y 11 se va perdiendo la textura rugosa y algunos defectos claros, como muestra la Figura 4.

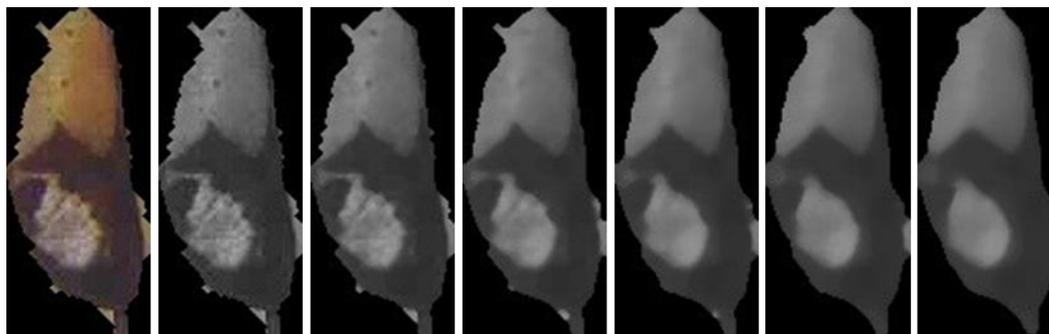


Figura 4. Parámetros para el Filtro Mediana (a) Segmentada, (b) Escala de gris, (c) Mediana = 3, (d) Mediana = 5, (e) Mediana = 7, (f) Mediana = 9 y (g) Mediana = 11

Para encontrar el parámetro del umbral óptimo (umbral) durante la división de la castaña en dos regiones, se realizó varias pruebas en 404 Imágenes de Entrenamiento (cáscara, ojos, manchada y castaña sin defecto) cuyo resultado de las estadísticas se muestran en la figura 5.5; se debe tener en cuenta que la región de la epidermis debe presentar un color café claro, café oscuro o negro ya que se encuentran los defectos de cáscara y ojos. Y la región de la pulpa presenta un color amarillo claro uniforme, amarillo-anaranjado, amarillo-oscuro o blanco ya que se encuentran los defectos de manchadas, rancia y desportillada.



Figura 5. Resultado de las pruebas realizadas para encontrar el umbral óptimo al dividir la Castaña en dos Regiones, donde el caso 3 obtuvo una mayor eficiencia que el resto, permitiendo eliminar los problemas en los defectos ojos claros, cáscara y manchada

La Tabla 3 muestra el resultado aplicando los umbrales propuestos de la figura 5.5, a través de estas estadísticas se puede observar cuando el umbral es 55 la región de la pulpa presenta regiones oscuras ya que la parte de la epidermis esta entre un color café claro y oscuro haciendo que esas partes claras queden junto con la región de la pulpa, provocando mayor cantidad de error (Caso 1 - 68.32%); si el umbral es 69 separa la región de la pulpa y epidermis sin embargo hay algunas castañas que presentan en la epidermis una coloración más clara confundiendo con los defectos de cáscara y manchada. Por otro lado, si el umbral es 93 separa mejor la epidermis de la pulpa ya que al aumentar el umbral permite que la región de la epidermis presente el defecto de cáscara (franjas de color café claro y oscura) y el defecto de manchadas solo aparece en la región de la pulpa, obteniendo como resultado 94.80%; si se aumenta el umbral a 107 se verá que al separar las regiones se va a perder el defecto de manchada ya que por su color se puede confundir con la epidermis.

Tabla 3. División de la Castaña en dos regiones (Epidermis y Pulpa), en función de los umbrales presentados

Imagen Segmentada	Región de la Epidermis y Pulpa de la Castaña			
	(umbral = 55)	(umbral = 69)	(umbral = 93)	(umbral = 107)

Para el parámetro de erosión de la epidermis y la pulpa de la castaña, se tiene que tener en cuenta el resultado de la umbralización, donde se observó que en el borde de las regiones de la pulpa se encuentran píxeles oscuros y al aplicar una erosión de 1 se elimina dicho borde; para la región de la epidermis cuyo color es un café claro, se observó que presenta en el borde píxeles oscuros y claros esto puede ser debido a la presencia de algún defecto como ojos, cáscara o desportillada, por ello se realiza una erosión de 2. Obteniendo finalmente los parámetros óptimos (mediana = 7, umbral = 93, erosionRegClara = 1 y erosionRegOscura = 2) para dividir la castaña en dos regiones, como muestra la Figura 6 y la Tabla 4.

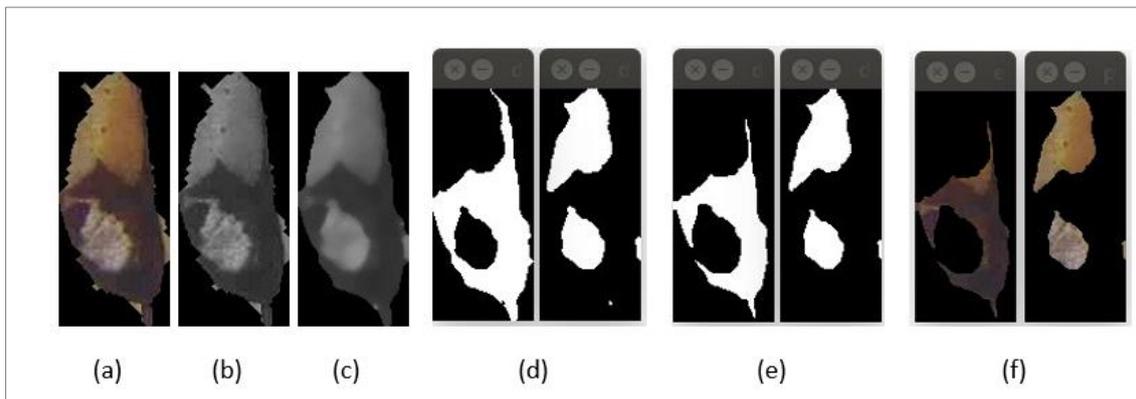
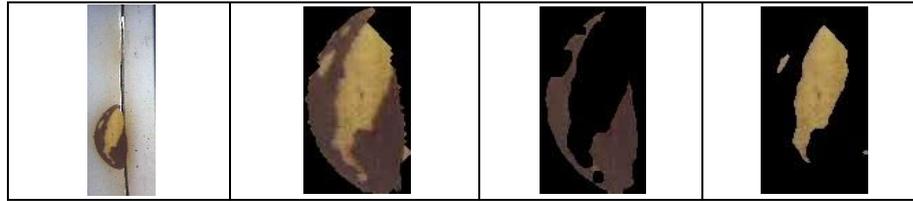


Figura 6. Divide la Castaña en dos Regiones (Epidermis y Pulpa): (a) Segmentada, (b) Escala de gris, (c) Filtro mediana, (d) Umbralización (epidermis y pulpa), (e) Erosión (epidermis y pulpa) y (f) Fusión (epidermis y Pulpa)

Tabla 4. Divide la Castaña en dos Regiones (Epidermis y Pulpa)

Imagen Original	Imagen Segmentada	Región de la Epidermis	Región de la Pulpa



3.5.1. Presenta defectos la región (oscura o clara)

Una vez dividida la castaña en dos regiones (epidermis y pulpa), cada región se divide en recuadros pequeños de dimensión "tamaño x tamaño". Se realizaron pruebas con diferentes dimensiones mostradas en la Figura 7a y se obtuvo que el tamaño (tamaño = 30) de la propuesta detecta mejor la totalidad del defecto como muestra la Figura 7b.

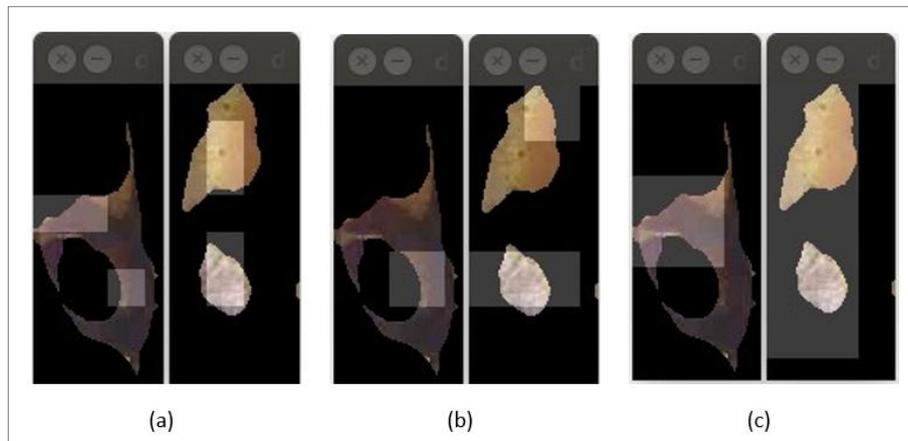


Figura 7. Dimensión del recuadro, donde (a) Dimensión de "20 x 20", (b) Dimensión de "30 x 30" y (c) Dimensión de "50 x 50"

La Figura 8 y el algoritmo Detectar Defecto (Alg. 2 y 3) muestran la región dividida en recuadros pequeños, los cuales son separados en 4 sectores:

- Sector A, presenta recuadros de "30 x 30"
- Sector B, presenta recuadros en el extremo derecho de tamaño "tright x 30"
- Sector C, presenta recuadros en el extremo inferior de tamaño "30 x tdown"
- Sector D, presenta un recuadro en la intersección entre el extremo derecho y el extremo inferior, de tamaño "tright x tdown"

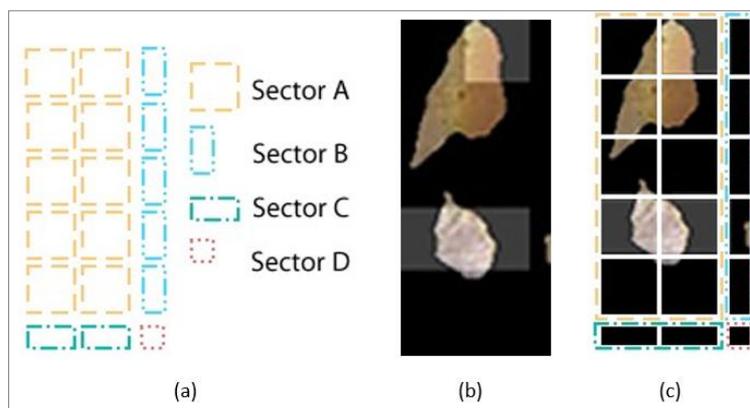


Figura 8. Divide la región en 4 sectores (A, B, C y D), donde cada recuadro es analizado por el Descriptor de Primer Orden, (b) Región de la Pulpa de la Castaña y (c) Región de la Pulpa de la Castaña dividida en 4 sectores (A, B, C y D)

El algoritmo Detectar Defecto (Alg. 2 y 3) divide la región en recuadros pequeños formando 4 sectores (A, B, C y D) donde cada recuadro tiene una dimensión de “tamaño x tamaño” cuyo valor es 30 y cada recuadro es analizado por el Descriptor de Primer Orden (Alg. 5) de Textura, si el recuadro presenta una cantidad de píxeles menor al porcentaje estimado (*porcentaje* = 20) entonces dicho recuadro es eliminado del análisis.

El Descriptor de Primer Orden permite interpretar la distribución de colores en una imagen; donde primero se obtiene la intensidad de gris de cada píxel de la imagen para adquirir la media/promedio y a partir de esta se puede hallar la varianza y finalmente la desviación estándar. Donde la desviación estándar va a determinar si presenta o no defecto en los recuadros analizados; llamando “defecto” a las diferentes texturas que puede presentar la imagen o presente cambios fuertes de color.

La castaña presenta dos regiones una epidermis (región oscura) y otra pulpa (región clara), por lo tanto, cada región debe verificar si presenta o no defectos a través del algoritmo Detectar Defecto (Alg.2 y 3) que utiliza el algoritmo de Descriptor de Primer Orden (Alg. 5), donde:

Región de la Epidermis:

Esta región presenta un color café claro y un poco oscuro, pero al presentar defectos como “Ojos y Cáscara” presentan un color café oscuro y negro (Figura 10); estos colores presentan intensidades más oscuras con respecto a la intensidad de color de la epidermis.

Esta región utiliza el algoritmo Detectar Defecto (Alg. 2 y 3) donde se define el *tipo* (σ_{tipo}) para la desviación estándar, esta región presenta diferencias mínimas en las intensidades del color ya que va de un color café claro (epidermis) a un café oscuro que luego se va tornando negro por el defecto de *Ojos*, además presenta textura por el defecto de *Cáscara* encontrando franjas alternadas de color café claro y café oscuro; debido a esto se utiliza el tipo 2 ($\sigma_{tipo} = 2$) para la desviación estándar, por lo tanto, si el valor de la desviación estándar obtenida (σ_{obt}) se encuentra dentro del umbral (σ_{min} y σ_{max}) entonces dicho recuadro presenta defecto.

La siguiente figura (Figura 9) muestra los resultados de las pruebas realizadas en 283 *Imágenes de Entrenamiento* (cáscara, ojos y castaña sin defecto) para encontrar los parámetros σ_{min} y σ_{max} para detectar los defectos en la región de la Epidermis de la Castaña, donde los parámetros que obtuvieron mayor precisión son $\sigma_{min} = 4.72$ y $\sigma_{max} = 8.51$ para la detección de los *defectos de ojos y cáscara* en la región de la Epidermis.

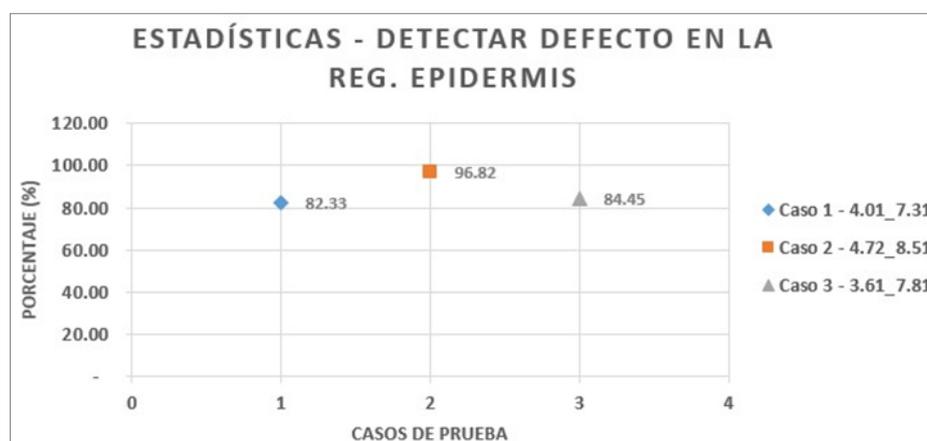


Figura 9. Resultado de las pruebas realizadas para encontrar defectos en la Región de la Epidermis de la Castaña

A continuación la Figura 10 muestra los valores que puede presentar la desviación estándar obtenida (σ_{obt}) en cada recuadro analizado de la región de la epidermis donde: si son menores de 4.72 son recuadros sin defecto, para detectar la presencia de ojos claros se tiene que encontrar entre 4.72 y 4.90; si se encuentran entre 4.91 y 6.71 va a presentar el defecto de cáscara, de igual manera si se encuentra entre 6.20 y 8.51 va presentar el defecto de ojos oscuros; de esta manera muestra la detección de los defectos de ojos claros, ojos oscuros y cáscara.

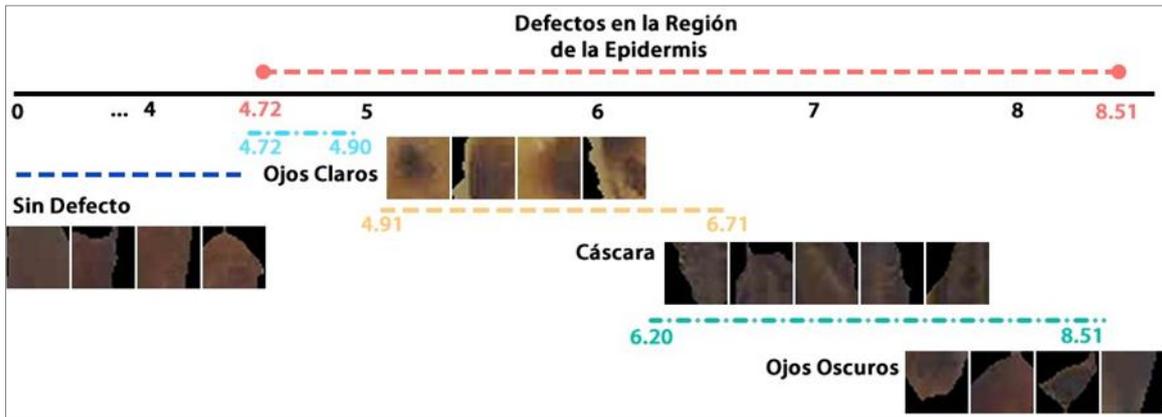


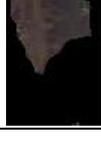
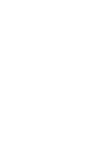
Figura 10. Recta de la Desviación Estándar en la Región de la Epidermis de la Castaña

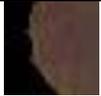
De esta manera se obtiene los parámetros óptimos: tamaño = 30, porcentaje = 20, $\sigma_{tipo} = 2$, $\sigma_{min} = 4.72$ y $\sigma_{max} = 8.51$ para detectar los defectos en la región de la epidermis de la castaña. La Tabla 5 muestra los resultados de la desviación estándar obtenida (σ_{obt}) de los defectos encontrados en la región de la epidermis y la Tabla 6 muestra el valor de la desviación estándar obtenida (σ_{obt}) de cada recuadro analizado por el algoritmo de Descriptor de Primer Orden (Alg. 5) durante la detección del defecto en la Región de la Epidermis, mostrando los recuadros analizados cuando presenta defectos (ojos claros, ojos oscuros y cáscara) y cuando no presenta.

Tabla 5. Detecta Defectos en la Región de la Epidermis de la Castaña

Imagen segmentada	Región de la Epidermis	Defecto en la región de la Epidermis	Num. Recuadro ($rect_{obt}$)	Media (μ_{obt})	Desviación Estándar obtenida (σ_{obt})
			11	65.8588	7.11528
			5	61.2234	6.67376
			-	-	-

Tabla 6. Muestra la presencia de defectos a través del Alg. De Descriptor de Primer Orden (Alg. 5)

Imagen Segmentada	Región de la Epidermis	Recuadro	Num. Recuadro ($rect_obt$)	Media (μ_obt)	Desviación Estándar obtenida (σ_obt)	Recuadro Detectado
			11	65.8588	7.11528	
			2	61.683	6.20646	
			5	61.2234	6.67376	
			4	58.6043	5.57995	
			7	63.7516	5.67855	
			2	76.4311	4.32498	
			5	70.9254	2.68371	
			10	62.3088	3.86452	
			5	71.1552	2.37799	
			7	68.8557	2.10547	

			10	71.3277	2.80724	
--	--	---	----	---------	---------	---

Región de la Pulpa:

Esta región presenta un color amarillo claro pero al presentar defectos como “Manchada, Rancia y Desportillada” presentan colores amarillo-anaranjado, amarillo-opaco y blanco (Figura 12); estos colores presentan intensidades más claras y un poco oscuras con respecto a la intensidad del color de la pulpa.

Esta región utiliza el algoritmo Detectar Defecto (Alg. 2 y 3) donde se define el tipo (σ_tipo) para la desviación estándar, esta región presenta colores de intensidades diferentes debido a los defectos que presenta como: manchadas y rancias tienen una intensidad más oscura que la intensidad de la pulpa y el defecto de desportillada presenta una intensidad mucho más clara que la intensidad de la pulpa; por lo tanto, se utiliza el tipo 1 ($\sigma_tipo = 1$) para la desviación estándar, si el valor de la desviación estándar obtenida (σ_obt) es mayor o igual que σ_min entonces dicho recuadro presenta defecto.

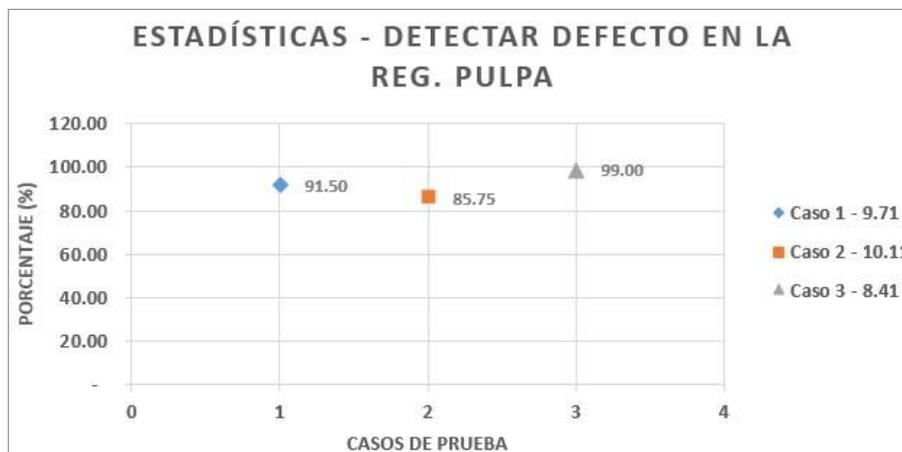


Figura 11. Resultado de las pruebas realizadas para encontrar defectos en la Región de la Pulpa de la Castaña

La Figura 11 muestra los resultados de las pruebas realizadas en 400 Imágenes de Entrenamiento (manchadas, rancias, desportillada y castaña sin defecto) para encontrar el parámetro σ_min para detectar los defectos en la región de la Pulpa de la Castaña, donde el parámetro $\sigma_min = 8.41$ obtuvo una eficiencia de 99.00% para la detección de los defectos de manchada, rancia y desportillada en la región de la Pulpa.

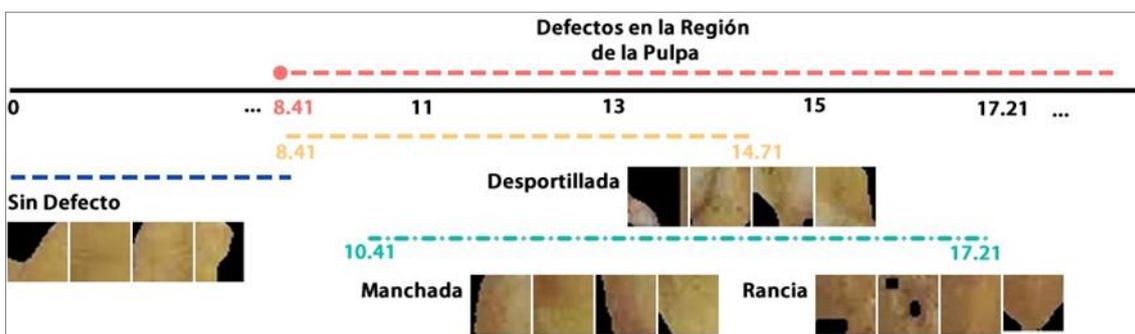


Figura 12. Recta de la Desviación Estándar en la Región de la Pulpa de la Castaña

La Figura 12 muestra los valores que puede presentar la desviación estándar obtenida (σ_{obt}) en cada recuadro analizado de la región de la Pulpa de la Castaña donde: si son menores de 8.41 son recuadros sin defecto, si se encuentran entre 8.41 y 14.71 va a presentar el defecto de desportilla, de igual manera si se encuentra entre 10.41 y 17.21 se puede encontrar los defectos de rancia y manchada; mostrando la detección de los defectos manchada, rancia y desportillada.

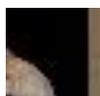
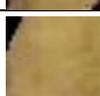
Donde los parámetros óptimos son: tamaño = 30, porcentaje = 20, $\sigma_{tipo} = 1$, $\sigma_{min} = 8.41$ para detectar los defectos en la región de la pulpa de la castaña. La Tabla 7 muestra los resultados de la desviación estándar obtenida (σ_{obt}) de los defectos encontrados en la región de la pulpa y la Tabla 8 muestra el valor de la desviación estándar obtenida (σ_{obt}) de cada recuadro analizado por el algoritmo de Descriptor de Primer Orden (Alg. 5) durante la detección del defecto en la Región de la Pulpa, mostrando los recuadros analizados cuando presenta defectos (manchada, rancia y desportillada) y cuando no presenta.

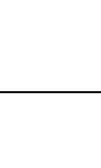
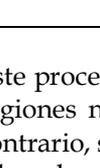
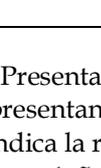
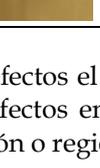
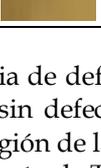
Tabla 7. Detecta Defectos en la Región de la Pulpa de la Castaña

Imagen Segmentada	Región de la Pulpa	Defecto en la Región de la Pulpa	Num. Recuadro ($rect_{obt}$)	Media (μ_{obt})	Desviación Estándar obtenida (σ_{obt})
			-	-	-
			1	115.664	10.6359
			8	121.413	13.9079
			11	143.021	11.393
			14	147.97	10.4556
			11	113.823	12.1659
			14	118.74	11.0029
			15	124.114	10.0227
			17	119.514	9.732
			5	136.391	12.6349
			7	136.647	16.8292
			8	133.065	16.9479
			10	119.927	12.1645

Tabla 8. Muestra la presencia de defectos a través del Alg. De Descriptor de Primer Orden (Alg. 5)

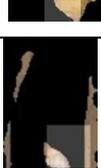
Imagen Segmentada	Región de la pulpa	Recuadro	Num. Recuadro ($rect_{obt}$)	Media (μ_{obt})	Desviación Estándar obtenida (σ_{obt})	Recuadro Detectado
			4	127.4	16.4276	

			7	117.564	16.3022	
			8	121.413	13.9079	
			11	143.021	11.393	
			5	109.778	10.4544	
			8	109.71	10.1895	
			5	117.576	10.8546	
			8	125.076	17.8303	
			5	136.391	12.6349	
			7	136.647	16.8292	
			8	133.065	16.9479	
			5	144.724	8.03289	

			8	125.076	17.8303	
			5	141.231	7.75409	
			6	155.599	5.75075	
			8	135.606	7.64834	

Este proceso (Presenta Defectos el Objeto) determina la presencia o ausencia de defectos, si las regiones no presentan defectos entonces se clasifican como una Castaña sin defecto; en caso contrario, se indica la región o regiones que presentan defectos, si es en la región de la epidermis o la pulpa de la castaña para su posterior identificación de defectos como muestra la Tabla 9. Esto permite disminuir el tiempo de procesamiento ya que solo se buscará en la región que presenta defecto evitando detectar todos los defectos a menos que ambas regiones presenten defectos.

Tabla 9. Muestra la presencia o ausencia de defectos en cada Región (Epidermis o Pulpa)

Imagen Segmentada	Región de la Epidermis	Región de la Pulpa	Defecto en Epidermis	Defecto en Pulpa	Presenta Defecto? (Num. Recuadro (<i>rect_obt</i>), Media (μ_{obt}) y Desviación Estándar (σ_{obt}))
					Epidermis: (1) 4, 58.6043, 5.57995; (2) 5, 54.4603, 5.03304; (3) 7, 63.7516, 5.67855 y Pulpa: (1) 2, 118.543, 10.0783
					Epidermis: (1) 2, 61.683, 6.20646; (2) 5, 61.915, 4.8755 y Pulpa: (1) 12, 127.007, 11.5337; (2) 14, 126.717, 10.7814
					Epidermis: (1) 7, 69.0287, 4.86691; y Pulpa: (1) 8, 125.076, 17.8303

					Pulpa: (1) 4, 127.4, 16.4276; (2) 7, 117.564, 16.3022; (3) 11, 128.15, 10.8674; (4) 14, 114.69, 11.3762
					-
					-

3.5.2. Identificación de Defectos por cada Región

Para la identificación de defectos por cada región de la Castaña se observa que la región de la Epidermis presenta un color café claro y un poco oscuro, pero al presentar defectos como “Ojos y Cáscara” presentan un color café oscuro y negro; mientras que la región de la Pulpa presenta un color amarillo claro uniforme, pero al presentar defectos como “Manchada, Rancia y Desportillada” presentan colores como amarillo-anaranjado, amarillo-opaco y otras regiones blancas. Es por ello, que para detectar los defectos se realiza a través de las características externas de la castaña como el color, tamaño y textura de los defectos, para ello se utiliza dos algoritmos implementados en la propuesta los cuales son: Segmentación por Color y Tamaño (Alg. 4) y Detectar Defecto (Alg. 2 y 3) que utiliza el algoritmo Descriptor de Primer Orden (Alg. 5).

Región de la Epidermis de la Castaña:

1. Defecto 1: Ojos

Estos defectos son malformaciones de forma callosa dentro de la castaña y se manifiestan como puntos o manchas oscuras (presenta una coloración oscura (café oscuro) que va llegando al color negro) de apariencia circular. Por lo tanto, serán “reparados”, es decir se eliminará el ojo y se convertirá en producto comercializable de segunda.

Sin embargo, existen dos tipos de ojos, los “ojos claros” de color café oscuro que se encuentra en la pulpa de la castaña y los “ojos oscuros” que presentan una coloración oscura que va llegando a un color negro que se presenta en la epidermis de la castaña. Por lo tanto, para este defecto se va a utilizar el algoritmo de Segmentación por Color y Tamaño (Alg. 4), donde se buscará un canal de un espacio de color que resalte mejor al defecto; para ello se muestra la tabla 5.10 con los espacios de color YCrCb, HLS y HSV y sus canales Cb, S y S respectivamente; se observa que el canal S del espacio de color HLS y HSV presentan una intensidad oscura en la región del defecto, permitiendo así que dicho defecto se diferencie del resto de la imagen.

Tabla 10. Detección de defectos “Ojos”, búsqueda del Espacio y Canal

Defecto	Espacio / Canal	Segmentada	Defecto en Epidermis	Espacio	Canal	Segmentada	Defecto en Epidermis	Espacio	Canal
---------	-----------------	------------	----------------------	---------	-------	------------	----------------------	---------	-------

Ojos Claros	YCrCb - Cb								
	HLS - S								
	HSV - S								
Ojos Oscuros	YCrCb - Cb								
	HLS - S								
	HSV - S								

Seguidamente, se realiza una umbralización de la imagen con un umbral mínimo (u_{min}), umbral máximo (u_{max}) y un tipo de umbral (u_{tipo}) que son obtenidos de manera experimental para cada uno de los espacios de color y su canal seleccionado anteriormente; esto va a permitir umbralizar la región del defecto y determinar qué espacio de color (HLS (S) o HSV (S)) conviene utilizar. La tabla 5.11 muestra el canal S del espacio de color HLS que presenta una coloración oscura en la región del defecto haciendo que sobre todo en ojos claros se pierda el defecto con la intensidad de la región de la epidermis de la castaña y el canal S del espacio de color HSV resalta mejor los defectos tanto de ojos claros como oscuros, ya que la intensidad de la epidermis es oscura y la intensidad del defecto es aún más oscura; finalmente se realiza un descarte de áreas eliminando áreas pequeñas como ruidos o muy grandes como brillos o sombras, considerando áreas entre un área mínima (a_{min}) y un área máxima (a_{max}) de píxeles, determinando así la identificación de defectos de ojos claros y oscuros.

Tabla 11. Detección de defectos “Ojos”, búsqueda de la Umbralización y Descarte por Áreas

Defecto	Espacio / Canal	Datos de Threshold	Canal	Umbralización	Descarte por Áreas	Canal	Umbralización	Descarte por Áreas
Ojos Claros	YCrCb - Cb	134 - 140 - MULTI_THRESHOLD						
	HLS - S	2 - 39 - MULTI_THRESHOLD						
		5 - 92 - MULTI_THRESHOLD						
Ojos	YCrCb - Cb	134 - 140 - MULTI_THRESHOLD						
	HLS - S	2 - 39 - MULTI_THRESHOLD						
	HSV - S	5 - 92 - MULTI_THRESHOLD						

La Figura 13 muestra los resultados de las pruebas realizadas en 100 Imágenes de Entrenamiento, para encontrar los parámetros óptimos para detectar los defectos de “ojos”, de los 3 casos presentados en las tablas 5.10 y 5.11, el caso 3 del espacio de color HSV obtuvo una eficiencia de 97.00% en la detección de los defectos de ojos claros y oscuros en la región de la Epidermis, cuyos parámetros son: espacio = HSV, canal = S, para la umbralización son $u_{min} = 5$, $u_{max} = 92$ y $u_{tipo} = multi_thresh$, con un área $a_{min} = 30$ hasta $a_{max} = 5700$ de pixeles.



Figura 13. Resultado de las pruebas realizadas para identificar el defecto “Ojos” en la Región de la Epidermis de la Castaña, donde el caso 3 del espacio de color HSV obtuvo una mayor eficiencia que el resto

2. Defecto 2: Cáscara

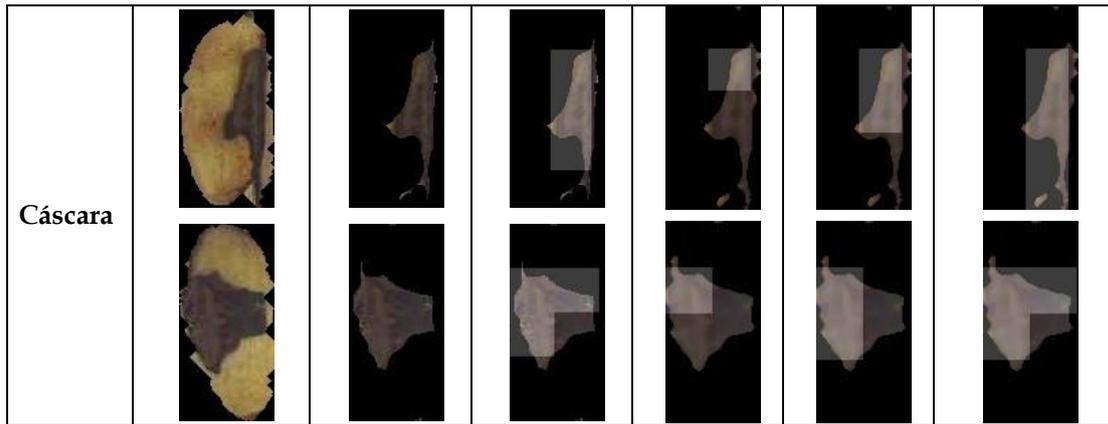
Son castañas que no fueron bien peladas y que en su superficie presenta una porción de cáscara, con una textura gruesa rugosa y su coloración es café claro y oscuro que en muchos casos se puede confundir con la epidermis de la castaña. Por lo tanto, se retirará el exceso de cáscara para que luego sea procesado nuevamente (re-procesados).

El defecto de cáscara presenta una textura rugosa en forma de franjas oscuras y claras alternadas de coloración café oscuro y claro, debido a esto se hace difícil segmentar ambos colores, ya que se identificará los defectos de ojos oscuros; por lo tanto, no se utilizará el algoritmo de Segmentación por Color y Tamaño (Alg. 4) sino por el descriptor de textura con el algoritmo Detectar Defecto (Alg. 2 y 3) que utiliza el algoritmo de Descriptor de Primer Orden (Alg. 5). Donde se agrega un filtro de mediana (mediana) para que pueda suavizar la textura y no pueda confundirse con los defectos de ojos oscuros, sin embargo al aplicar este filtro aún conserva sus franjas alternadas.

Debido a la textura de las franjas oscuras y claras de la cáscara presenta diferencias mínimas en las intensidades de gris de cada pixel del defecto; es por ello por lo que se utilizará el tipo 2 ($\sigma_{tipo} = 2$) donde la desviación estándar obtenida (σ_{obt}) se encuentra entre una desviación estándar mínima (σ_{min}) y máxima (σ_{max}), de esta manera no podrá confundirse con los defectos de ojos oscuros. Dichos parámetros son determinados de manera experimental en el algoritmo Detectar Defecto (Alg. 2 y 3), los valores que estén entre este umbral representaran al defecto de cáscara, como muestra la Tabla 12 donde primero muestra si la región de la epidermis presenta defecto y posteriormente verifica si el defecto que presenta es “cáscara”.

Tabla 12. Detección de defectos “Cáscara”, a través del algoritmo Detectar Defecto (Alg. 2 y 3) que utiliza el descriptor de Primer Orden (Alg. 5)

Defecto	Segmentada	Región Epidermis	Defecto en Epidermis	Defecto Cáscara ($\sigma_{min}-\sigma_{max}$)		
				4.91 - 5.04	4.91 - 5.31	4.91 - 5.51



3. Defecto 3: Manchada

Este defecto presenta áreas de color amarillo-anaranjado y amarillo-oscuro, es tolerable si el área es 20% de la superficie; sin embargo, estas castañas son descartadas del consumo humano.

Existen dos tipos de defecto de manchadas las “manchadas claras” de color amarillo-anaranjado y “manchadas oscuras” que presentan una coloración amarillo-oscuro. Para este defecto se va a utilizar el algoritmo de Segmentación por Color y Tamaño (Alg. 4), donde se buscara un canal de un espacio de color que resalte mejor el defecto en ambos tipos de manchadas; para ello se muestra la Tabla 13 con los espacios de color HSV, XYZ y Luv y sus canales S, X y L respectivamente, que resaltan mejor al defecto de manchadas tanto en manchas claras y oscuras; se puede observar que los espacios de color XYZ (X) y Luv (L) presentan una intensidad oscura en la zona del defecto, permitiendo así que dicho defecto se diferencie del resto de la imagen, el espacio de color HSV (S) presenta problemas en los defectos de manchadas claras; sin embargo el canal X del espacio de color XYZ presenta una intensidad más oscura en la zona del defecto que el canal L del espacio Luv, esto se puede apreciar más en manchas oscuras.

Tabla 13. Detección de defectos “Manchada”, búsqueda del Espacio y Canal

Defecto	Espacio / Canal	Segmen- tada	Defecto en Pulpa	Espacio	Canal	Segmen- tada	Defecto en Epidermis	Espacio	Canal
Manchadas Claras	HSV - S								
	XYZ - X								
	Luv - L								

Manchadas Oscuras	HSV - S								
	XYZ - X								
	Luv - L								

4. Defecto 4: Rancia

Las castañas rancias van adquiriendo un color amarillo-opaco que va tomando un color manteca en más del 50% de la superficie, se puede originar por el tiempo de almacenamiento o por condiciones no adecuadas como exceso de calor. Por lo tanto, son descartadas del consumo humano al igual que el defecto de manchadas.

Este defecto presenta una textura lisa y también rugosa, si se utiliza el algoritmo Detectar Defecto (Alg. 2 y 3) no va a tener buenos resultados, debido a que la castaña rancia es totalmente lisa o rugosa por lo que no hay dos texturas diferentes para comparar; es por ello que va a realizar mediante el descriptor de color utilizando el algoritmo de Segmentación por Color y Tamaño (Alg. 4), donde se buscó un canal de un espacio de color que resalte mejor el defecto; para ello se muestra la Tabla 14 los espacios de color HSV y XYZ y sus canales S y X respectivamente; se puede observar que el canal X del espacios de color XYZ muestra mejor el área rancia ya sea que presente una textura lisa o un poco rugosa, a diferencia del canal S del espacio HSV muestra buenos resultados en textura lisa pero algunos defectos de textura rugosa no son detectados.

Tabla 14. Detección de defectos “Rancias”, búsqueda del Espacio y Canal

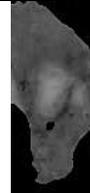
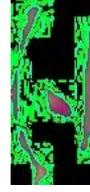
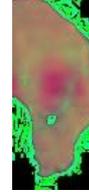
Defecto	Espacio / Canal	Segmen- tada	Defecto en Pulpa	Espacio	Canal	Segmen- tada	Defecto en Pulpa	Espacio	Canal
Rancia	HSV - S								
	XYZ - X								

5. Defecto 5: Desportillada

Este defecto presenta áreas blancas productos del roce entre ellas o factores mecánicos; son comercializados a menor valor pues siguen siendo aptos para el consumo humano pero estéticamente se les considera de menor valor; es por ello por lo que es un producto comercializable de tercera.

De igual manera, para este defecto se va a utilizar el algoritmo de Segmentación por Color y Tamaño (Alg. 4), donde se utilizarán los espacios RGB, HSV y XYZ y sus canales R, S y Z respectivamente como muestra la Tabla 15, donde los canales R y Z muestran intensidades claras en el defecto y el canal S muestra una intensidad oscura.

Tabla 15. Detección de defectos “Desportillada”, búsqueda del Espacio y Canal

Defecto	Espacio / Canal	Segmentada	Defecto en Pulpa	Espacio	Canal	Segmentada	Defecto en Pulpa	Espacio	Canal
Desportillada	RGB - R								
	HSV - S								
	XYZ - Z								

3.6. Descripción de la interfaz de usuario

El diseño de la propuesta fue desarrollado en el IDE Qt Creator para la interfaz de usuario y como framework de procesamiento de imágenes se utilizó OpenCV con el lenguaje de programación de C++. La interfaz de usuario desarrollada presenta dos procesos: Proceso Automático, donde se realiza el procesamiento en sí de las castañas y un Proceso de Calibración Semi-automática, donde obtenemos los parámetros para realizar dicho procesamiento; las cuales se describen a continuación.

- Proceso automático

El proceso automático es el procesamiento en sí de las castañas u otro objeto (detección de defectos), con los parámetros obtenidos del proceso de calibración semi-automática. Este proceso automático muestra en su interfaz la detección de los defectos visuales en la castaña, donde a partir de la imagen ingresada (Sección A), se realiza una separación de las líneas de producción (Sección B), posteriormente se observa la segmentación de la castaña (Sección C), seguidamente de la detección de defectos en ambas regiones (Sección D) y finalmente muestra la identificación de los defectos encontrados (Sección E), para su posterior clasificación (Sección F).



Figura 14. Interfaz de Usuario para la detección e identificación de defectos visuales en Castañas (Automático). Muestra la identificación del defecto de Ojos

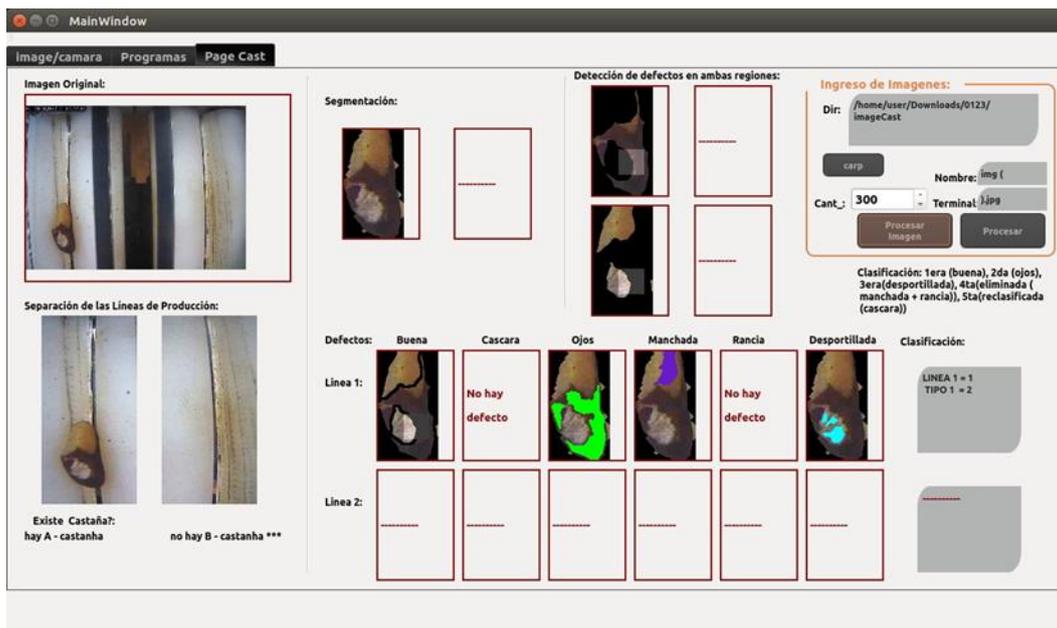


Figura 15. Interfaz de Usuario para la detección e identificación de defectos visuales en Castañas (Automático). Muestra la identificación de los defectos de: Ojos, Manchada y Desportillada

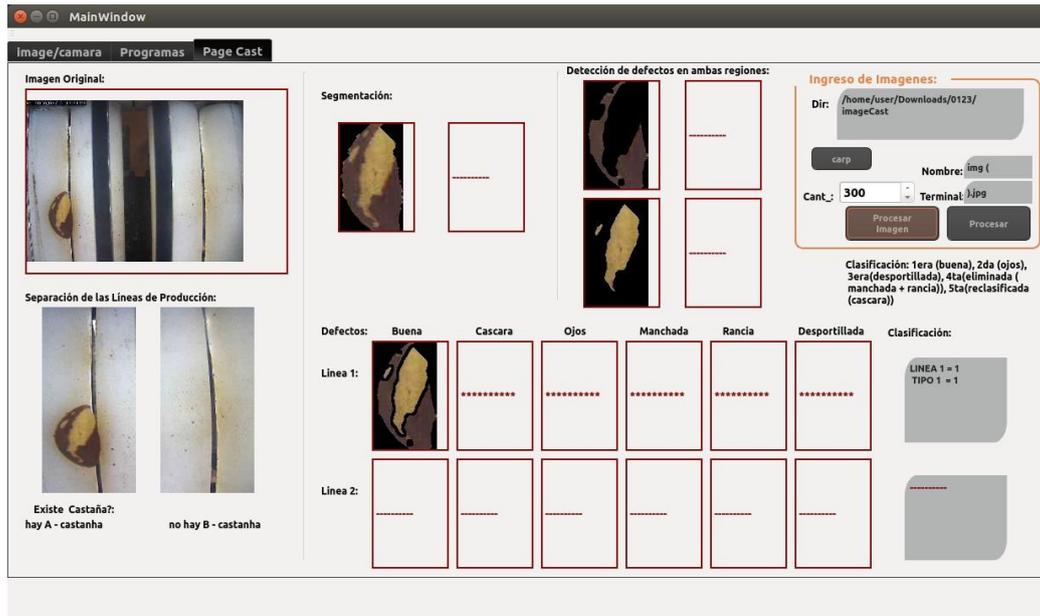


Figura 16. Interfaz de Usuario para la detección e identificación de defectos visuales en Castañas (Automático). Muestra una castaña sin defectos

- Proceso de Calibración Semi-automática

Para segmentar un objeto en este caso la castaña y poder encontrar los parámetros para cada defecto, se realiza a través de un proceso de calibración semi-automática por medio de una inspección visual de la persona, esta calibración semi-automática comprende:

1. Dividir el Objeto en dos Regiones (Oscuro y Claro) En este caso dividimos a la castaña en dos regiones (Epidermis y Pulpa), utilizando el algoritmo Dividir Objeto (Alg. 1) a través de una umbralización presente en la barra de desplazamiento (umbral = 93); donde si son mayores de 93 se selecciona como región de pulpa y el resto como epidermis.

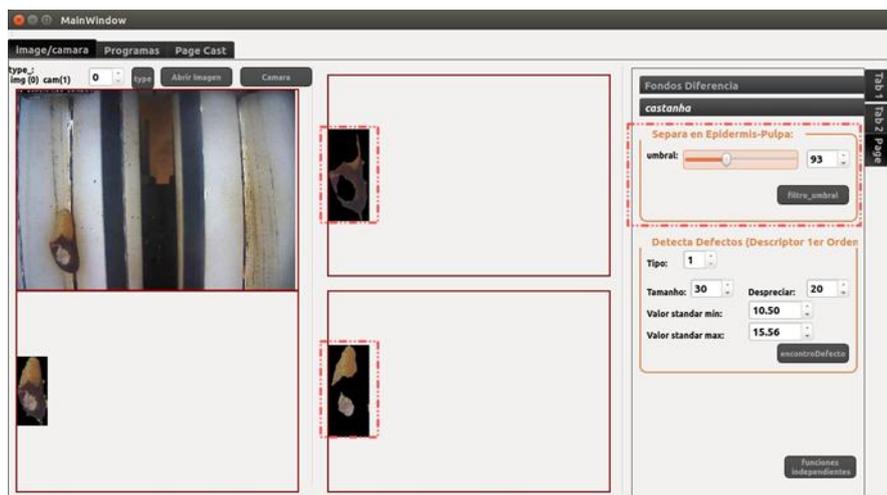


Figura 17. Interfaz de Usuario para Dividir la Castaña en dos Regiones (Epidermis y Pulpa), siendo este caso de una castaña con defecto "Ojo, Manchada y Desportillada"

2. Detectar la presencia o ausencia de defectos en cada región (Oscura o Clara). Para determinar la presencia o ausencia de los defectos en cada región se realiza a través del descriptor de textura,

utilizando el algoritmo de Detectar Defecto (Alg. 2 y 3) que utiliza el Descriptor de Primer Orden (Alg. 5).

- Región de Epidermis: A través de un rango mínimo ($\sigma \text{ min} = 4.72$) y máximo ($\sigma \text{ max} = 8.51$) de la desviación estándar, si sobrepasan este rango, entonces presenta defecto de ojos y cáscara, mostrando el recuadro con otro color.

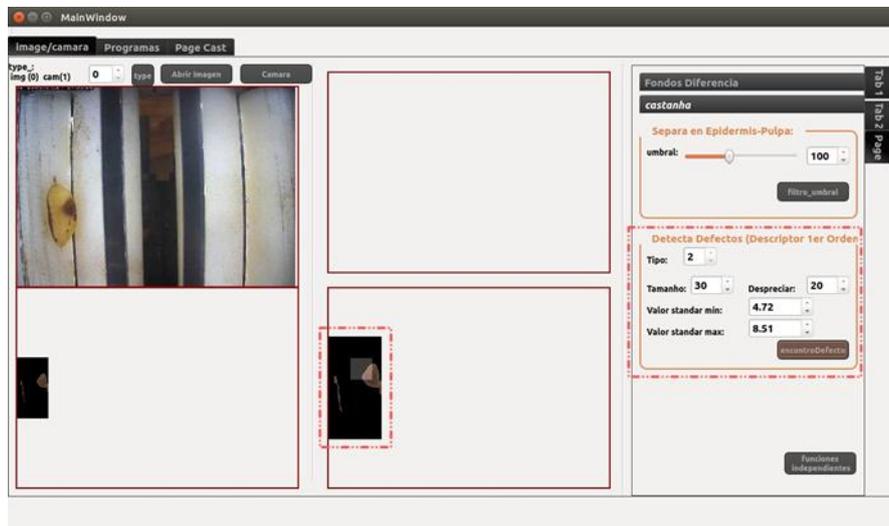


Figura 18. Interfaz de Usuario para Detectar la presencia de defectos en la Región de la Epidermis de la Castaña

- Región de Pulpa: A través de un valor de la desviación estándar mínimo ($\sigma \text{ min} = 9.71$), si sobrepasa este valor entonces presenta defectos de manchada, rancia o desportillada.

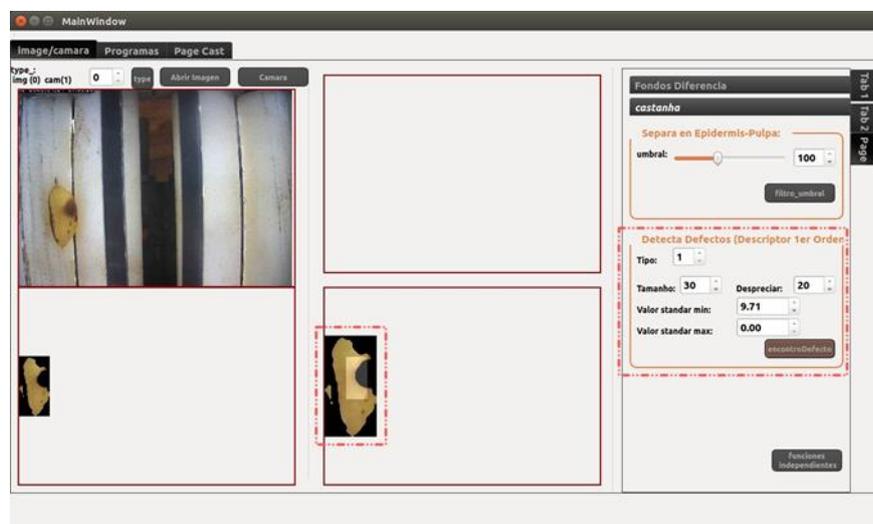


Figura 19. Interfaz de Usuario para Detectar la presencia de defectos en la Región de la Pulpa de la Castaña

3. Identificar una variedad de colores (claros y oscuros) y tamaños

Consiste en seleccionar cada uno de los canales de un espacio de color determinado (RGB, HSV, HLS, YCrCb, Lab, Luv, XYZ) para poder identificar un canal de un espacio de color determinado que resalte mejor dicho defecto detectando intensidades claras, intensidades oscuras o diferentes al resto de la imagen a través de una inspección visual; después se procede a identificar los parámetros de la umbralización que permita que los píxeles que se encuentren entre dichos

umbrales sean considerados como parte del defecto, y finalmente se realiza un descarte por áreas. Ya que este proceso es semi-automático, se va a ir actualizando automáticamente y mostrando los resultados con cada cambio que se realice; es por ello, que optimizamos los parámetros para un defecto determinado y se obtiene en un menor tiempo. El proceso automático es el procesamiento en sí en el caso de las castañas, con los parámetros obtenidos del proceso de calibración semi-automática.

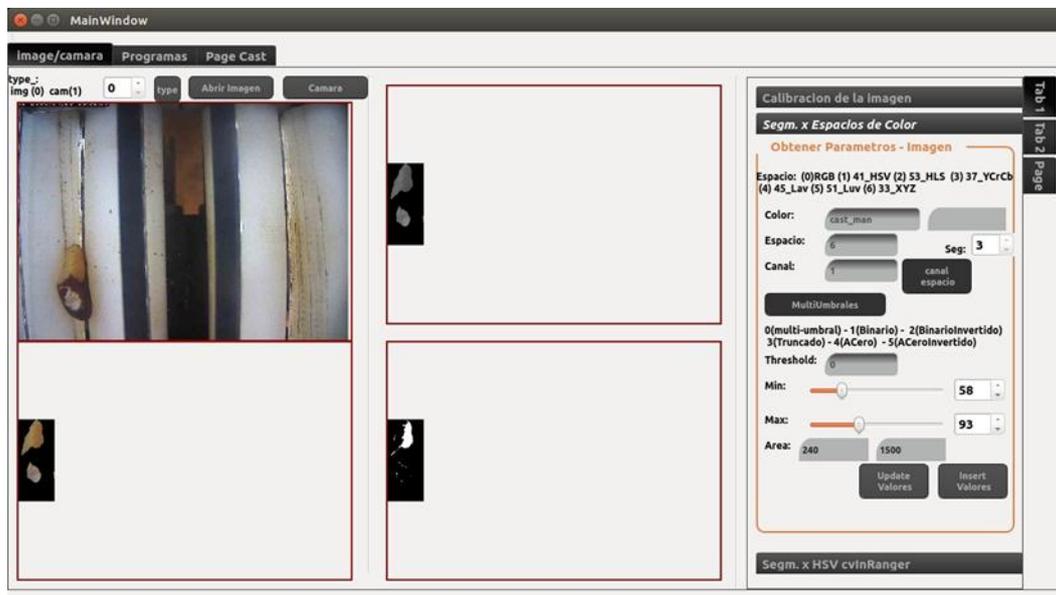


Figura 20. Interfaz de Usuario para la Calibración Semi-automática para la Segmentación por Color y tamaño. Siendo en este caso la detección del defecto "Manchada"

4. Conclusiones

La investigación evidenció que al dividir la castaña en dos regiones se logra superar las deficiencias en la identificación de defectos como ojos claros, cáscaras y manchas, ya que este enfoque permite optimizar la búsqueda de anomalías por zonas específicas y mejorar el tiempo de procesamiento respecto al algoritmo inicial del proyecto, dado que no es necesario detectar todos los defectos, sino únicamente en la región donde se presentan. Para la detección de la presencia o ausencia de defectos, el sistema se basa en el descriptor de textura de cada región, proponiendo el uso del algoritmo Detectar Defecto (Alg. 2 y 3), sustentado en el Descriptor de Primer Orden (Alg. 5), lo cual permite indicar con precisión en qué región se encuentra la anomalía, evitando así la necesidad de identificar cada defecto de manera individual para determinar si una castaña está libre de imperfecciones. Asimismo, la identificación de los defectos visuales se efectúa mediante descriptores de color, tamaño y textura, aplicando el algoritmo de Segmentación por Color y Tamaño (Alg. 4), que utiliza espacios de color y técnicas de umbralización para reconocer defectos claros u oscuros de textura lisa, mientras que el algoritmo Detectar Defecto se aplica en los casos de textura rugosa, obteniendo así tanto la posición central como el área de los defectos identificados. Por otro lado, los espacios de color empleados permiten reconocer una amplia variedad cromática a través de los canales de diferentes modelos de color utilizados en el algoritmo de Segmentación, mientras que el Descriptor de Primer Orden aporta un análisis textural basado en la desviación estándar para determinar la presencia de defectos en cada región, siendo este un insumo fundamental para el algoritmo Detectar Defecto. Finalmente, los estudios y pruebas desarrollados en este estudio demostraron que es posible detectar e identificar automáticamente los defectos en la castaña a partir de sus características externas, color, tamaño y textura, alcanzando una tasa de eficiencia del 97,90% en pruebas

realizadas con imágenes sin entrenamiento (60% de la base de datos) y un tiempo de procesamiento de apenas 25 ms, validando así la efectividad y viabilidad del sistema propuesto.

Financiamiento

Ninguno.

Conflicto de intereses

La autora declara no tener ningún conflicto de intereses.

Contribución de autores

C. Cervantes-Jilaja: Conceptualización, Curación de datos, Análisis formal, Investigación, Metodología, Administración del proyecto, Software, Validación, Visualización, Redacción - borrador original.

Referencias bibliográficas

- Compac. (2016). *Compac Sorting Equipment, Technology for Apples. Apple graders, sizers and sorting machines with electronic weight sizing plus quality & blemish grading*. Computerized grading of Apples and Apple packing equipment and solutions. <http://www.compacsort.com>
- Database - Chestnut. (2017). *Database Chestnut - LARVIC, Research Project: Development of mechatronic components based on intelligent artificial vision for the optimization of the selection process of chestnuts*. Machine Learning Repository. <https://www.dropbox.com/sh/1u7c8hhay5vxlhz/AABdLm4-cyLaODLiIosI0-7-a?dl=0>
- Ganiron, T. J. (2014). Size Properties of Mangoes using Image Analysis. *International Journal of Bio-Science and Bio-Technology*, 6(2), 31-42. <https://doi.org/10.14257/ijbsbt.2014.6.2.03>
- Guzmán, R. (2015). *Mejoramiento de Imágenes Digitales para la Clasificación de Defectos de Granos de Café Verde*. Universidad Nacional de San Agustín.
- Mayhua, A. G. (2015). *Clasificación Automática de Defectos en la Producción de Tejidos en Lana de Alpaca: Un Enfoque Utilizando Redes Neuronales y Descriptores de Forma*. Universidad Nacional de San Agustín.
- Narendra, V. G., & Hareesh, K. S. (2014). Computer Vision System to Estimate Cashew Kernel (White Wholes) Grade Colour and Geometric Parameters. *Journal of Food Processing & Technology*, 05(06). <https://doi.org/10.4172/2157-7110.1000336>
- Proy.PIPEA_134. (2013). *Proyecto de Investigación: Desarrollo de componentes mecánicos basados en visión artificial inteligente para la optimización del proceso de selección de castañas*. Contrato PIPEA-134-2010 y ejecutado por la Universidad Nacional de San Agustín y la Empresa El Bosque E.I.R.L. Catedra CONCYTEC en TIC's - UNSA.
- Qureshi, W. S., Satoh, S., Dailey, M. N., & Ekpanyapong, M. (2024). Dense segmentation of textured fruits in video sequences. *IEEE Xplore*, 12, 193263-193283. <https://ieeexplore.ieee.org/document/7294963>
- Ripas-Mamani, R., Cervantes-Jilaja, C., Rosas-Cuevas, Y., Patino-Escarcina, R. E., & Barrios-Aranibar, D. (2016). A Semi-Automated Approach for Recognizing Moving Targets Using a Global Vision System. *2016 XIII Latin American Robotics Symposium and IV Brazilian Robotics Symposium (LARS/SBR)*, 13-18. <https://doi.org/10.1109/LARS-SBR.2016.10>

VRC. (2016). *Vision Robotics Corporation*. <http://visionrobotics.com>