

Universidad del Norte
Departamento de Ingeniería Eléctrica y Electrónica



**Segmentación de Imágenes de Frutos de Café utilizando
Información de Textura y Descriptores de Forma**

TESIS

Para la obtención del título de:

Magíster en Ingeniería Electrónica

José Rafael Escorcia Gutierrez

Barranquilla, Colombia

Noviembre 2010

Universidad del Norte
Departamento de Ingeniería Eléctrica y Electrónica



**Segmentación de Imágenes de Frutos de Café utilizando
Información de Textura y Descriptores de Forma**

Para la obtención del título de:

Magíster en Ingeniería Electrónica

José Rafael Escorcía Gutierrez

Trabajo asesorado por:

Julián Andrés Betancur Acevedo, MSc.

Barranquilla, Colombia

Noviembre 2010

Nota de Aceptación

Presidente del Jurado

Jurado

Jurado

Asesor

Barranquilla, 22/11/2010

©2010 - José Rafael Escorcía Gutiérrez

Todos los derechos reservados.

Contenido

| | |
|--|-----------|
| Título | i |
| Tabla de Contenido | v |
| Lista de Figuras | viii |
| Lista de Tablas | x |
| Agradecimientos | xi |
| Dedicatoria | xii |
| 1 Introducción | 1 |
| 1.1 Motivación | 1 |
| 1.2 Problemas Relacionados con la Segmentación de Frutos de Café | 3 |
| 1.3 Objetivos | 4 |
| 1.3.1 Objetivo General | 4 |
| 1.3.2 Objetivos Específicos | 4 |
| 1.4 Delimitaciones | 4 |
| 1.5 Principales Contribuciones | 5 |
| 1.6 Guía Para esta Tesis | 5 |
| 2 Marco Teórico y Estado del Arte | 7 |
| 2.1 Sistema de Visión Artificial | 7 |
| 2.2 Técnicas de Segmentación Utilizadas en la Agricultura | 8 |
| 2.3 Extracción del Fondo y Objetos de Interés | 10 |
| 2.3.1 Métodos de agrupamiento | 10 |
| 2.3.2 Espacios de Color en el Procesamiento Digital de Imágenes | 11 |
| 2.4 Localización de los Objetos de Interés | 11 |
| 2.4.1 Detección de Bordos | 11 |
| 2.4.2 Análisis de descriptores de forma de los frutos de café | 15 |
| 2.5 Selección Efectiva de Características y Clasificación | 15 |
| 2.6 Evaluación de Desempeño | 17 |
| 2.7 Complejidad Computacional | 17 |
| 2.8 Estado del Arte | 19 |
| 3 Descripción General del Sistema | 22 |
| 3.1 Extracción de Fondo y Objetos de Interés | 23 |
| 3.2 Detección de Bordos | 27 |

| | | |
|----------|---|-----------|
| 3.2.1 | Definición del Texel | 29 |
| 3.2.2 | Selección Efectiva de Características | 31 |
| 3.2.3 | Clasificador Bayesiano | 36 |
| 3.3 | Descriptores de Forma | 38 |
| 3.4 | Procedimiento General | 45 |
| 3.4.1 | Extracción de fondo y objetos de interés | 45 |
| 3.4.2 | Detección de bordes | 46 |
| 3.4.3 | Descriptores de forma | 46 |
| 4 | Pruebas y Resultados | 48 |
| 4.1 | Extracción del Fondo y Objetos de Interés | 49 |
| 4.2 | Detección de Bordes | 53 |
| 4.3 | Descriptores de Forma | 56 |
| 4.4 | Evaluación de Desempeño del Sistema de Segmentación | 57 |
| 4.5 | Complejidad Computacional | 64 |
| 5 | Conclusiones y Trabajos Futuros | 69 |
| | Bibliografía | 72 |
| A | Visión Artificial | 80 |
| A.1 | Adquisición de Imágenes | 80 |
| A.2 | Preprocesamiento | 80 |
| A.3 | Segmentación | 81 |
| A.4 | Representación y Descripción | 81 |
| A.5 | Reconocimiento e Interpretación | 81 |
| B | Características de Los Frutos de Café | 82 |
| B.1 | Características de Color | 82 |
| B.2 | Características de Textura | 83 |
| B.3 | Características de Forma | 84 |
| B.3.1 | Rectangularidad | 84 |
| B.3.2 | Circularidad | 85 |
| B.3.3 | Firma | 85 |
| B.3.3.1 | Momentos Estadísticos de la Firma | 86 |
| B.3.4 | Índices de Convexidad y Concavidad | 86 |
| C | Matriz de Coocurrencia | 87 |
| C.1 | Descriptores de Textura | 88 |
| C.2 | Construcción de la Matriz | 92 |
| D | Operadores Morfológicos | 93 |
| E | Matriz de Confusión | 96 |

| | | |
|----------|--------------------------------|------------|
| F | Tablas de Fisher | 98 |
| G | Adelgazamiento de Borde | 100 |
| H | Pseudocódigos | 102 |

Lista de Figuras

| | | |
|------|--|----|
| 2.1 | Diagrama de Bloques de un Sistema de Visión Artificial. | 8 |
| 2.2 | Modelo Unidimensional y Continuo de un Borde. | 12 |
| 2.3 | Muestras de Bordes. | 12 |
| 2.4 | Funciones de Ordenes más comunes en el Análisis de Algoritmos de Complejidad. | 19 |
| 3.1 | Diagrama de Bloque General del Sistema de Segmentación. | 22 |
| 3.2 | Histograma de matiz (H), para una imagen de muestra. | 24 |
| 3.3 | Flujograma de Extracción de Fondo. | 26 |
| 3.4 | Transición de Color en la Componente de Saturación (S). | 27 |
| 3.5 | Imagen Resultante del Proceso de Extracción de Fondo y Objetos de Interés. | 28 |
| 3.6 | Representación de la División por Texel de la Imagen a Segmentar. | 30 |
| 3.7 | Representación de los Frutos de Café a Segmentar luego del Proceso de Extracción de Fondo. | 31 |
| 3.8 | Muestra para el Cálculo de las Características de Textura. | 32 |
| 3.9 | Flujograma del Detector de Bordes. | 37 |
| 3.10 | Imagen Resultante del Proceso de Suavizado de Bordes y Etiqueta de las Regiones. | 38 |
| 3.11 | Ejemplo de Error del Detector de Bordes (Instancia de Sub-segmentación). | 39 |
| 3.12 | Muestra Ideal de Concavidad en Frutos de Café. | 41 |
| 3.13 | Detección y Corrección de Instancias de Sub-Segmentación. | 42 |
| 3.14 | Posibles Uniones de los Frutos de Café. | 43 |
| 3.15 | Segmentación Final. | 43 |
| 3.16 | Flujograma del Sub-segmentador. | 44 |
| 4.1 | Extracción de Fondo y Objetos de Interés. | 52 |
| 4.2 | Extracción de Fondo y Objetos de Interés con Umbrales en H. | 53 |
| 4.3 | Detección de Bordes con un Texel de Dimensión 2x2 Píxeles. | 54 |
| 4.4 | Detección de Bordes con un Texel de Dimensión 8x8 Píxeles. | 55 |
| 4.5 | Detección de Bordes con un Texel de Dimensión 4x4 Píxeles. | 56 |
| 4.6 | Regiones Detectadas Correctamente. | 59 |
| 4.7 | Sobresegmentación. | 59 |

| | | |
|------|--|----|
| 4.8 | Mejoras de las Etapas del Sistema de Segmentación Propuesto. | 61 |
| 4.9 | Sistema de Segmentación SRG y Fuzzy. | 62 |
| 4.10 | Sistema de Segmentación Basado en la Información de Textura. | 62 |
| 4.11 | Sistema de Segmentación STC Center. | 63 |
| B.1 | Estados de Maduración del Café | 83 |
| C.1 | Obtención de la Matriz de Coocurrencia. | 87 |
| D.1 | Ejemplo de Elemento Estructural. | 93 |

Lista de Tablas

| | | |
|-----|---|-----|
| 2.1 | Jerarquía de Ordenes de Complejidad. | 19 |
| 3.1 | Rangos de Intensidades en la componente de matiz (H) del espacio HSV. | 25 |
| 3.2 | Relación Dimensión del Texel versus Tiempo de Cómputo. | 29 |
| 3.3 | Características de Textura para los Texels de Muestra | 33 |
| 3.4 | Relación Discriminante de Fisher en Relación a las Cinco Características mas Importantes. | 34 |
| 3.5 | Valores más Altos Obtenidos del Índice Discriminante de Fisher Según las Muestras Tomadas. | 35 |
| 3.6 | Relación Dimensión de la Máscara versus Concavidades Detectadas. | 41 |
| 4.1 | Matrices de Confusión. | 50 |
| 4.2 | Desempeño del Clasificador por Grupo de Entrenamiento. | 51 |
| 4.3 | Razón entre Efectividad y Error Negativo. | 51 |
| 4.4 | Heurística del Diseñador para Validar los Umbrales. | 52 |
| 4.5 | Rendimiento de Área Bajo la Curva para Distintas Dimensiones de Máscaras. | 57 |
| 4.6 | Rendimiento del Sistema de Segmentación. | 61 |
| 4.7 | Comparación de Rendimiento de los Sistemas de Segmentación. | 63 |
| 4.8 | Tiempo de Cómputo. | 67 |
| 4.9 | Características de Plataforma Hardware. | 67 |
| E.1 | Matriz de Confusión. Clasificador de dos Clases. | 96 |
| E.2 | Matriz de Confusión. | 97 |
| F.1 | Valores mas Altos Obtenidos del Índice Discriminante de Fisher Según las Muestras Tomadas. | 98 |
| F.2 | Relación Discriminante de Fisher para las Clases de Muestra de Selección Efectiva de Características. | 99 |
| H.1 | Pseudocódigo de la Extracción de Fondo y Objetos de Interés. | 102 |
| H.2 | Pseudocódigo del Detector de Bordes. | 102 |
| H.3 | Pseudocódigo del Sub-segmentador. | 103 |

Agradecimientos

Esta tesis evidencia el valor de la amistad por parte de mis compañeros de estudio y colegas Jorge Acevedo y Xavier García, quienes me brindaron su apoyo incondicional en los momentos más difíciles del diseño e implementación del sistema de segmentación que se propuso.

Y por último, gracias a nuestro señor Jesucristo por permitirme realizar otro gran sueño, como siempre con el apoyo incondicional de mis padres Alberto Escorcia y Ena Gutierrez. A mi hermanita Yesenia por soportarme y alegrarme en los momentos que no veía camino donde seguir. A mi Novia Melitsa por su gran comprensión, fe y amor que me ha brindado siempre.

A mi abuelo José Escorcia.

Capítulo 1

Introducción

1.1 Motivación

Para la Comisión de Ajuste de la Institucional Cafetera, el café más que un producto agrícola es ante todo un tejido social, cultural, institucional y político que ha servido de base para la estabilidad democrática y la integridad nacional. Esta actividad representa el corazón de gran parte de la sociedad rural colombiana, ofreciendo una oportunidad de trabajo, de ingreso y de subsistencia [30].

El café en Colombia más que aportar económicamente al sector primario o agropecuario, es motor de desarrollo para los sectores solidario, industrial, comercio y transporte, como expresó el Ministro de Hacienda del 2002, Juan Manuel Santos, hoy día Presidente de Colombia: “el café en los últimos 50 años le entregó a las arcas del Estado más de 11 mil millones de dólares”, resaltando la importancia del café Colombiano [35]. En la II Conferencia Mundial del café llevada a cabo en el año 2005, el presidente de Brasil Luiz Lula da Silva expuso que más de 25 millones de personas pertenecientes a 60 países con un alto nivel de pobreza en su mayoría tienen como principal fuente de ingreso la comercialización del café, representando para los productores colombianos una gran competencia [35].

La crisis económica internacional que ocurre actualmente no excluye al sector agropecuario, y específicamente el café. En la última Conferencia (XI) de las Naciones Unidas sobre Comercio y Desarrollo (UNCTAD) celebrada el 17 de Junio de 2010 en

Sao Paulo, se expuso por parte de Rubens Ricupero, Secretario General de la UNCTAD, que los productores de café a nivel mundial sólo reciben en promedio la suma de 5 mil millones de dólares de los 75 mil millones de dólares anuales que se obtienen de la actividad de venta del fruto [34]. La drástica discriminación de las ganancias que produce el café no solo afecta a los productores sino también a los consumidores, por lo que es muy bien recibida la sugerencia de Estados Unidos cuando cita en volver al Acuerdo Internacional del Café (AIC) que caducó en 1989, cuyo objetivo era estabilizar los precios y asegurar un aprovisionamiento regular del café, gracias a un sistema de contingentes de exportación y precios mínimos y máximos concertados [25], [34].

Ante la problemática mundial del café, la Federación Nacional de Cafeteros de Colombia enfoca su nuevo modelo de negocio en discriminar la mayor parte de las ganancias a los caficultores a través de nuevas y mejores estrategias de producción y comercialización con el fin de posicionar a nivel mundial el café colombiano, por ser uno de los principales productos de exportación hasta el punto de ser reconocido internacionalmente no sólo por su producción sino por su calidad, la cual depende en gran medida de la selectividad del cosechado, que es realizada manualmente. He aquí donde se identifica otro de los grandes problemas, la mano de obra por parte de las 566 mil familias que se dedican al cultivo decae con el tiempo. Además, el hecho de que el 64% de estas familias caficultoras son minifundistas, 31% correspondiente a campesinos o como los denota la Federación de Cafeteros de Colombia “economía cafetera campesina”; el 5% restante a los cafeteros empresariales, lo cual denota la necesidad de seguir desarrollando estudios desde diferentes disciplinas con el objetivo de automatizar el proceso de siembra y cosechado del fruto a un bajo costo y fácil manipulación de los equipos [24], [30].

El desarrollo de un sistema de visión artificial serviría de apoyo al trabajo manual de recolección y selección de los frutos de café, implicando un descenso sustancial en los costos de producción. Investigaciones como [13], [32], [39] y [59] demuestran la importancia de implementar un sistema de visión artificial en otros productos agrícolas. Sin embargo, cada una se ha centrado en una de las 5 etapas de un sistema de visión (adquisición, pre-procesamiento, segmentación, caracterización y reconocimiento), donde la segmentación no alcanza aún su máxima eficiencia. En

[50] y [51] presentan herramientas de segmentación diseñados para imágenes de café, concluyendo los resultados obtenidos como insatisfactorios, ya sea por la complejidad computacional y/o la eficiencia; los resultados de [5], [33] y [65] que corresponden a las etapas de caracterización y reconocimiento, parten del punto de una eficiencia del proceso de segmentación del 100% que se reconoce como segmentación ideal. En el caso de [6], [5], [50] y [51] se ha trabajado en segmentación desde diferentes enfoques y resaltan las recomendaciones a seguir para obtener mejores resultados.

1.2 Problemas Relacionados con la Segmentación de Frutos de Café

Según los resultados que entrega Montes en [51], se evidencia que uno de los principales problemas que presenta el proceso de segmentación de frutos de café son las condiciones de adquisición de las imágenes en campo, criterio que ratifica Betancur en [5] y [6]. Por otro lado, se encuentran los solapes y la unión de dos o más frutos que presentan las mismas características, y por último, el tiempo de cómputo y la carga computacional de los distintos segmentadores desarrollados [49], [38].

La adquisición de las imágenes influye directamente en la eficiencia del proceso de segmentación y cada investigador concluye que las imágenes deben encontrarse bajo condiciones controladas para que el aporte del pre-procesamiento sea mayor al momento de resaltar los bordes, contrastes, formas, textura de los frutos y remover artefactos tal como se plantea en las conclusiones de [50], [7].

El centro de esta investigación se encuentra en la exploración de las características de textura que presenta los frutos de café en sus distintas etapas de maduración teniendo en cuenta los descriptores de forma para corregir instancias de sub-segmentación y analizar la complejidad computacional con propósito de seleccionar una plataforma hardware capaz de llevar a cabo el proceso de segmentación a futuro. En el marco de esta investigación se realizaron aproximaciones preliminares como los mostrados en los trabajos desarrollados por Betancur, Mora, Viera [8]; Escorcia, Campos, Núñez [15] y Escorcia, Escudero, Morillo [23].

1.3 Objetivos

1.3.1 Objetivo General

Diseñar un algoritmo para la segmentación de imágenes de frutos de café utilizando información de textura y descriptores de forma.

1.3.2 Objetivos Específicos

1. Diseñar un algoritmo de segmentación de frutos de café utilizando información de textura.
2. Desarrollar un algoritmo que divida una instancia de sub-segmentación en las diferentes regiones que corresponden a los frutos.
3. Determinar la complejidad computacional del sistema de segmentación para su posterior descripción en componentes hardware de un sistema embebido.
4. Comparar el rendimiento del sistema de segmentación con los descritos en el estado del arte.

1.4 Delimitaciones

La precisión de un sistema de segmentación se puede cuantificar con los parámetros propuestos por Min, Powell y Bowyer [10], quienes la miden por las regiones detectadas correctamente, regiones sobresegmentadas, regiones subsegmentadas, regiones con presencia de ruido y regiones fallidas, comparando el resultado de la máquina con el resultado deseado. Empero, un sistema de segmentación también puede ser evaluado por su complejidad computacional en cuanto a eficiencia se refiere. Montes en [51] plantea la necesidad de desarrollar códigos de programación para tareas afines en lenguajes distintos a los utilizados en investigaciones como [51], [48], [65], [33], el sistema que se propone en el presente trabajo se desarrolla en C++ ya que es un lenguaje que difiere del desarrollado en las investigaciones mencionadas en las áreas de: destino de compilación, gestión de memoria, punteros, sobrecarga de operadores, directivas para el preprocesador, entre otras más; el hecho que el destino de compilación se realice en

lenguaje ensamblador permite interactuar con menos recursos computacionales con una plataforma hardware, caso contrario del lenguaje C#, Java y MATLAB, los cuales se compilan en un lenguaje intermedio por medio del proceso de compilación JIT [61], [19], [37], luego es almacenado en un conjunto de ficheros conocidos como unidad de ensamble que componen los DLL (Dynamic-Link Library).

1.5 Principales Contribuciones

El objetivo es cuantificar y analizar su eficiencia y complejidad computacional con miras a detallar los requisitos computacionales para su implementación en una plataforma hardware con el menor costo.

Los algoritmos que se proponen diseñar para el proceso de segmentación de los frutos de café están orientados al uso de la información de textura gracias a los resultados, conclusiones y recomendaciones de los trabajos [5], [33] y [37]. Además, el sistema de segmentación se complementa con un segundo algoritmo capaz de dividir instancias de sub-segmentación presentes luego del proceso de segmentación utilizando información de textura del fruto de café.

Por último, se entregan los requisitos mínimos que requiere un sistema hardware para llevar a cabo la tarea de segmentación de frutos de café para el caso particular de esta investigación. Al evaluar diferentes realizaciones en el sistema incrustado BeagleBoard basado en el sistema operativo GNU-LINUX.

1.6 Guía Para esta Tesis

El capítulo 2 se estructura con una revisión de los temas necesarios del procesamiento digital de señales orientado al proceso de segmentación de imágenes a color, así como avances de investigaciones relacionadas al diseño e implementación de sistemas de visión artificial en la agricultura, para luego enfocarnos en los aportes al proceso de segmentación de frutos de café.

En el capítulo 3 se detalla cómo se desarrolla la presente investigación indicándose el método de segmentación, la selección de los descriptores de textura y forma del fruto de café, como también el cómputo de la complejidad computacional del sistema. Cada sección está basada en los pseudocódigos de los algoritmos de segmentación a diseñar. Los resultados obtenidos en cada uno de los pasos ejecutados para el diseño, desarrollo e implementación de los algoritmos del sistema de segmentación con su respectivo análisis y comparación con el estado del arte se muestran en el capítulo 4.

Con base a lo descrito en los capítulos 3 y 4 se constituye el capítulo 5 como un compendio de las conclusiones que se generaron en el transcurso de la presente investigación, en compañía con una propuesta para trabajos futuros en el área de segmentación de frutos de café.

Capítulo 2

Marco Teórico y Estado del Arte

En este capítulo se detalla de manera conceptual el sistema de visión artificial, enfocándose en el desarrollo de la etapa de segmentación de imágenes de frutos de café. Por lo que se hace necesario esclarecer la importancia de los procesos de selección efectiva de características y métodos de clasificación de los objetos de interés (frutos de café). Luego, se definen los métodos de evaluación propuestos en el estado del arte para cuantificar la eficiencia de un sistema de segmentación, así como la definición de los requerimientos hardware requeridos para implementar el sistema de segmentación, requerimientos que son obtenidos al momento de evaluar la complejidad computacional del sistema propuesto.

Finalmente, se concluye este capítulo con una consulta al estado del arte enfocado en los sistemas de visión artificial en la agricultura para luego encauzarse en el producto de interés que es el café, teniendo en cuenta que el enfoque del estudio se centra en la etapa de segmentación del sistema y en los requerimientos hardware que se necesitan para llevar a cabo sus respectivas implementaciones en campo.

2.1 Sistema de Visión Artificial

Un sistema de visión artificial tiene como meta principal emular el comportamiento del sistema de visión del ser humano mediante algoritmos capaces de aprender autónoma-mente, hacer inferencias y tomar decisiones. Actualmente, los sistemas

de visión artificial se encuentran en desarrollo con aplicaciones que tienen como fin aumentar la producción y calidad de productos que necesiten ser inspeccionados, es decir, los sistemas de visión artificial de hoy en día ejecutan tareas visuales repetitivas y alienantes para el ser humano. Como se muestra la Figura 2.1, un sistema de visión artificial está compuesto por tres niveles de información: bajo, medio y alto. Donde la información de bajo nivel es suministrada por las etapas de adquisición y procesamiento, segmentación y extracción de características (representación y descripción) componen las de medio nivel y las etapas de reconocimiento e interpretación integran las de alto nivel [29].

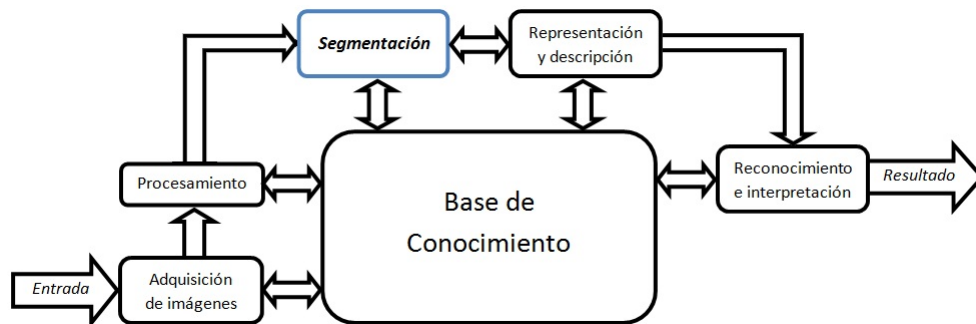


Figura 2.1: Diagrama de Bloques de un Sistema de Visión Artificial [29].

Esta investigación se centra en el proceso de segmentación de frutos de café mediante el diseño de algoritmos que se estructuran con pasos metodológicos para extraer el fondo y los objetos de interés por medio de métodos de agrupamiento de color o un estudio de las características de uno o más espacios de color que permita disociar el fondo de los objetos de interés; detectar bordes usando información de textura a través de un clasificador y el análisis de los descriptores de forma para localizar los objetos de interés son las técnicas a utilizar para el diseño de los algoritmos de segmentación.

2.2 Técnicas de Segmentación Utilizadas en la Agricultura

La segmentación es una etapa clave en la visión artificial, donde se determinan las regiones en la imagen que corresponden a los objetos de interés. En este proceso se

seleccionan y sortean regiones con ciertas características específicas, para luego ser reagrupadas y etiquetadas, definiendo así la pertenencia de los píxeles de la imagen a una región u otra [29],[63].

En general, la segmentación se divide en dos diferentes clases: segmentación por discontinuidad y segmentación por similitud [29]. La segmentación por discontinuidad se refiere a la detección de cambios significativos entre píxeles cercanos de una imagen; propiedad característica de los bordes que describen los límites de un objeto. Por otro lado, la segmentación por similitud es la que se realiza al comparar píxeles cercanos entre si y determinar que pertenecen a un conjunto de píxeles que conforman un mismo objeto [29],[63].

Se pueden generalizar los tipos de segmentación existentes en cuatro grandes grupos: Técnicas basadas en regiones, técnicas basadas en contornos, técnicas de umbrales fijos y técnicas híbridas [6].

- ▷ Técnicas basadas en Regiones: Se seleccionan píxeles de la imagen y se comparan con sus píxeles vecinos mas parecidos, conformando regiones que se espera, describan a un objeto de la imagen [69].
- ▷ Técnicas basadas en Contornos: Consiste en medir la velocidad de cambio entre píxeles cercanos. En su mayoría resalta y moldea las fronteras entre un objeto, el fondo y el resto de objetos [29],[63].
- ▷ Técnicas de Umbrales Fijos: Este método consiste en la selección de niveles de intensidad, los cuales definen los límites de intensidad de los diferentes objetos dentro de la imagen. Se suele utilizar como información de referencia datos obtenidos del histograma de intensidades de color, obteniendo muy buenos resultados ante un comportamiento multimodal. Puede presentar problemas ante un bajo contraste con respecto al fondo o debido a objetos juntos con las mismas características de color [29],[63].
- ▷ Técnicas Híbridas: Este último tipo de segmentación combina los métodos de segmentación anteriores con el objetivo de disminuir las debilidades de cada uno.

Una vez analizadas las técnicas de segmentación se procede a relacionar la información pertinente al esquema de segmentación híbrido desarrollado en este proyecto. Como primera instancia se remueve el fondo de las imágenes de interés gracias al alto contraste que existe entre él y los objetos a segmentar ya que su adquisición fue realizada en laboratorio bajo condiciones controladas de iluminación y fondo [5]. Removido el fondo, se ubican los objetos de interés ya sea por la información de textura o los descriptores de forma de los frutos de café, para detectar los bordes de cada elemento. El esquema de segmentación propuesto es una recopilación de los problemas y sugerencias realizadas en investigaciones previas [5], [8] y [51], donde se detallan el por qué no se alcanzan los resultados esperados.

2.3 Extracción del Fondo y Objetos de Interés

2.3.1 Métodos de agrupamiento

Bajo la perspectiva de clasificación, los métodos de agrupamiento tienen como función determinar el grado de asociación o similitud de un grupo de muestras multivariada entre los diferentes miembros del grupo conformado por clases o “clusters” que se destacan por ser lo más homogéneo posible con el fin de que cada elemento que sea parte de la clase esté más próximo entre sí que los pertenecientes a las diferentes clases del grupo. Los resultados de las medidas de similitud o también llamada medida de semejanza son calculados por algoritmos de agrupamiento basados en métodos jerárquicos y no jerárquicos.

Los métodos jerárquicos se basan en las medidas obtenidas de la matriz de semejanza para la construcción del árbol jerárquico que describe, mediante sus uniones o divisiones sucesivas, las relaciones entre los objetos en análisis. Algoritmos como Vecinos más Cercanos y Vecinos Lejanos se distinguen por estructurarse bajo esta jerarquía. Estos son algoritmos de fácil interpretación del árbol resultante, pero el hecho de analizar una sola vez el conjunto de datos a analizar no le permite subsanar o corregir una clase inicial desacertada. Situación contraria a los algoritmos de agrupamiento con métodos no jerárquicos ya que estos empiezan con la definición de una clase inicial de un conjunto de k clases especificado a priori, dentro de los cuales se define un centroide con

su respectiva ubicación y cada objeto perteneciente a cada de una las clases es medido a partir de la clase inicial para ser ubicado en la clase correspondiente; este procedimiento es iterativo hasta el punto de no producirse cambios en las clases previamente definidas. Dentro este método resalta algoritmos, K-means, Fuzzy K-means, K-means Secuencial entre otros [2],[14],[68].

En el procesamiento digital de imágenes, los métodos de agrupamiento son utilizados como técnicas de segmentación basadas en los valores de píxel (histograma de color) dependiendo del espacio de color en el que se trabaje. En otras palabras, se obtiene el histograma de color de una imagen, se identifican los valores máximos y se analizan los intervalos de cada uno de los máximos durante el proceso de segmentación [16], [46], [53], [71].

2.3.2 Espacios de Color en el Procesamiento Digital de Imágenes

Existen diversos espacios de color que se usan dependiendo de las aplicaciones gráficas de los software en se utilicen pero muchos de ellos son inadecuados en el tratamiento estocástico que se le da a las imágenes debido no conlleva a una independencia entre las componentes cromáticas y acromáticas por no basarse en normas o distancias vectoriales de los puntos (píxeles) en un espacio de color. Una metodología muy común para el agrupamiento morfológico para la segmentación de imágenes está dada por los espacios de color RGB, OHTA, HSI, CMY, CMYK, YIQ, YCbCr, HSV, entre muchos otros [29].

2.4 Localización de los Objetos de Interés

2.4.1 Detección de Bordos

Los bordes de los objetos en una imagen digital se definen por las transiciones abruptas en los niveles de grises entre dos regiones, las cuales son obtenidas mediante la correlación en conjunto de los píxeles adyacentes al píxel de interés.

En la Figura 2.2 se representa una rampa con valor inicial B y valor final A que definen la variación de intensidad ($A - B$) dándole soporte a la definición de borde. El




Figura 2.2: Modelo Unidimensional y Continuo de un Borde.

ángulo de inclinación de la rampa α y el punto intermedio de la transición de intensidad X_0 proporciona la amplitud y localización del borde. En la Figura 2.3 se observa la diferencia visual entre un borde ideal y uno real, el cual está expuesto a presencia de ruido proveniente de la etapa de adquisición afectando su localización y definición; he aquí la importancia de desarrollar un sistema detector de bordes que tenga como finalidad una baja tasa de error refiriéndose a la capacidad de clasificar píxeles de la imagen como borde sin incluir elementos espurios [2],[11].




Figura 2.3: Muestras de Bordes.

Un detector de bordes se basa en dos técnicas, orientadas al píxel y orientadas a la región, donde la primera de ellas detecta las discontinuidades en la información de los píxeles de una imagen, mientras que la segunda determina una medida cuantitativa de propiedades intrínsecas como continuidad, energía, textura entre otros al grupo conexo de píxeles que serán menos dependientes del tamaño de los objetos y fondo [36],[27].

El uso de la información de las propiedades de un píxel en el proceso de detección de bordes o contornos puede categorizarse en el grupo de técnicas de segmentación híbrida; esta investigación utiliza la información de textura de un grupo conexo de píxeles para discriminar la información de fondo y fruto del borde o contorno del mismo [56].

En esencia no existe una definición de textura pero puede entenderse como réplicas, simetrías o combinaciones, usualmente en pequeñas variaciones aleatorias, del tono dentro de un vecindario de píxeles. Se dice si una textura es dominante o el tono es dominante si se tiene, respectivamente, alta variación o poca variación del tono dentro de la pequeña área de píxeles analizadas. Existen tres variables a tener en cuenta durante la extracción de características de textura: dimensión del área de estudio, el valor relativo de las características discretas de tono y la distribución en el área de las características de tono, obteniendo así descripción sobre la suavidad, regularidad y rugosidad de una región [8], [31], [66].

La suavidad y rugosidad de la textura también pueden ser tomadas en cuenta para el análisis del estado de madurez en el fruto de café. Durante el proceso de maduración del café, existen diferentes etapas en las que su epidermis muestra una distribución uniforme del color, mientras que en algunas etapas existe una variación ya sea suave o brusca entre un color y otro. El análisis de rugosidad es útil para hallar los frutos de café cuando están demasiado maduros o secos [66].

El problema del análisis de textura, radica en definir qué tipo de textura se está analizando, teniendo en cuenta que la textura en general presenta un comportamiento tanto aleatorio como periódico; para ello existen dos enfoques:

- ▷ Enfoque Estadístico: La textura es descrita como un proceso estocástico bi-dimensional descrito por sus parámetros estadísticos. Es decir, mediante las propiedades estadísticas de las intensidades y posiciones de los píxeles [47],[17].
- ▷ Enfoque Estructural: Este enfoque introduce el termino *texels*¹ o *texons*, utilizados para describir estructuras complejas de textura por medio de matrices de pequeñas estructuras simples, considerando que la textura tiene propiedades periódicas o quasi-periódicas en una región [66].

Dependiendo del enfoque se obtienen las diferentes medidas estadísticas de los parámetros que caracterizan a la textura de un grupo de píxeles, anteriormente se describió la importancia de utilizar la información de suavidad, regularidad y rugosidad

¹Del inglés “Texture Element” o “Texture Pixel”. Un *texel* es definido como la expresión mínima de la textura en una imagen [47]

en los frutos de café. Aparte de los parámetros o medidas estadísticas, también se obtienen medidas de interés de la matriz de coocurrencia con enfoque estadístico que computa los momentos estadísticos de segundo orden, uniformidad, entropía, contraste, homogeneidad local, correlación, tendencia de cluster, directividad, momento de diferencia de orden K , momento inverso de diferencia de orden K , máxima probabilidad y varianza definidos dentro de un clasificador automático que permita separar y clasificar un conjunto de imágenes en sus diferentes clases [8], [37], [66].

La construcción de la matriz de coocurrencia involucra la ubicación espacial de los píxeles, relación con el vecindario y valor de su intensidad. Donde la condición, dirección y distancia determinarán las características de textura [37].

- ▷ Condición: Regla que debe seguir un pixel con relación a su vecino para ser cuantificado.
- ▷ Dirección: Es la orientación espacial a en cual se evalúa la condición, como casos típicos se utilizan direcciones como 0 grados, 45 grados, 90 grados y 135 grados.
- ▷ Distancia: Es el número de píxeles entre el par de píxeles evaluados, como distancias típicas se utilizan 1, 3 y 5 píxeles de distancia.

Las características de textura suelen presentar información redundante entre sí y mucho más cuando se analizan éstas en diferentes espacios de color (RGB, HSV, Colores Oponentes, Baéz y OHTA), en trabajos previos realizados por Sandoval denotan que para el caso del café, solo 5 de las 121 características extraídas de la matriz de coocurrencia no presentan información redundante [65], [66]. Al caracterizar un fruto de café se extraen un sin número de características relevantes con el fin de clasificarlos, reconocerlos o en este caso de segmentarlos, Sandoval demuestra en sus investigaciones que para el objeto de interés existen 208 características originarias de la forma, textura y color[65]. Empero, este gran número de características aumentan de manera considerable la complejidad computacional del sistema que se desee diseñar, ya sea un clasificador o en nuestro caso un sistema de segmentación. El por qué y cómo se debe reducir las características se desarrollará en el apartado de Selección Efectiva de Característica y Clasificación (Sección 2.5).

Los momentos estadísticos de las características de textura resultantes del análisis de selección efectiva de características determinará si una región de interés de la imagen en análisis pertenece a la clase fruto de café o no, siendo el no información perteneciente a borde. Sin embargo, se puede presentar el caso que información perteneciente a la clase borde no sea clasificada como tal debido a que la separabilidad de los momentos estadísticos de las características de textura no sea discriminante, para tal caso se recurre al análisis de los descriptores de forma.

2.4.2 Análisis de descriptores de forma de los frutos de café

Un objeto puede ser descrito por medio de los descriptores de forma bajo los esquemas de representación interna y externa, que tienen la misma definición que las técnicas de segmentación anteriormente expuestas, respectivamente técnicas basadas en regiones y en contorno. Propiedades como singularidad, integridad, invarianza bajo transformaciones geométricas, sensibilidad y abstracción de los detalles definen el esquema de descriptor de forma a utilizar, dentro de los cuales se resaltan por su común uso, centroide, perímetro, elongación, entre muchos más [68].

En el caso del café, su forma es típicamente elipsoidal-esférica. Durante las primeras etapas de maduración, el café se muestra con forma elipsoidal, y a medida que llega al estado de plena madurez, su forma se va tornando esférica, para luego volverse nuevamente elipsoidal a medida que el fruto se seca. Dentro de los descriptores que ayudan a clasificar las características del fruto de café son: rectangularidad, circularidad, firma, momentos estadísticos de la firma, índices de concavidad y convexidad [22], [26], [64], [65].

2.5 Selección Efectiva de Características y Clasificación

De acuerdo a la información de textura descrita en la sección 2.4, se enumeran 11 características extraídas de la matriz de coocurrencia describiendo a cada fruto de café variedad Coffea Arabica, características que entre sí presentan información redundante al momento de correlacionarse. El hecho que exista redundancia en la información repercute en el costo computacional, convirtiéndose en el gran problema

a la hora de implementar un detector de bordes. En [65] se redujo a 5 características de textura que representan la información necesaria para implementar un detector de bordes eficiente en segmentación y tiempo de cómputo; la reducción la llevó a cabo por medio de un selector de característica que tiene como objetivo suprimir aquellas que no sean ortogonales entre sí y así escoger las mejores características del conjunto dado, reduciéndolas pero al mismo tiempo conservando la información discriminante. La escogencia del menor número de características sin afectar el espacio vectorial característico depende directamente del método estadístico de selección utilizado entre los que se destaca la relación discriminante de Fisher, el análisis de componentes principales, el análisis de variable, el análisis multivariable y el análisis de correlación [20], [21].

Los métodos de clasificación se fundamentan en la regla de Bayes del mínimo error [21] si un objeto con unas características determinadas, pertenece a una clase si la probabilidad de pertenecer a ésta es mayor que la probabilidad de pertenecer a cualquier otra. En esta regla se fundamenta el clasificador bayesiano bi-clase. En el caso descrito para las características de textura de los frutos de café extraídas de la matriz de coocurrencia se tiene 121 características para el clasificador donde cada una de ellas tiene asociada una probabilidad $p(\frac{m}{w_i})$ y una probabilidad a priori $p(w_i)$. Otros clasificadores bi-clases que se basan en la regla de Bayes del mínimo error son los clasificadores de agrupamiento no jerárquico [21].

Los métodos de clasificación se fundamentan en la regla de Bayes del mínimo error [21], si un objeto pertenece a una clase dependiendo si la probabilidad de pertenecer a esta es mayor que la probabilidad de pertenecer a otra. En esta regla se fundamenta el clasificador bayesiano bi-clase. En el caso descrito para las características de textura de los frutos de café extraídas de la matriz de coocurrencia se tiene 121 características para el clasificador donde cada una de ellas tiene asociada una probabilidad $p(\frac{m}{w_i})$ y una probabilidad a priori $p(w_i)$. Otros clasificadores bi-clases que se basan en la regla de Bayes del mínimo error son los clasificadores de agrupamiento no jerárquico [21].

2.6 Evaluación de Desempeño

Los métodos de evaluación de desempeño de un sistema o algoritmo de segmentación se dividen en las categorías de métodos empíricos y métodos analíticos. La primera categoría mide la calidad de los resultados de segmentación por medio de pruebas realizadas a un conjunto de imágenes; en cambio, la categoría analítica examina y evalúa directamente los algoritmos de segmentación con algoritmos referencias a la temática desarrollada.

El sistema de evaluación sobre los métodos analíticos presentan la desventaja que no pueden ser implementados debido a la no existencia de un experimento para su evaluación, lo anterior se evidencia en las investigaciones [67] en donde solo se alcanza evaluar el diseño del algoritmo de segmentación al comparar los resultados con modelos particulares o según las propiedades que exhiba [67], [73].

Los métodos de evaluación empíricos se basan en los esquemas de subjetividad y discrepancia, siendo la subjetividad el proceso de establecer apreciaciones según la intuición del ser humano entre la imagen a segmentar y el resultado del algoritmo de segmentación sin requerir el conocimiento a priori de la imagen segmentada de referencia [55], [62], [67]. Caso contrario presenta el esquema de evaluación de discrepancia, la cual necesita de la disponibilidad de la imagen segmentada de referencia, también llamada “Ground Truth” o “Gold Standard” para sensor la calidad y eficiencia del algoritmo de segmentación a partir del número de regiones presentes en la imagen [1], [67]. Regiones que son clasificadas según [10] como segmentaciones correctas, sub-segmentación, sobre-segmentación, regiones pérdidas y regiones con presencia de ruido o con bordes espurios.

2.7 Complejidad Computacional

Un algoritmo puede definirse como el conjunto de reglas operacionales inherentes a un tiempo de cómputo que buscan resolver un problema y se caracteriza por su efectividad, la cual es alta siempre y cuando cada instrucción o regla del algoritmo sea lo suficientemente básica para ser ejecutada por un ser humano usando procedimientos

matemáticos rápidos [44]. Para esto, un algoritmo eficiente debe desarrollar la tarea para la que fue diseñado con el mínimo consumo de espacio (memoria requerida) y tiempo de cómputo. Ambos consumos dependen del tipo de compilador en el que se desee implementar, esta investigación se centra en el sistema de desarrollo BeagleBoard soportado por el sistema operativo GNU-LINUX [44], [72].

Las medidas de memoria requerida y tiempo de cómputo de un algoritmo se basan en los análisis a priori y a posteriori, donde el primero de los análisis presenta como ventaja la no dependencia del equipo hardware o lenguaje de programación en que se diseñe el algoritmo debido a que el tiempo de ejecución no es medido en unidades de tiempo sino en el número de veces que se ejecuta una operación primitiva, cumpliendo así con el principio de invarianza, es decir, el tiempo de ejecución de dos implementaciones distintas del mismo algoritmo, no va a diferir en el número de operaciones ejecutadas (operaciones aritméticas, asignaciones de tipos predefinidos, saltos, comparaciones lógicas y acceso a estructuras indexadas). Aunque, el comportamiento del algoritmo puede variar ante cambios en la variable de entrada, por lo que suele categorizarse para un mismo algoritmo el mejor de los casos, el peor de los casos y por último el caso promedio. Cuando un algoritmo se ejecuta muchas veces ante distintos tipo de entrada nos centramos en el comportamiento promedio que presenta por lo que se evidencia la distribución de los datos de entrada, este sería el caso ideal pero ¿qué pasaría si no conocemos todas las entradas? Entonces se puede optar por el mejor de los casos o el peor de los casos dependiendo de la necesidad para la que fue diseñado el algoritmo. El tiempo de ejecución se obtiene a través de los métodos de benchmarking, profiling y análisis [3].

- ▷ **Benchmarking:** Considera una colección de entradas típicas representativas de un conjunto de datos para cuantificar el tiempo de cómputo en un mismo algoritmo.
- ▷ **Profiling:** Asocia a cada instrucción del algoritmo un número que representa la fracción de tiempo total tomada para ejecutar la instrucción, procedimiento que se conoce como asignación de peso sináptico.
- ▷ **Análisis:** Agrupa las entradas de acuerdo a su tamaño y estima el tiempo de ejecución del algoritmo ante grupos del mismo tamaño.

La complejidad es definida como $f(n)$ y el tiempo de ejecución como una función de entrada denotada como $T(n)$ donde n denota el tamaño de la variable de entrada. El comportamiento de la función de complejidad está asociado al orden de jerarquía (ver Tabla 2.1), orden que definirá qué tan complicado es el modelo matemático de la función de complejidad para un algoritmo. En la Figura 2.4 se muestra un ejemplo de los órdenes de jerarquía para la función de complejidad [41].

| Nomenclatura | Nombre |
|--------------|-------------------------------|
| $O(1)$ | orden constante |
| $O(\log n)$ | orden logarítmico |
| $O(n)$ | orden lineal |
| $O(n^2)$ | orden cuadrático |
| $O(n^a)$ | orden polinomial ($a > 2$) |
| $O(a^n)$ | orden exponencial ($a > 2$) |
| $O(n!)$ | orden factorial |

Tabla 2.1: Jerarquía de Ordenes de Complejidad.




Figura 2.4: Funciones de Ordenes más comunes en el Análisis de Algoritmos de Complejidad.

2.8 Estado del Arte

A nivel mundial la agricultura desarrolla un rol cada vez más prometedor en el campo ambiental y humano en las necesidades de abastecimiento y provisión de

alimentos, un fuerte apoyo que ha encontrado este sector proviene de sistemas basados en inteligencia artificial, principalmente, los sistemas de visión artificial debido a que estos proporcionan la calidad de la recolección de los productos. El sistema de visión artificial más avanzado que se ha implementado y que hoy en día proporciona grandes ganancias es el Citrus-Robot, desarrollado por el Instituto Valenciano de Investigaciones Agrarias (IVIA) [28]. El Citrus-Robot detecta y localiza el fruto mediante el análisis de sus características en una imagen digital, sensa la distancia a la que se encuentra el fruto del sistema mediante técnicas de estereoscopia, despeja los artefactos de la escena en análisis por medio de una pinza prensora y un sistema de sensores electrónicos acoplados al sistema de visión para determinar la calidad de la fruta recolectada por el robot. Aplicaciones como el Citrus-Robot se orientan en el instituto tecnológico de Chihuahua de México para el desarrollo de un sistema de visión artificial para el control de calidad del Melón, el cual tiene como objetivo la selección de las variedades Cantaloupe y Honeydew del melón [18]. Aunque el sistema de visión desarrollado por el instituto se encuentra en trabajo para lograr implementar el sistema de visión en una plataforma hardware. Al igual que el Departamento de Agricultura de los Estados Unidos (USDA) en el proyecto de clasificación de patatas [28],[18].

Los sistemas de visión artificial han incrementado con el transcurrir del tiempo su interés en el sector agropecuario, específicamente en los procesos agrícolas de cosechado, cultivo y control de calidad. Siendo estos los pilares de una demanda alta del producto, investigadores de todo el mundo han desarrollado trabajos afines pero en la presente investigación se resaltarán las técnicas de segmentación utilizadas en los distintos productos agrícolas como: mandarinas [9], [40], manzanas [4], [12], [45], tomates [43], oliva [60], cultivos de cereales [70], entre muchos más.

En cuanto al producto de interés de esta investigación, es decir, el café variedad Coffea Arabica se pueden destacar los trabajos de los grupos de investigación de la Universidad del Norte, que ha aportado en los trabajos realizados en [7], [8] y de la Universidad Nacional de Manizales [6], [51].

De los trabajos relacionados en Colombia acerca de las técnicas de segmentación de los frutos de café se encuentran los resultados de [5] orientados a la técnica de segmentación de crecimiento de regiones a través de los sistemas euclídeo, sistema

ACB-PCB y sistema híbrido integrado por un detector de bordes y crecimiento de regiones a partir de semillas. En [8] se realizaron aproximaciones preliminares de esta investigación alcanzando una eficiencia del 85% en el promedio de los casos al momento de la evaluación del sistema referido solamente a la eficiencia de la segmentación.

El desarrollo de esta investigación se soporta en lo desarrollado por Betancur en [8] y en los aportes de trabajos futuros que entrega Montes en [51], donde destaca la necesidad de estudiar la posibilidad de utilizar la información de textura de los frutos de café para el proceso de segmentación. Además, Montes recomienda la búsqueda de un lenguaje de programación, técnicas de optimización de algoritmo con el fin de obtener una alta complejidad computacional para la implementación de los algoritmos que componen el sistema de segmentación en una plataforma hardware.

Capítulo 3

Descripción General del Sistema

En el capítulo anterior se presentó la información teórica por medio de la cual se diseñará el sistema de segmentación. Ahora, se detalla el desarrollo de cada etapa del sistema y las diferentes técnicas aplicadas para alcanzar el objetivo de cada subsistema que fue descrito en los apartados del Marco Teórico en relación con los expuestos en el diagrama de bloques general del sistema de segmentación que se muestra en la Figura 3.1.

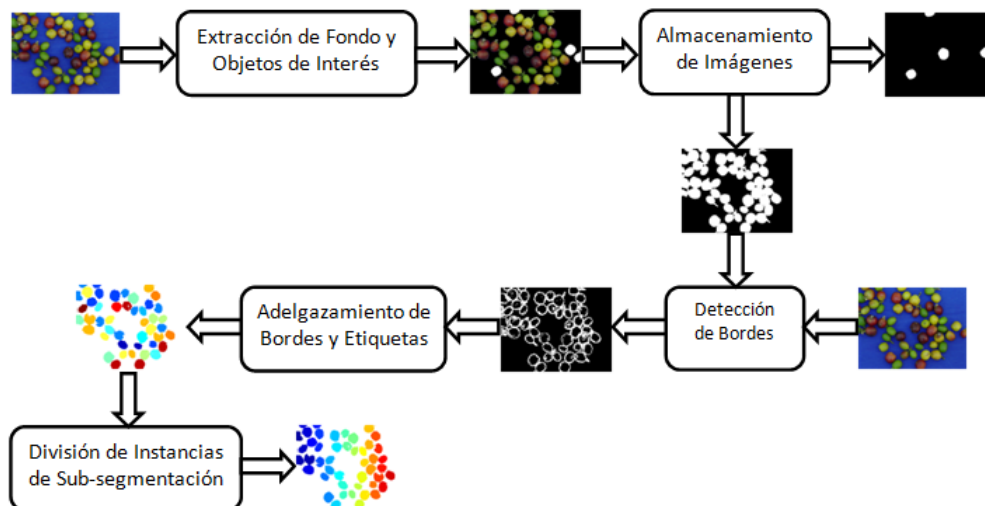


Figura 3.1: Diagrama de Bloque General del Sistema de Segmentación.

El sistema de segmentación mostrado en la Figura 3.1 está compuesto por los subsistemas: extracción de fondo y objetos de interés, almacenamiento de imágenes,

detección de bordes y, adelgazamiento de bordes y etiqueta, éstos conforman el algoritmo que utiliza la información de textura de los frutos de café para segmentarlos. De manera general se muestra en el Anexo H.1 y H.2 el flujograma del algoritmo con el fin de esquematizar el conjunto de pasos de lógicos que se siguieron para el diseño del primer algoritmo de segmentación. En las siguientes secciones se describe con mayor detalle el diseño de cada subsistema del algoritmo al igual que el último subsistema, división de instancias de sub-segmentación, que corresponde al segundo algoritmo que integra el sistema de segmentación; en el Anexo H.3 se muestra su respectivo pseudocódigo.

3.1 Extracción de Fondo y Objetos de Interés

Con el objetivo de minimizar el tiempo de cómputo se realiza el procedimiento de extracción del fondo y de los objetos de interés de cada imagen. Para la extracción del fondo se procedió a un estudio subjetivo en donde se resaltan la características de un grupo de imágenes. Entre estas características se encuentra el fondo, el cual se destaca debido al contraste ligeramente distinto a los frutos de café gracias a las condiciones en que fueron adquiridas las imágenes (ambiente controlado), por lo que se decidió realizar un agrupamiento de color con el objetivo de observar sus histogramas en diferentes espacios de color y así determinar cuál de ellos entrega información discriminante del fondo.

Bajo las condiciones controladas en que fueron obtenidas las imágenes a segmentar, visualmente se puede discriminar el fondo de los objetos de interés; este hecho motiva a explorar diferentes espacios de color en busca de obtener una o más componentes de color que discriminará la información que se percibe por el sistema de visión del ser humano. En un sistema de visión artificial, el espacio de color RGB es el más compatible con una plataforma hardware, empero este espacio no es muy útil en la especificación y reconocimiento de colores [54]. A pesar de que la naturaleza del color puede ser representada por las combinaciones de cantidades de componente roja, verde o azul, su interpretación por el sistema de visión humano no es capaz de percibirlo, en cambio los atributos perceptuales de matiz, saturación y luminancia describen el color

de forma semejante a cómo es percibido por el ser humano. Las derivaciones del modelo cromático HSV, HSI, HLS entre otros, compuestas por los atributos perceptuales, son definidas como variables intuitivas y psicológicas que describen la interacción del sistema de visión humano con su entorno [54], [57].

Con base en el espacio de color HSV se analizan los histogramas de color de cada una de las componentes y se escoge la que mayor información discriminante presente entre el fondo y los objetos de interés. En la Figura 3.2 se muestra el histograma de la componente de matiz o intensidad del espacio de color HSV por ser el más representativo entre los demás; la imagen escogida fue seleccionada aleatoriamente. Los datos que mayor frecuencia presentan corresponden al fondo mientras los demás a los objetos de interés. En la Tabla 3.1 se consignan los intervalos de frecuencias correspondientes al fondo y a cada objeto de interés que es categorizado por Montes [52] como fruto verde, pintón, maduro, sobre-maduro y seco [58].

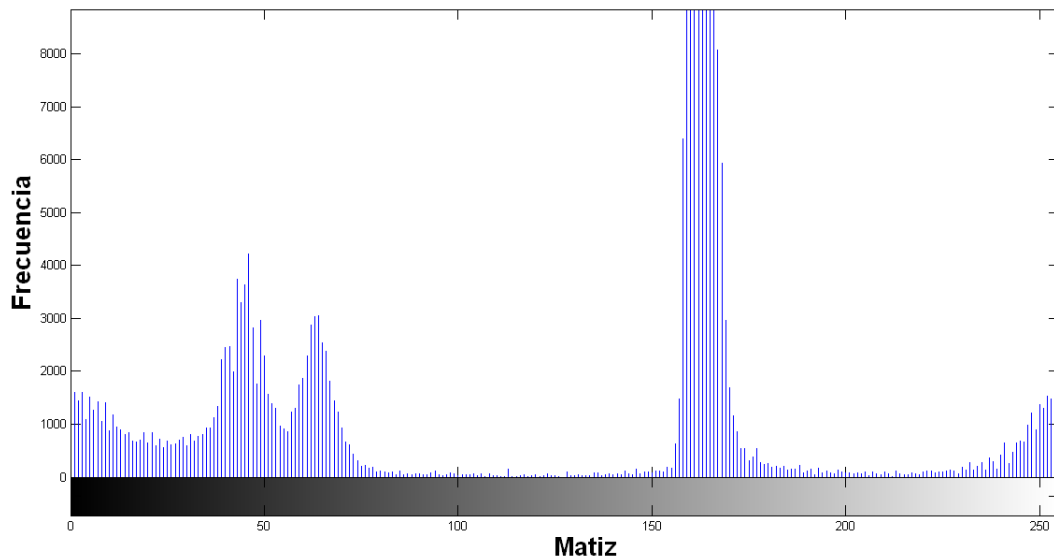


Figura 3.2: Histograma de matiz (H), para una imagen de muestra.

| Objeto | Rango de Intensidades en Matiz | |
|--------------------|-----------------------------------|-----------|
| Fruto Verde | 52 - 100 | |
| Fruto Pintón | 0 - 60 | 250 - 255 |
| Fruto Maduro | 0 - 20 | 210 - 255 |
| Fruto Sobre-maduro | 0 - 255 | |
| Fruto Seco | 0 - 205 | 220 - 255 |
| Fondo | 134 - 178 | |

Tabla 3.1: Rangos de Intensidades en la componente de matiz (H) del espacio HSV.

De la Tabla 3.1 se observa que los objetos de interés no pueden ser discriminados entre sí debido a que sus valores en la componente de matiz no presentan la cantidad de información necesaria, inclusive el intervalo de frecuencia de la clase fruto (sobre-maduro y seco) coincide con la clase fondo, por lo que si se maneja una técnica de segmentación por umbrales fijos, donde los umbrales correspondan al mínimo y máximo del intervalo de frecuencia correspondiente a la clase fondo, se perderá información de la clase fruto, específicamente los frutos de café categorizados como secos y sobre-maduros. Este problema se soluciona al explorar la caracterización del color en su transitividad de las distintas combinaciones entre fondo, fruto sobre-maduro y fruto seco de las componentes de saturación y luminancia. En la Figura 3.4 se muestra una realización correspondiente a la transitividad del color entre el fondo y un conjunto de frutos que presentan solapes de acuerdo a la Tabla 3.1.

En la Figura 3.4 se puede observar el conjunto de coordenadas A, B, C y D, donde A denota la transitividad del color entre fondo y fruto sobre-maduro; B, fruto sobre-maduro y fruto seco; C, fruto seco y maduro; y D fruto maduro y fondo. De las transitividades de color entre los distintos objetos se puede apreciar de la Figura 3.4 que la componente de saturación diferencia la clase fondo de la clase del conjunto de frutos que presentan solapes debido a un cambio fuera del promedio del color en los valores de intensidad.

En la Figura 3.3 se presenta el flujograma desarrollado e implementado para la extracción de fondo y objetos de interés.

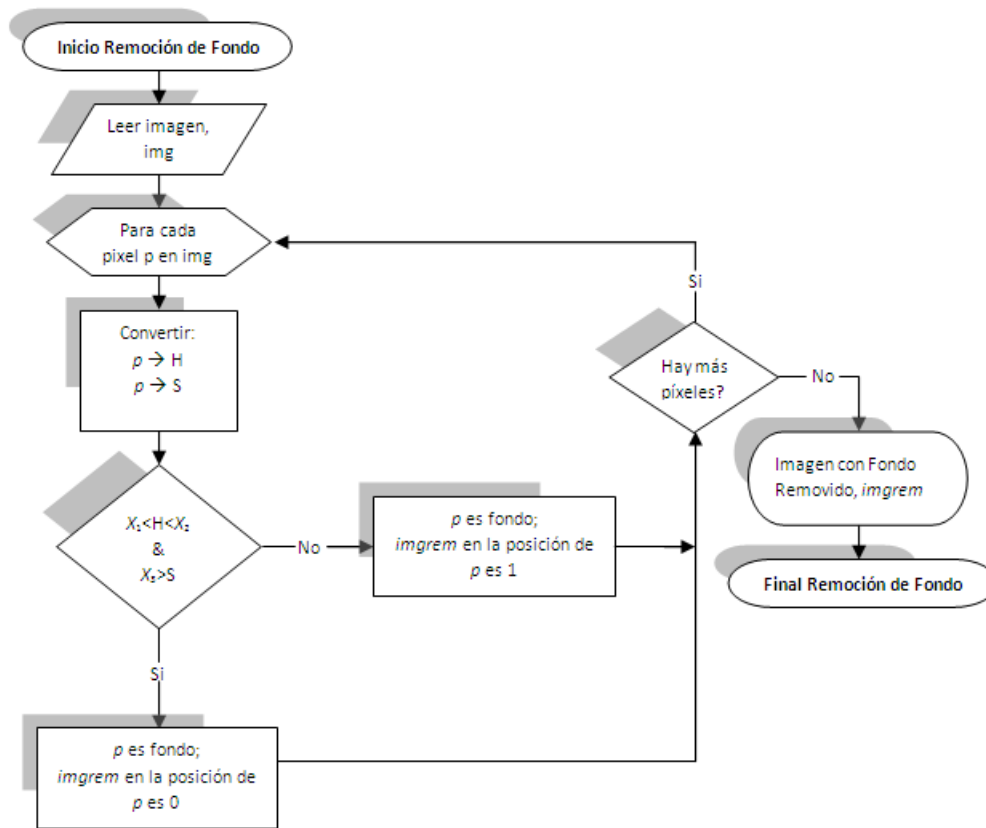


Figura 3.3: Flujograma de Extracción de Fondo.

Para soportar las afirmaciones anteriores con respecto a cómo las componentes de color del espacio HSV determinarían por medio de la técnica de segmentación de umbrales fijos el proceso de extracción de fondo y objetos de interés, se diseña un experimento en el que se validan los umbrales por medio del método de validación cruzada por no contar con un conjunto de muestra la suficientemente grande. Los detalles de cómo se diseñó el experimento y los respectivos resultados se encuentran relacionados en la sección 4.1.

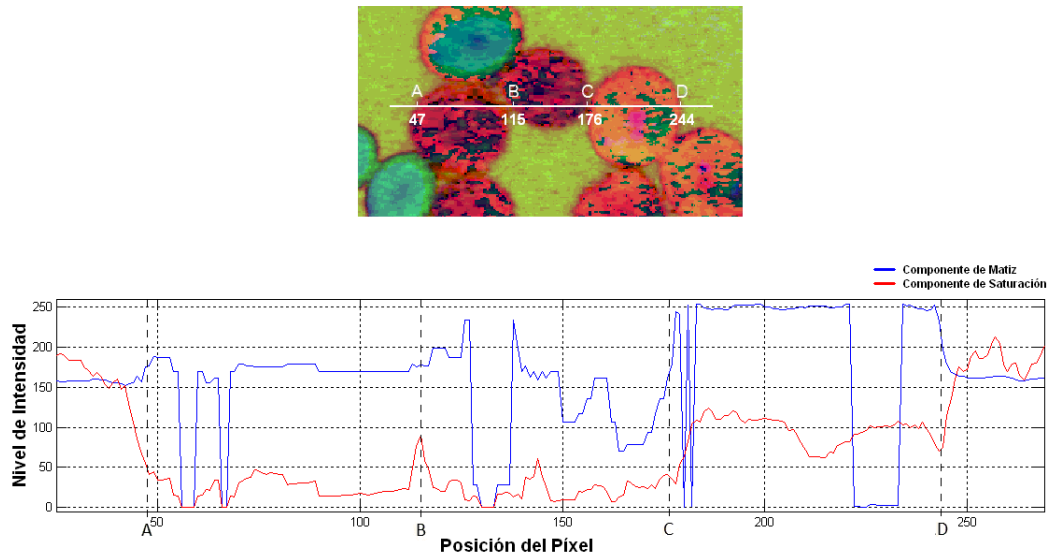


Figura 3.4: Transición de Color en la Componente de Saturación (S).

3.2 Detección de Bordes

El desarrollo de esta investigación se basa en la utilización de la información de textura para identificar los bordes de los frutos de café y así atribuirle a la técnica de segmentación híbrida un aporte sustancial en cuanto a eficiencia de segmentación se refiere (Sección 4.2). Ante esta instancia ya se ha desarrollado por la técnica de segmentación de umbral fijo la remoción del fondo de las imágenes. Este proceso trajo consigo la segmentación de frutos de café que se encontraban aislados de los demás frutos, representando un ahorro en el número de operaciones a realizar (complejidad computacional). Como se definió en la sección 2.7, la complejidad computacional de un algoritmo depende no solo del tiempo de cómputo sino también del consumo de memoria, por lo que se representa el primer proceso de segmentación.




Figura 3.5: Imagen Resultante del Proceso de Extracción de Fondo y Objetos de Interés.

En la Figura 3.5 se muestra la imagen resultante de extraer el fondo y los frutos de café segmentados (frutos de color blanco), en compañía con los frutos de café a segmentar por medio del análisis de textura de un grupo píxeles conexos (texel) de toda la imagen y clasificarlos en una de las tres clases existentes (fondo, fruto segmentado o información de la imagen a segmentar). Para realizar el análisis de textura es necesario definir la dimensión del texel (sección 3.2.1) y evaluar si la clase pertenece a la información de la imagen a segmentar, entonces se extraen las 11 características de textura de la matriz de coocurrencia, las cuales determinarán si la información analizada corresponde a borde o fruto. Este proceso de determinación de la información se enmarca bajo la regla de Bayes del mínimo error. Por tener dos posibilidades, borde o fruto, se desarrolló e implementó un clasificador bayesiano bi-clase (sección 3.2.3) con las características de textura de la matriz de coocurrencia.

En el proceso anterior al de clasificación, se llevó a cabo la reducción del hiperespacio de las características de textura extraídas desde diferentes espacios de color por medio de un selector efectivo de características (sección 3.2.2) basado en la región discriminante de Fisher. En [65] se relaciona distintos métodos de clasificación para seleccionar las características que mejor representen la información de textura de los frutos de café sin presentar información redundante, concluyendo que sólo 5 características de las 121 extraídas no son ortogonales entre ellas. La reducción del hiperespacio de características se ve representado en un ahorro de tiempo de cómputo

por lo que el algoritmo del sistema de segmentación puede categorizarse como un algoritmo eficiente.

3.2.1 Definición del Texel

La definición de la dimensión del texel óptimo es crucial para obtener las características de textura que discriminarán la información de borde del fruto en toda la imagen. Para esto se realizó un estudio exploratorio de la resolución de los bordes de los frutos de café, dado que la naturaleza de los frutos es semejante en tamaño y forma. La dimensión del texel es cuadrada y depende de los factores: tamaño de la imagen, tiempo de cómputo del cálculo de la matriz de coocurrencia y resolución¹ del borde.

Las imágenes que se encuentran en la base de datos tienen una dimensión de 640 píxeles de ancho por 480 píxeles de alto (640x480) limitando la dimensión del texel a números divisibles por la dimensión de la imagen. La selección depende entonces de la relación tiempo de cómputo de la matriz de coocurrencia y resolución del borde. En la Tabla 3.2 se consignan los resultados de tiempo de cómputo según el número de veces que se debe obtener la matriz de coocurrencia para diferentes dimensiones de texel.

| Número de Matrices de Coocurrencia | Dimensión del Texel (píxeles x píxeles) | Tiempo (ms) |
|------------------------------------|--|----------------|
| 76800 | 2x2 | 191 |
| 19200 | 4x4 | 90 |
| 12288 | 5x5 | 74 |
| 4800 | 8x8 | 53 |

Tabla 3.2: Relación Dimensión del Texel versus Tiempo de Cómputo.

Al evaluar los resultados consignados en la Tabla 3.2 en los extremos, se aprecia que para una dimensión del texel de 2x2 píxeles el tiempo de cómputo es considerable si se compara con una dimensión de 8x8 píxeles, pero una dimensión de este tamaño brinda una resolución de borde muy baja al igual que una dimensión de 5x5 píxeles, es decir, los bordes serían representados por un texel de mayor tamaño que de su estado natural produciendo sobre-segmentación en el proceso de segmentación. De acuerdo a las conclusiones de cada dimensión evaluada en tiempo de cómputo, sólo queda disponible

¹Entiéndase como resolución: tamaño o dimensión

dimensiones para texel de 2x2 píxeles y 4x4 píxeles, y se opta por la dimensión de 4x4 píxeles con el sacrificio de un menor tiempo de cómputo en la matriz de coocurrencia a consta de una resolución baja para el caso de la dimensión de 2x2 píxeles para el texel.

Definida la dimensión del texel, se procede a dividir en dimensiones de 4x4 píxeles la imagen en análisis para obtener en cada uno de ellos las respectivas características que se extraen de la matriz de coocurrencia (sección 2.4.1). A manera de representación, se muestra en la Figura 3.6 la división de la imagen en regiones de 4x4 píxeles alternados en los espacios de color RGB y HSV.




Figura 3.6: Representación de la División por Texel de la Imagen a Segmentar.

Con el objetivo de no aumentar el tiempo de cómputo del sistema sólo se analiza los texels correspondientes a los objetos de interés, tal como se muestra en la Figura 3.7B, separando los frutos segmentados luego del proceso de extracción de fondo y objetos de interés (Figura 3.7A).




Figura 3.7: Representación de los Frutos de Café a Segmentar luego del Proceso de Extracción de Fondo.

3.2.2 Selección Efectiva de Características

Para discriminar la información de fondo y objetos de interés, se diseñó un clasificador bayesiano bi-clase capaz de diferenciar la clase de borde y la clase de fruto. Sin embargo, en la sección 2.5 se relacionó la información correspondiente a la importancia entre la ortogonalidad de las características de textura para el diseño del clasificador. En otras palabras, se requiere verificar que las características de textura extraídas de la matriz de coocurrencia no deben presentar información redundante entre ellas al momento de diseñar el clasificador, el cual tiene como meta diferenciar la clase borde de la clase fruto con el menor tiempo cómputo.

El proceso de extracción de características de la matriz de coocurrencia se llevó a cabo en cada una de las componentes de colores de los espacio de color RGB, HSV, Báez, Colores Oponentes y OHTA [8], ante cada combinación posible entre los diferentes tipos de frutos de café. En la Figura 3.8 se muestra en su respectivo orden las muestras tomadas de bordes en unión, muestras de bordes del contorno de los frutos y muestras de frutos. Las muestras se tomaron del espacio de color Báez, específicamente la componente C3.




Figura 3.8: Muestra para el Cálculo de las Características de Textura.

En la Tabla 3.3 se contrasta el comportamiento de las características de textura correspondientes a los casos expuestos en la Figura 3.8, codificando las muestras de borde en unión (3 muestras), borde externo (4 muestras), fruto (6 muestras) en colores azul, rojo, lila y naranja respectivamente.

Por simple inspección visual, en la Tabla 3.3 se nota una amplia variación entre las características de textura en varianza y contraste de las muestras tomadas. Sin embargo, un análisis heurístico no es viable por la cantidad de muestras que se deben analizar ante distintas variables. Esto es, en el análisis de selección efectiva de características se tienen 15 muestras correspondientes a las combinaciones posibles entre los distintos tipos de fruto, de los cuales se extraen 11 texels para su análisis en 5 espacios de color relevantes para el análisis [8], donde 4 de ellos constan de 3 componentes y el restante de 2 componentes. En total se analiza un hiperespacio de 4125 muestras de las cuales se debe realizar su análisis para las 11 características de textura, lo que conlleva a un aumento en el tiempo de cómputo del sistema al igual que el número de operaciones a realizar. Debido a esto se propone un selector efectivo de características que tiene como objetivo reducir por criterio de orgonalidad el número de características a obtener y así aumentar la complejidad computacional del sistema.

| Características de Textura | Borde en Unión | | |
|------------------------------------|----------------|--------|---------|
| Energía | 0.044 | 0.025 | 0.024 |
| Entropía | 4.786 | 5.330 | 5.377 |
| Contraste | 75.833 | 85.229 | 293.340 |
| Homogeneidad Local | 0.277 | 0.181 | 0.089 |
| Coorrelación | 0.661 | 0.583 | 0.901 |
| Tendencia de Clúster | 0.000 | 0.000 | 0.000 |
| Mom. de Diferencia de Orden K | 6.611 | 7.951 | 14.785 |
| Mom. Inv. de Diferencia de Orden K | 0.223 | 0.216 | 0.102 |
| Máxima Probabilidad | 0.118 | 0.049 | 0.028 |
| Directividad | 0.118 | 0.028 | 0.000 |
| Varianza | 86.531 | 69.622 | 352.200 |

| Características de Textura | Borde Externo | | | |
|------------------------------------|---------------|--------|---------|---------|
| Energía | 0.024 | 0.024 | 0.024 | 0.024 |
| Entropía | 5.377 | 5.377 | 5.377 | 5.377 |
| Contraste | 388.924 | 73.153 | 133.208 | 412.056 |
| Homogeneidad Local | 0.075 | 0.216 | 0.181 | 0.085 |
| Coorrelación | 0.740 | 0.580 | 0.576 | 0.885 |
| Tendencia de Clúster | 0.000 | 0.000 | 0.000 | 0.000 |
| Mom. de Diferencia de Orden K | 17.382 | 7.097 | 9.111 | 17.486 |
| Mom. Inv. de Diferencia de Orden K | 0.083 | 0.295 | 0.213 | 0.102 |
| Máxima Probabilidad | 0.028 | 0.028 | 0.028 | 0.028 |
| Directividad | 0.000 | 0.028 | 0.028 | 0.000 |
| Varianza | 481.791 | 86.182 | 148.709 | 458.727 |

| Características de Textura | Fruto | | | | | |
|------------------------------------|-------|-------|-------|-------|-------|-------|
| Energía | 0.097 | 0.062 | 0.051 | 0.209 | 0.144 | 0.115 |
| Entropía | 3.648 | 4.197 | 4.523 | 2.603 | 3.056 | 3.398 |
| Contraste | 4.479 | 4.264 | 4.819 | 0.660 | 1.076 | 2.347 |
| Homogeneidad Local | 0.533 | 0.436 | 0.443 | 0.735 | 0.659 | 0.594 |
| Coorrelación | 0.217 | 0.660 | 0.795 | 0.279 | 0.494 | 0.584 |
| Tendencia de Clúster | 0.000 | 0.000 | 0.000 | 0.000 | 0.000 | 0.000 |
| Mom. de Diferencia de Orden K | 1.563 | 1.778 | 1.819 | 0.563 | 0.771 | 1.139 |
| Mom. Inv. de Diferencia de Orden K | 0.448 | 0.538 | 0.548 | 0.490 | 0.593 | 0.513 |
| Máxima Probabilidad | 0.188 | 0.125 | 0.097 | 0.354 | 0.236 | 0.194 |
| Directividad | 0.271 | 0.118 | 0.125 | 0.486 | 0.354 | 0.313 |
| Varianza | 2.853 | 4.206 | 4.821 | 0.440 | 0.654 | 1.693 |

Tabla 3.3: Características de Textura para los Texels de Muestra.

El proceso de selección efectiva de característica se somete a 3 realizaciones donde la toma de datos de las muestras es aleatoria. Se analiza por el método de relación discriminante de Fisher, el cual cuantifica la separabilidad de cada unas de las características mediante la función IDF (Ec. 3.1), donde μ_1 y σ_1^2 corresponden a la media y varianza respectivamente de las muestras de bordes y μ_2 y σ_2^2 a la media y varianza de las muestras de frutos. Sin embargo en esta investigación se hallarán dos relaciones discriminantes de Fisher, las cuales tienen como objeto discriminar las características de los bordes de unión de un fruto con el centro del fruto y bordes externos con el centro del fruto (Anexo F), y al final se promedian los resultados.

$$IDF = \frac{(\mu_2 - \mu_1)^2}{\sigma_2^2 + \sigma_1^2} \tag{3.1}$$

En la Tabla 3.4 se presenta los resultados más relevantes del método de relación de Fisher asociado con la característica textura y los espacios de color implementados en [8]. Definido el conjunto de características de textura, se entrena el clasificador bayesiano que detectará los bordes correspondientes de la imagen en análisis.

| Características de Textura | Espacio de Color | Componente |
|-------------------------------------|------------------|------------|
| Homogeneidad Local | HSV | H |
| Contraste | RGB | R |
| Varianza | Báez | C3 |
| Momento Diferencias orden K | HSV | H |
| Momento Inverso Diferencias orden K | HSV | H |

Tabla 3.4: Relación Discriminante de Fisher en Relación a las Cinco Características mas Importantes.

Las relaciones discriminantes de Fisher expuestas en la Tabla 3.4 corresponden a la combinación de muestras de bordes en unión, bordes externos y centro de fruto. Sin embargo, en el Anexo F se consignaron los resultados de las relaciones discriminantes de Fisher para el caso de muestras de bordes en unión y muestras de fruto, y muestras de bordes externos y muestras de frutos, con el objetivo de encontrar cuál de los dos casos presenta el menor grado de dificultad para un clasificador y predecir los posibles errores que puede presentar el clasificador al momento de detectar los bordes. De los resultados relacionados en el Tabla 3.5² es claro que las muestras correspondientes

²Resultados relevantes del Anexo F

a bordes externos no presentarán inconvenientes al momento de ser detectados, caso contrario a las muestras de bordes en unión. En otras palabras, dado que la relación discriminante de Fisher no ofrece una separabilidad considerable en las características de texturas extraídas de la matriz de coocurrencia, el clasificador para los casos bordes en unión y frutos de las mismas características de color ocasionará sub-segmentación en el sistema. En la sección 3.3 se diseña e implementa posibles soluciones para el caso de sub-segmentación en el sistema mediante el uso de los descriptores de forma.

| Característica de Textura | Componente de Color | IDF |
|---------------------------|---------------------|------------------|
| Contraste | R | 179,434907051612 |
| Varianza | C3 | 57,3079358626126 |
| Mom. Dif.K | R | 28,6023334567776 |
| Mom. Inv. Dif.K | H | 15,2413985988239 |
| Mom. Dif.K | C3 | 13,1175933376218 |

A. Clase Borde Contorno versus Clase Fruto

| Característica de Textura | Componente de Color | IDF |
|---------------------------|---------------------|------------------|
| Mom. Dif.K | H | 17,8176182999053 |
| Homogeneidad | H | 14,169517136233 |
| Varianza | I3 | 10,1790086006581 |
| Mom. Inv. Dif.K | H | 9,58162871101837 |
| Energia | I3 | 5,99063950870504 |

B. Clase Bordes versus Clase Fruto

| Característica de Textura | Componente de Color | IDF |
|---------------------------|---------------------|------------------|
| Contraste | I3 | 11,4330670325306 |
| Homogeneidad | H | 8,44054456296216 |
| Varianza | H | 8,35706277528729 |
| Mom. Dif.K | H | 6,49540592854069 |
| Mom. Inv. Dif.K | I3 | 6,14116090580869 |

C. Clase Borde Unión versus Clase Fruto

Tabla 3.5: Valores más Altos Obtenidos del Índice Discriminante de Fisher Según las Muestras Tomadas.

3.2.3 Clasificador Bayesiano

El clasificador bayesiano encargado de clasificar si un texel corresponde a la clase borde o clase fruto se basa en la asignación de función de probabilidad (Ec. 3.2) a las clases en análisis.

$$g_i = \ln[p(x|\omega_i)] + \ln[p(\omega_i)] \quad (3.2)$$

Donde $p(x|\omega_i)$ es la probabilidad condicional, representada por la función (Ec. 3.3), de que el elemento X_i pertenezca a la clase ω_i y $p(\omega_i)$ es la probabilidad a priori de ω_i .

$$p(x|\omega_i) = \frac{1}{(2\pi)^{\frac{d}{2}} \cdot |\Sigma_i|^{\frac{1}{2}}} \cdot e^{-0.5 \cdot (x-\mu_i)^t \cdot \Sigma_i^{-1} \cdot (x-\mu_i)} \quad (3.3)$$

x es el vector que contiene la información seleccionada por la relación discriminante de Fisher de las características de texturas extraídas de la matriz de coocurrencia del texel en análisis, μ_i y Σ_i corresponden respectivamente al vector de medias y a la matriz de covarianzas de las características de la clase ω_i y d es la dimensión de los vectores anteriormente descritos.

El entrenamiento del clasificador depende directamente de las muestras seleccionadas para la obtención de las probabilidades a priori (Ec. 3.4 y 3.5), μ_i y Σ_i . El procedimiento de selección de muestras es análogo al cálculo de la relación discriminante de Fisher en un número significativo de repeticiones en diferentes imágenes seleccionadas aleatoriamente.

$$p(\omega_1) = \frac{\textit{Texel Borde}}{\textit{Texel Fruto} + \textit{Texel Borde}} \quad (3.4)$$

$$p(\omega_2) = \frac{\textit{Texel Fruto}}{\textit{Texel Fruto} + \textit{Texel Borde}} \quad (3.5)$$

Determinados los parámetros de entrenamiento del clasificador implementado para la detección de bordes de frutos de café se prosigue con su implementación en el sistema de segmentación en conjunto con el algoritmo de adelgazamiento de bordes propuesto por Lam, Ching y Seong [42], y el etiquetado de cada una de las regiones compuestas

por los bordes detectados. El conjunto de pasos lógicos presentados en la presente sección se resumen en el flujograma (Figura 3.9) del algoritmo a implementar como complemento al sistema de segmentación (Figura 3.3).

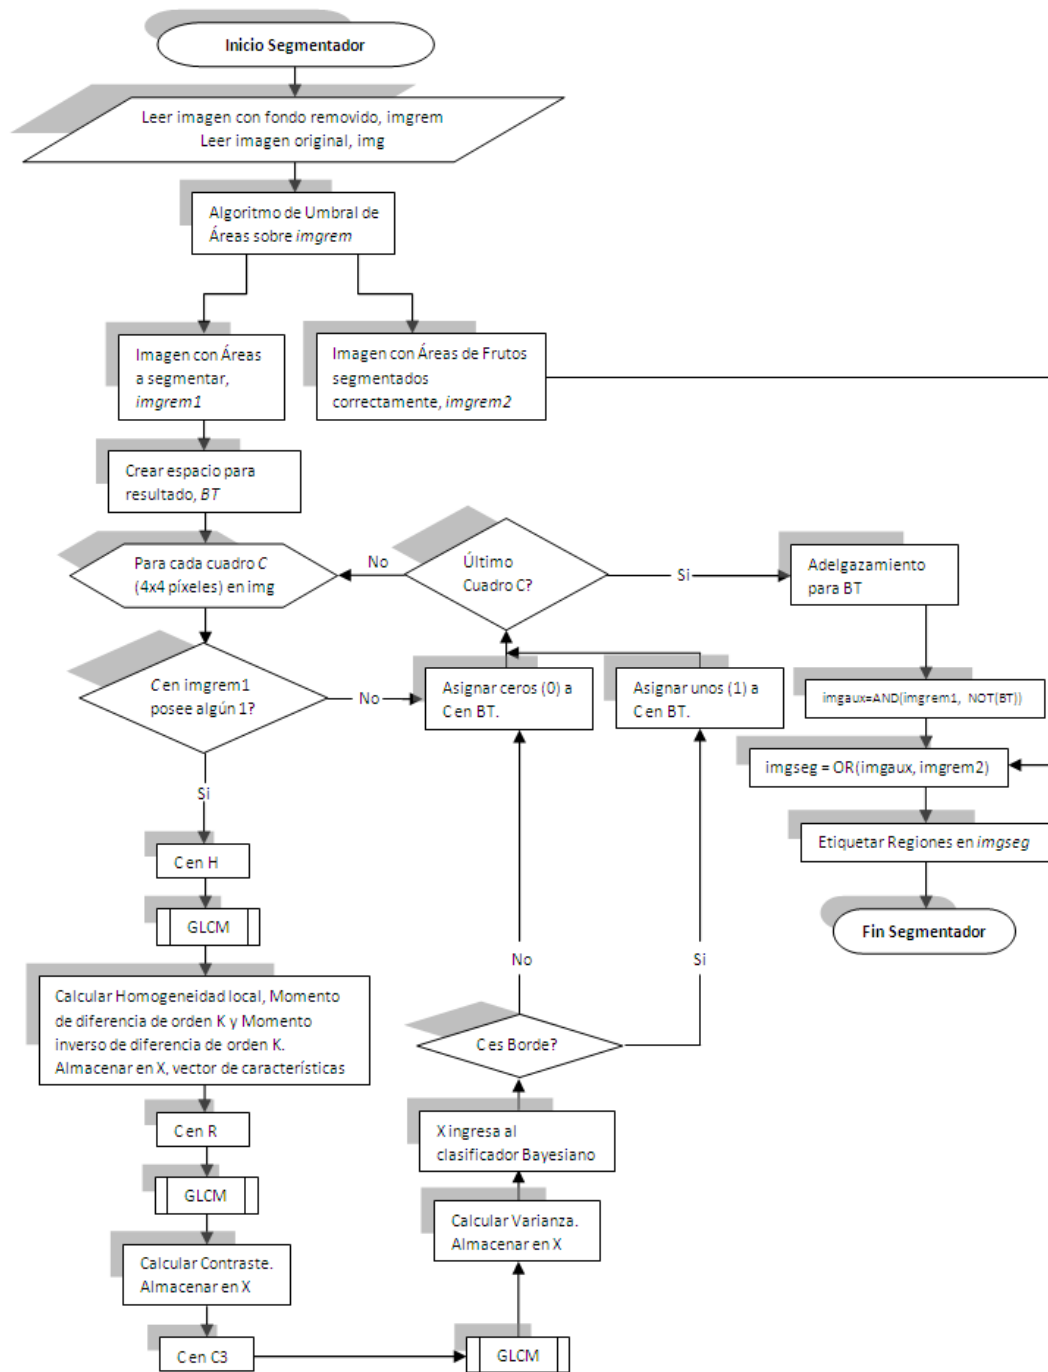


Figura 3.9: Flujograma del Detector de Bordes.

La Figura 3.10 muestra el análisis de la imagen que se encuentra en la Figura 3.5 como resultado de la ejecución del algoritmo detallado en el pseudocódigo (Tabla 3.9) de la presente sección.




Figura 3.10: Imagen Resultante del Proceso de Suavizado de Bordes y Etiqueta de las Regiones.

De la Figura 3.10 se nota la presencia de una instancia de sub-segmentación, la cual es resultado de la predicción de falla del clasificador Bayesiano. Sin embargo, también se planteó como solución el diseño e implementación de un algoritmo de división de instancias de sub-segmentación por medio del uso de los descriptores de forma del fruto de café.

3.3 Descriptores de Forma

Para completar el sistema de segmentación se suavizan por medio de filtros digitales los bordes detectados con el fin de recuperar la forma natural de los frutos de café. En algunos casos se puede presentar que el detector de borde falle a causa de las

condiciones propias de adquisición del sistema de segmentación, es decir, puede que existan dos o más frutos unidos que presenten las mismas características naturales y que las características de la matriz de coocurrencia no brinden la información suficiente. En la Figura 3.11 se muestra un ejemplo donde se sabe que fallará el detector de bordes. Para este caso, se evaluarán descriptores de forma con la ayuda de operadores morfológicos que nos permitan inferir los bordes omitidos por el detector de bordes de textura del fruto de café.



Figura 3.11: Ejemplo de Error del Detector de Bordes (Instancia de Sub-segmentación, Sección 4.3).

Dada la naturaleza de la forma del fruto de café colombiano se decidió realizar la implementación y evaluación de los descriptores de forma derivados de la firma y los índices de convexidad y concavidad. Propuestas desarrolladas por Escorcía en [15] y [23].

La primera propuesta [23] trató de dividir las instancias sub-segmentadas por el uso de la firma y los operadores morfológicos de erosión y dilatación. Los resultados obtenidos en cuanto a la división de las instancias de sub-segmentación fueron satisfactorios pero el número de operaciones realizadas era mayor que las pertenecientes al algoritmo detector de borde, además la cantidad de información que se perdía de un fruto al momento de erosionarlo no se podía recuperar en la misma cantidad con el proceso de dilatación. En la sección 4.4 se muestra los resultados del proceso de evaluación del sistema de segmentación incorporando la propuesta [23] al igual que la propuesta [15]. Ésta última consistía en extraer las instancias de sub-segmentación para analizarles los índices de concavidad al contorno de la región y mediante su obtención encontrar la distancia más corta entre los índices para trazar una línea divisoria y así dividir la región en sus correspondientes regiones. A diferencia de la propuesta [23] no se perdía información alguna correspondiente a los frutos y el número de operaciones realizadas se encontraba por debajo del 90% del total de las operaciones.

En la propuesta [15] se extraen las instancias que presenten sub-segmentación a una nueva imagen por medio del modelo matemático de área (Ec. 3.6), el cual relaciona el área convexa (AC) y el área (A) normalizada con respecto al área de los frutos de café. Esto con el objetivo de seleccionar frutos con pequeñas imperfecciones causadas por el proceso de reconstrucción de los bordes detectados en la sección 2.3.

$$f = \frac{AC - A}{A} \quad (3.6)$$

Cada instancia de sub-segmentación se le llamó mini-imagen, las cuales fueron tratadas independientemente por dos enfoques:

- ▷ **Análisis de la Firma:** Este enfoque consiste en trazar una línea divisoria en el contorno de la mini-imagen cuya distancia fuese máxima y a su vez cada punto de la línea perteneciera al contorno, luego encontrar los puntos cóncavos por el criterio de proximidad a la línea divisoria.
- ▷ **Análisis de Concavidad:** En este enfoque se calcula el índice de concavidad de los contornos de la mini-imagen en máscaras de dimensión $n \times n$ píxeles mediante la función (Ec. 3.7), donde M corresponde a la máscara y B a la mini-imagen binaria.

$$concavidad(j) = \sum_{j-1}^{j+1} \sum_{x=1}^n \sum_{y=1}^n M_j \cap B \quad (3.7)$$

El enfoque de análisis de la firma no es recomendable debido a que es un procedimiento iterativo de alto costo computacional por el número de comparaciones que debe realizar para determinar la validez de las líneas divisorias que se tracen para dividir las instancias de sub-segmentación. Los resultados obtenidos fueron satisfactorios para el caso de que la instancia de sub-segmentación correspondiese a dos frutos, mientras que si la instancia correspondía a más de dos frutos el sistema presentaba un incremento en las operaciones mayor al 80% del caso de instancias de dos frutos y en todos los casos la división de los frutos no era correcta.

Para el análisis de concavidad se estableció con base a un estudio exploratorio la dimensión en píxeles de una máscara que recorre el contorno de la mini-imagen detectando el número de concavidades. Dado las condiciones controladas en la que fueron adquiridas las imágenes se define una máscara con dimensión de 15x15 píxeles debido al tamaño de los frutos de café. En la Figura 3.12 se ejemplifica una muestra ideal con el objetivo de detectar las concavidades denotadas por los círculos rojos según la variación de la dimensión de la máscara. Los resultados se exponen en la Tabla 3.6 evidenciando que la dimensión de la máscara seleccionada por inspección visual detecta un número concavidades cercano por encima del número del caso que se analice. En la sección 4.3 se presenta el diseño de experimento que se realizó para validar la escogencia de la dimensión de la máscara que detecta el número de concavidades con base a los índices de concavidad.





Figura 3.12: Muestra Ideal de Concavidad en Frutos de Café.

| Dimensión de la Máscara (píxeles x píxeles) | Número de Concavidades Detectadas |
|--|--------------------------------------|
| 3 x 3 | 32 |
| 5 x 5 | 24 |
| 7 x 7 | 20 |
| 9 x 9 | 20 |
| 11 x 11 | 12 |
| 13 x 13 | 7 |
| 15 x 15 | 3 |
| 17 x 17 | 1 |
| 19 x 19 | 0 |

Tabla 3.6: Relación Dimensión de la Máscara versus Concavidades Detectadas.

Detectados los puntos de concavidad de los casos de interés, se procedió a realizar la división de la instancia de sub-segmentación mediante el trazo de una línea de longitud no mayor a 40 píxeles para uniones cortas y no mayor a 65 píxeles para uniones largas, entendiéndose como regiones cortas y largas las que se muestran en la Figura 3.14A y Figura 3.14B respectivamente. La definición de la longitud en píxeles de la línea divisoria se basó en el estudio exploratorio de muestras del grupo de pruebas del experimento para definir el umbral de concavidad al medir la menor y mayor distancia en píxeles en los casos de uniones entre frutos.

El algoritmo desarrollado antes de trazar la línea divisoria valida los casos: 1. Si un punto cóncavo detectado ya fue seleccionado para el trazo de una línea no será tomado en cuenta para futuras realizaciones y 2. Entre varias líneas divisorias se selecciona la de menor longitud. En la Figura 3.13A se muestra la imagen a tratar por el proceso de sub-segmentación en conjunto con una extracción del caso interés dividido en sus respectivas regiones tratadas (Figura 3.13B).




A. Imagen en Presencia de Frutos Subsegmentados



B. Mini-imagen detectada y corregida por el algoritmo de sub-segmentación

Figura 3.13: Detección y Corrección de Instancias de Sub-Segmentación.



A. Región Corta de Unión B. Región Larga de Unión

Figura 3.14: Posibles Uniones de los Frutos de Café.

En la Figura 3.15 se muestra el resultado final del sistema de segmentación con la integración de las imágenes correspondientes a la extracción de fondo y objetos de interés (Figura 3.7), y la resultante del proceso de sub-segmentación (Figura 3.13).




Figura 3.15: Segmentación Final.

El conjunto de pasos lógicos (algoritmo) llevados a cabo para alcanzar los resultados demostrados en la sección 3.3 se muestra a manera de flujograma en la Figura 3.16.

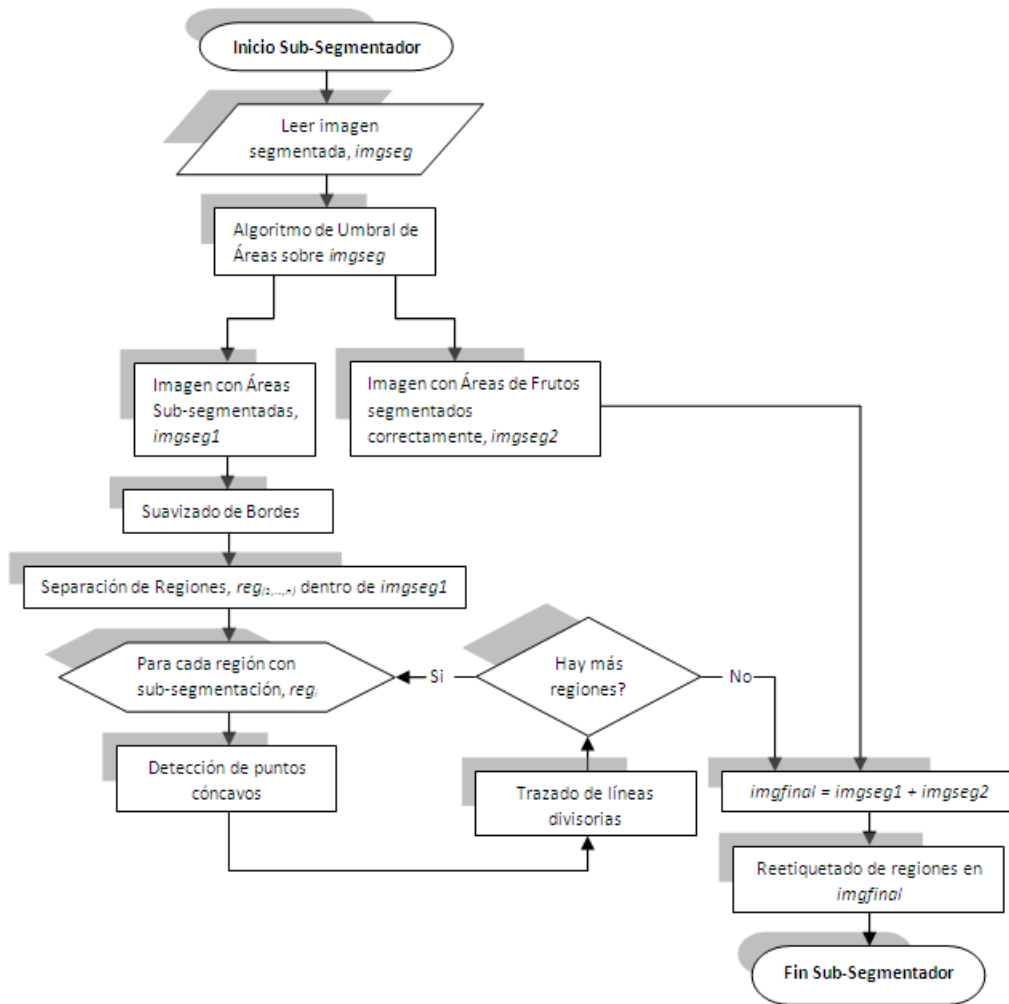


Figura 3.16: Flujograma del Sub-segmentador.

Con la implementación de este último algoritmo al sistema se logra un aumento en su eficiencia superando el 95% para el mejor de los casos (sección 4.5) pero, de acuerdo a lo explicado en el apartado de complejidad computacional, todo algoritmo debe ser evaluado en el peor de los casos. Los análisis de resultados de este tipo se encontrarán en la sección 4.5.

Para evaluar los requerimientos computacionales y asegurar la viabilidad de la implementación hardware, se diseñó el sistema de segmentación de tal forma que

utilizara los mínimos consumos de memoria y tiempo de cómputo posibles con el fin de aumentar la complejidad computacional del sistema. Sin embargo, estas medidas son calculadas por medio de las técnicas de profiling y benchmarking, técnicas de complejidad computacional empírica, lo que indica una variación de ellas dependiendo de la plataforma hardware en que se evalúen. En la sección 4.5 se muestra el diseño de la prueba para la obtención de la complejidad computacional empírica al igual que la analítica. El número de operaciones que realiza los algoritmos que integran el sistema de segmentación pueden ser calculada analíticamente con el fin de determinar qué tan complejo es el sistema diseñado ante la invariabilidad de la plataforma hardware.

De acuerdo a la información consignada hasta este punto en el capítulo Descripción General del Sistema, se describió a partir de las secciones 3.1, 3.2 y 3.3 el conjunto de pasos lógicos de cómo se diseñaron los algoritmos de segmentación. Aunque, la definición de las variables, parámetros y limitantes de cada algoritmo se encuentran restringido al conjunto de imágenes de la base de datos disponible, no significa que el sistema propuesto falle sino que necesita ser ajustado de acuerdo al procedimiento que se describe en la sección 3.4.

3.4 Procedimiento General

3.4.1 Extracción de fondo y objetos de interés

Para el proceso de extracción de fondo y objetos de interés es significativamente importante que el fondo presente un contraste distinto al de los objetos. Esto permite discriminar por medio del estudio del modelo cromático HSI los valores de intensidades correspondientes al fondo y objetos, para ser discriminados por la técnica de segmentación de umbrales fijos.

- ▷ Variables: Valores de intensidad del fondo y frutos.
- ▷ Parámetros: Umbrales en H y S (Si el fondo es derivado del color azul).
- ▷ Limitantes: Condiciones de adquisición de las imágenes.

3.4.2 Detección de bordes

El detector de bordes diseñado en esta investigación tiene como limitantes el tamaño en píxeles del borde del fruto y los posibles texels a definir, estas limitaciones son producto de cómo se controle el ambiente de adquisición de las imágenes. Para definir la dimensión del texel se debe tener en cuenta si éste es divisible por el tamaño de la imagen dado que no se pueden omitir píxeles en este proceso de segmentación. De igual forma, la dimensión del texel presenta una fuerte relación con el tamaño del borde de los frutos debido a que una mala definición del texel puede causar sub-segmentación si no existe una medida cuantitativa de textura, o sobre-segmentación si la dimensión del texel es muy grande comparada con el tamaño del borde del fruto. Sin embargo, hasta este punto no hay información suficiente para definir la dimensión del texel, sólo limitaciones al respecto. El tiempo de cómputo que se requiere para obtener el número de características extraídas de la matriz de coocurrencia, necesarias para discriminar la clase borde de la clase fruto, es el factor que define la dimensión del texel debido a que el sistema de segmentación se encuentra orientado a disminuir el número de operaciones posibles con fin de aumentar la complejidad computacional del sistema.

- ▷ Variables: Tiempo de cómputo.
- ▷ Parámetros: Dimensión del texel.
- ▷ Limitantes: Tamaño del borde del fruto y tamaño de la imagen.

3.4.3 Descriptores de forma

El algoritmo diseñado para dividir las instancias de sub-segmentación resultantes del proceso de detección bordes se encuentra basado en los índices de concavidad presentes en los frutos, los cuales presentan un mismo tamaño por las condiciones de adquisición controlada de las imágenes. Los índices de concavidad se calculan a partir de una máscara (grupo conexo de píxeles) la cual recorre todo el contorno de la instancia de sub-segmentación determinando los índices de concavidad. Los posibles índices de concavidad son escogidos por el criterio de la línea divisoria, la cual tiene una distancia mínima y máxima en píxeles correspondientes a la juntura de los frutos que se muestran en la Figura 3.14.

- ▷ Variables: Índices de concavidad.
- ▷ Parámetros: Tamaño en píxeles de la máscara y distancia mínima y máxima de una línea divisoria en píxeles.
- ▷ Limitantes: Tamaño del fruto.

Capítulo 4

Pruebas y Resultados

En el presente capítulo se llevarán a cabo las pruebas y análisis de los resultados correspondientes de cómo se diseñaron e implementaron los algoritmos del sistema de segmentación de frutos de café propuesto. El conjunto de pasos lógicos en que se presentan las pruebas y cómo se explican los resultados obtenidos son los mismos estructurados en los capítulos 2 y 3, es decir, se comienza explicando la extracción de fondo y objetos de interés de la imagen, luego se prosigue con el cálculo de la matriz de coocurrencia para extraer las características de textura que serán analizadas por la relación discriminante de Fisher con el objetivo de obtener el menor número de características no ortogonales que discrimine entre la clase borde de la clase de fruto, usando un clasificador bayesiano para detectar los bordes. El último algoritmo que compone el sistema de segmentación es el encargado de detectar regiones sub-segmentadas con el objetivo de dividir las en sus áreas correspondientes por medio de los descriptores de forma (sección 2.4.2) y operadores morfológicos (Anexo D).

Una vez explicado el diseño e implementación del sistema de segmentación se procede con su evaluación por medio de los descriptores de desempeño de [10] (método analítico) y se constatan los resultados obtenidos por la subjetividad del diseñador.

Finalmente se presenta un análisis detallado de la complejidad computacional por el método de análisis (sección 2.7), para calcular el número de operaciones que realiza el sistema de segmentación y así determinar el consumo de memoria y tiempo de cómputo, que requiere el sistema. Luego, por medio de los métodos de benchmarking y

profiling, se calcula la complejidad computacional (métodos empíricos) que definen los requerimientos hardware sobre la plataforma BeagleBoard Rev. C3 ¹.

4.1 Extracción del Fondo y Objetos de Interés

La hipótesis de extraer el fondo de los objetos de interés por medio de la técnica de umbrales fijos de segmentación, donde dos de los tres umbrales se encuentran definidos por el mínimo y máximo correspondiente al conjunto de datos con mayor frecuencia del histograma de color de la componente de matiz que corresponde al fondo, y el tercer umbral por el punto de transición de color entre la clase fondo de la clase fruto en la componente de saturación, se valida por medio del diseño de experimento al evaluar el desempeño de un clasificador bi-clase encargado de discriminar el fondo de los objetos de interés en cada una de las imágenes de la base de datos con su correspondiente imagen de referencia. La variable de evaluación es el error de clasificación que se estima a partir de la proporción de imágenes etiquetadas incorrectamente por la ecuación (4.1).

$$d(img, clase) = \begin{cases} 1 & \text{Si } d(img) \neq clase \\ 0 & \text{Si } d(img) = clase \end{cases} \quad (4.1)$$

Donde d es el clasificador, img es la imagen en análisis y $clase$ es la clase a la que pertenece la imagen. El desempeño se analiza por medio de los indicadores de la matriz de confusión (Anexo E).

Para estimar el error de clasificación entre la clase fondo y la clase fruto se utiliza el método de validación cruzada. En el cual se dividen en un conjunto de entrenamiento y de prueba. El clasificador se diseña usando las muestras de entrenamiento y luego se evalúa obteniendo el error de clasificación para las muestras de prueba. Con base en el error obtenido se predice el desempeño del clasificador ante nuevas muestras por medio de la matriz de confusión (ver Tabla 4.1). Para obtener una medida confiable del desempeño, el conjunto de muestras debe ser lo suficientemente grande y, los conjuntos de entrenamiento y de prueba deben ser independientes.

¹Hoja de datos del fabricante: http://beagleboard.org/static/BBSRM_latest.pdf

El error de clasificación depende directamente de la escogencia de la terna de umbrales que se explicaron en la sección 3.1.

GT: Segmentación Referencia h1=Componente menor de Matiz
 IM: Segmentación del Algoritmo h2=Componente mayor de Matiz
 SF: Si es Fruto s=Componente de Saturación
 NF: No es Fruto

| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
|---|----|---------------------|----------|---------------------|--|----|--|----|--|------------|--|------------|--|----|----|---------|--------|----|----|--------|----------|--|--|---------------------|--|--------------------|--|----|--|----|--|------------|--|------------|--|----|----|---------|--------|----|----|--------|----------|
| <table style="margin: auto; border-collapse: collapse;"> <tr> <td colspan="2" style="padding: 5px;">h1=135 h2=173 s=101</td> <td colspan="2" style="padding: 5px;">h1=134 h2=175 s=115</td> </tr> <tr> <td colspan="2" style="padding: 5px; text-align: center;">IM</td> <td colspan="2" style="padding: 5px; text-align: center;">IM</td> </tr> <tr> <td colspan="2" style="padding: 5px; text-align: center;">SF NF</td> <td colspan="2" style="padding: 5px; text-align: center;">SF NF</td> </tr> <tr> <td style="padding: 5px; text-align: center;">GT</td> <td style="padding: 5px; border-right: 1px solid black; border-bottom: 1px solid black;">SF</td> <td style="padding: 5px; border-bottom: 1px solid black;">8627175</td> <td style="padding: 5px; border-bottom: 1px solid black;">583811</td> </tr> <tr> <td style="padding: 5px; text-align: center;">GT</td> <td style="padding: 5px; border-right: 1px solid black;">NF</td> <td style="padding: 5px;">490031</td> <td style="padding: 5px;">53213543</td> </tr> </table> | | h1=135 h2=173 s=101 | | h1=134 h2=175 s=115 | | IM | | IM | | SF NF | | SF NF | | GT | SF | 8627175 | 583811 | GT | NF | 490031 | 53213543 | <table style="margin: auto; border-collapse: collapse;"> <tr> <td colspan="2" style="padding: 5px;">h1=134 h2=178 s=101</td> <td colspan="2" style="padding: 5px;">h1=134 h2=178 s=95</td> </tr> <tr> <td colspan="2" style="padding: 5px; text-align: center;">IM</td> <td colspan="2" style="padding: 5px; text-align: center;">IM</td> </tr> <tr> <td colspan="2" style="padding: 5px; text-align: center;">SF NF</td> <td colspan="2" style="padding: 5px; text-align: center;">SF NF</td> </tr> <tr> <td style="padding: 5px; text-align: center;">GT</td> <td style="padding: 5px; border-right: 1px solid black; border-bottom: 1px solid black;">SF</td> <td style="padding: 5px; border-bottom: 1px solid black;">8609548</td> <td style="padding: 5px; border-bottom: 1px solid black;">559932</td> </tr> <tr> <td style="padding: 5px; text-align: center;">GT</td> <td style="padding: 5px; border-right: 1px solid black;">NF</td> <td style="padding: 5px;">507649</td> <td style="padding: 5px;">53237431</td> </tr> </table> | | h1=134 h2=178 s=101 | | h1=134 h2=178 s=95 | | IM | | IM | | SF NF | | SF NF | | GT | SF | 8609548 | 559932 | GT | NF | 507649 | 53237431 |
| h1=135 h2=173 s=101 | | h1=134 h2=175 s=115 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| IM | | IM | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| SF NF | | SF NF | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| GT | SF | 8627175 | 583811 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| GT | NF | 490031 | 53213543 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| h1=134 h2=178 s=101 | | h1=134 h2=178 s=95 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| IM | | IM | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| SF NF | | SF NF | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| GT | SF | 8609548 | 559932 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| GT | NF | 507649 | 53237431 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |

Tabla 4.1: Matrices de Confusión.

De acuerdo a los resultados obtenidos de las matrices de confusión consignados en la Tabla 4.1 se puede determinar el error positivo y negativo; la especificidad, la efectividad, la precisión y la eficiencia de los clasificadores entrenados para cada terna de umbrales, al promediar las eficiencias respectivas a cada grupo de imágenes por la función (Ec 4.2) se obtiene el desempeño del clasificador. En la Tabla 4.2 se consignan los resultados de las métricas obtenidas a partir de la matriz de confusión, sin embargo no existe una medida que discrimine la selección de la terna de umbrales, empero se puede concluir que para cualquier terna de la Tabla 4.2 se obtiene un desempeño del alrededor del 98% para un intervalo de confianza del 95%.

$$\eta = \text{promedio} \left(\frac{\sum \text{diag}_i}{N \cdot D} \right) \quad \text{Donde } i = 1, 2, \dots, n \quad (4.2)$$

Donde η representa el desempeño total del clasificador, N el tamaño de la población de las muestras, D la dimensión de las muestras y diag representa la diagonal de una matriz de confusión que es especificada por i .

| Umbral | Error positivo (%) | Error negativo (%) | Especificidad (%) | Efectividad (%) | Precisión (%) | Desempeño del Clasificador (%) |
|---------------------------|--------------------|--------------------|-------------------|-----------------|---------------|--------------------------------|
| h1=135 h2=173 s=101 | 5.3748 | 1.0852 | 98.9148 | 94.6252 | 93.6618 | 98.2932% |
| h1=134 h2=175 s=115 | 4.7739 | 1.2274 | 98.7726 | 95.2261 | 92.9320 | 98.2586% |
| h1=134 h2=178 s=101 | 5.5680 | 1.0408 | 98.9592 | 94.4320 | 93.8935 | 98.3031% |
| h1=134 h2=178 s=95 | 5.8869 | 0.9784 | 99.0216 | 94.1131 | 94.2200 | 98.3103% |

Tabla 4.2: Desempeño del Clasificador por Grupo de Entrenamiento.

A pesar de que para cualquier terna se obtiene las mismas métricas de rendimiento para el clasificador, la razón entre efectividad y error negativo consignados en la Tabla 4.3 demuestran con relación a la imagen referencia que los píxeles mal clasificados por la variación del conjunto de umbrales puede pertenecer a información de fondo.

| Umbral | Efectividad/Error Negativo |
|---------------------------|----------------------------|
| h1=135 h2=173 s=101 | 87.1958% |
| h1=134 h2=175 s=115 | 77.5829% |
| h1=134 h2=178 s=101 | 90.7287% |
| h1=134 h2=178 s=95 | 96.1873% |

Tabla 4.3: Razón entre Efectividad y Error Negativo.

De acuerdo a los resultados obtenidos de la Tabla 4.3 se concluye que la terna umbrales a seleccionar son 134 y 178 para la componente de matiz y 95 para la componente de saturación. El procedimiento de selección de cada umbral seleccionado

para cada grupo de entrenamiento se basó en la heurística del diseñador. Quien procuró minimizar el error de fruto tanto cuantitativamente como cualitativamente mediante el proceso descrito en la Tabla 4.4.

- 1: Se seleccionan dos umbrales en la componente de matiz que delimiten el conjunto de datos de mayor frecuencia dentro del histograma de intensidades (Ver Figura 3.2).
- 2: Se evalúan los valores seleccionados por medio de un análisis cualitativo de las imágenes seleccionadas, procurando eliminar cuanto más se pueda de los píxeles correspondientes a la clase fondo sin eliminar los que correspondan a la clase fruto, teniendo en cuenta que los frutos sobre-maduros y secos podrán ser recuperados en un siguiente paso, obteniendo así dos nuevos valores de umbral en la componente de matiz.
- 3: Dado que los pasos anteriores no solo eliminan la clase fondo, sino también gran parte de los frutos sobre-maduros y secos, se procede a seleccionar un tercer umbral, el cual diferencie este tipo de frutos correspondientes a la clase fruto de la clase fondo. Para ello se identifica una línea de píxeles dentro de la imagen que contenga información de la clase fondo y los tipos de frutos sobre-maduros y secos de la clase fruto.
- 4: Se identifica por medio de una gráfica de intensidades (Figura 3.3) los rangos de valores dentro de la componente de saturación que discriminen entre la clase fondo y los tipos de frutos sobre-maduros y secos de la clase fruto, eligiendo así un valor de umbral.
- 5: Se realizan pruebas utilizando los tres valores para una evaluación del umbral en la componente de saturación.
- 6: Se realizan pruebas utilizando los tres valores para una reevaluación de éstos, considerando el impacto que generan pequeños cambios en cada uno de ellos.

Tabla 4.4: Heurística del Diseñador para Validar los Umbrales.

En la Figura 4.1 se muestra el resultado del proceso de extracción de fondo y los objetos de interés es una imagen binaria (negro representa el fondo y blanco, los objetos de interés). En la sección 3.2 se mencionó que uno de los efectos colaterales de remover el fondo es que los frutos de café que se encuentren aislados de los demás quedan segmentados, indicando que el resto de la información de la imagen corresponde a las regiones que se analizarán a continuación por sus características de textura y forma.




Figura 4.1: Extracción de Fondo y Objetos de Interés.

Para la misma muestra representada en la Figura 4.1 se enseña la importancia de

la escogencia de la componente de saturación como complemento a la técnica de segmentación de umbrales fijos por medio de la Figura 4.2, donde se puede apreciar la pérdida de información de los frutos sobre-maduros y secos.




Figura 4.2: Extracción de Fondo y Objetos de Interés con Umbrales en H.

4.2 Detección de Bordos

En la sección 3.2 se detalló el procedimiento desarrollado por el algoritmo de segmentación para separar los frutos de café usando la información de textura para implementar un clasificador Bayesiano encargado de discriminar la información de un texel entre la clase borde o fruto.

El calculo de la matriz de coocurrencia para extraer las características de textura y la implementación del clasificador dependen directamente de la dimensión del texel. Un texel muy pequeño no puede brindar la información textura necesaria para discriminar entre las clases de interés, en la Figura 4.3 se muestra como el clasificador falla en gran proporción para la clase borde unión, en la cual se expuso en la sección 3.2.2 que no existe una separabilidad en la características de textura como para discriminar si pertenece a una clase en específico; hecho que aumenta el número de instancias de sub-segmentación degenerando la eficiencia del algoritmo [10]. En cambio, para un

texel muy grande (Figura 4.4) los resultados son opuestos que para el caso descrito anteriormente, en este caso la eficiencia del algoritmo de segmentación es degenerada por las instancias de sobre-segmentación resultante, las cuales no son tratadas en el diseño de los algoritmos que se proponen en esta investigación.




Figura 4.3: Detección de Bordos con un Texel de Dimensión 2x2 Píxeles.




Figura 4.4: Detección de Bordos con un Texel de Dimensión 8x8 Píxeles.

Una dimensión de 4x4 píxeles para el texel a analizar fue la que se definió en la sección 3.2.1 a implementar el diseño del algoritmo, en la Figura 4.5 se muestra los resultados obtenidos, dentro de los cuales se puede notar la ausencia de instancias de sobre-segmentación y la reducción de las instancias de sub-segmentación en comparación para un texel de dimensión de 2x2 píxeles (Figura 4.3).




Figura 4.5: Detección de Bordes con un Texel de Dimensión 4x4 Píxeles.

4.3 Descriptores de Forma

Para dar soporte a la escogencia de la máscara de detección de los índices de concavidad es necesario ejecutar el algoritmo diseñado (Tabla H.3) e integrar los resultados obtenidos al sistema de segmentación para luego obtener el desempeño del sistema por medio de las métricas de [10].

La definición de la dimensión de la máscara, sobre la cual se determina el índice de concavidad, se realiza mediante la minimización de función de costos (Ec. 4.3). Esta función optimiza el tamaño de la máscara de modo que el área bajo la curva del rendimiento de las regiones de sub-segmentación detectadas sea la menor y se mantenga el área bajo la curva de las regiones de sobre-segmentación descritas por la métricas de [10], es decir, que su implementación tenga como consecuencia un número menor de regiones de sub-segmentación e igual número de regiones de sobre-segmentación.

$$J(dm) = A_{sub} \quad (4.3)$$

Donde dm hace referencia a la dimensión de la máscara y A_{sub} a las regiones que presentan sub-segmentación en la imagen analizada.

En la Tabla 4.5 se consignan los resultados obtenidos del experimento y se relacionan los errores obtenidos en el caso de las áreas de interés (sub-segmentación y sobre-segmentación).

| Dimensión de la Máscara <i>píxeles x píxeles</i> | Área Bajo la Curva | |
|---|--------------------|--------------------|
| | sub-segmentación | sobre-segmentación |
| 3x3 | 3 | 5 |
| 5x5 | 3 | 4.5 |
| 7x7 | 2.1 | 3.7 |
| 9x9 | 0.8 | 3.2 |
| 11x11 | 0.8 | 2.6 |
| 13x13 | 0.5 | 1.4 |
| 15x15 | 0.1 | 0.6 |
| 17x17 | 0 | 0.2 |
| 19x19 | 0 | 0.2 |

Tabla 4.5: Rendimiento de Área Bajo la Curva para Distintas Dimensiones de Máscaras.

De acuerdo a los resultados consignados en la Tabla 4.5 se concluye que para una máscara de tamaño de 15x15 píxeles no se obtiene instancias de sub-segmentación y las instancias de sobre-segmentación presentes se atribuyen al algoritmo que utiliza la información de textura como clasificador de bordes.

4.4 Evaluación de Desempeño del Sistema de Segmentación

En las secciones 4.2 y 4.3 se presentó el diseño del clasificador del detector de bordes y el algoritmo de división de instancias de sub-segmentación en conjunto con los resultados obtenidos de una imagen seleccionada aleatoriamente del grupo de entrenamiento en que se basó la selección de la terna de umbrales para extraer el fondo y

los objetos de interés (sección 4.1). De la Figura 3.13 se evalúa subjetivamente bajo las apreciaciones: imagen correctamente segmentada aunque con pérdida de información en los bordes debido al texel definido para la extracción de características de textura para el entrenamiento del clasificador de bordes. Ahora, es necesario valorar las apreciaciones de evaluación subjetiva por un modelo de evaluación analítica presentada por [10] (sección 2.6) a nivel global, es decir, validar el desempeño del sistema de segmentación ante imágenes diferentes pero de las mismas características.

El algoritmo principal del sistema de segmentación es el que corresponde a la detección de bordes por medio del clasificador bayesiano bi-clase razón por la cual se decide validar el sistema de segmentación a partir de las entradas al clasificador, es decir, el vector x que contiene las características de textura escogidas por la relación discriminante de Fisher. El experimento de validación es el mismo que el desarrollado para la definición de los umbrales para extraer el fondo y los objetos de interés; se tienen 4 grupos de 5 imágenes cada uno, se entrena el clasificador por el proceso descrito en la sección 3.2.3 para cada grupo de imágenes y se obtiene el desempeño del clasificador en función de las métricas, regiones correctamente detectadas, regiones sub-segmentadas y regiones sobre-segmentadas definidas por [10].

En la sección 3.2.2 se concluyó que el mejor desempeño lo otorgan las características de textura descritas en la Tabla 3.4 con su respectiva componente de color. En las Figura 4.6 y 4.7 se muestran los resultados de las métricas de [10] correspondiente a las regiones correctamente detectadas, regiones sobre-segmentadas respectivamente, No se presenta grafica de detección de la regiones de sub-segmentación debido a que no existen datos relacionados debido al algoritmo desarrollado para tal propósito.




Figura 4.6: Regiones Detectadas Correctamente.




Figura 4.7: Sobresegmentación.

A partir de la Figura 4.6 se puede concluir que el sistema de segmentación propuesto en esta investigación alcanza resultados satisfactorios al presentar un desempeño de 98% de detecciones correctas en función de una tolerancia del 50% a 70%. A pesar que se obtiene un alto desempeño del sistema de segmentación, éste no alcanza los resultados de una segmentación trivial gracias a la pérdida de información que se obtiene al momento de detectar los bordes de los frutos a través de la información de textura y

la presencia mínima de instancias de sobre-segmentación ante una tolerancia del 70% al 85% (Figura 4.7).

De manera comparativa se muestra por medio de la Figura 4.8 el desempeño del sistema de segmentación en cada una de las etapas descritas en el diagrama de bloque del sistema (Figura 3.1) con el objeto de presentar las mejoras implementadas a partir de la extracción de fondo y objetos de interés de la imagen. La primera mejora fue el diseño e implementación del detector de bordes constituido por un clasificador bayesiano bi-clase encargado de detectar a partir de la información de textura de un texel, si este pertenecía a clase borde o clase fruto (sección 3.2). La segunda mejora fue la implementación del algoritmo de Lam, Ching y Seong [42], que trajo consigo aumento del desempeño del clasificador ante una tolerancia del 50% al 80% (ver grafica de color rojo de la Figura 4.8), a pesar de que a una tolerancia mayor el desempeño es menor, sin embargo el área debajo la curva denota capacidad del sistema de segmentación. La última mejora es la que otorga el algoritmo de sub-segmentación por medio de la localización de las regiones y su respectiva lógica de división en sus respectivas regiones. En la Tabla 4.6 se presentan las métricas relacionadas al desempeño en función de la tolerancia del sistema y al área bajo la curva que relaciona la capacidad del sistema de segmentación; conociéndose como segmentación trivial el área bajo la curva descrita por las coordenadas (0,100), (100,100) y (100,0).

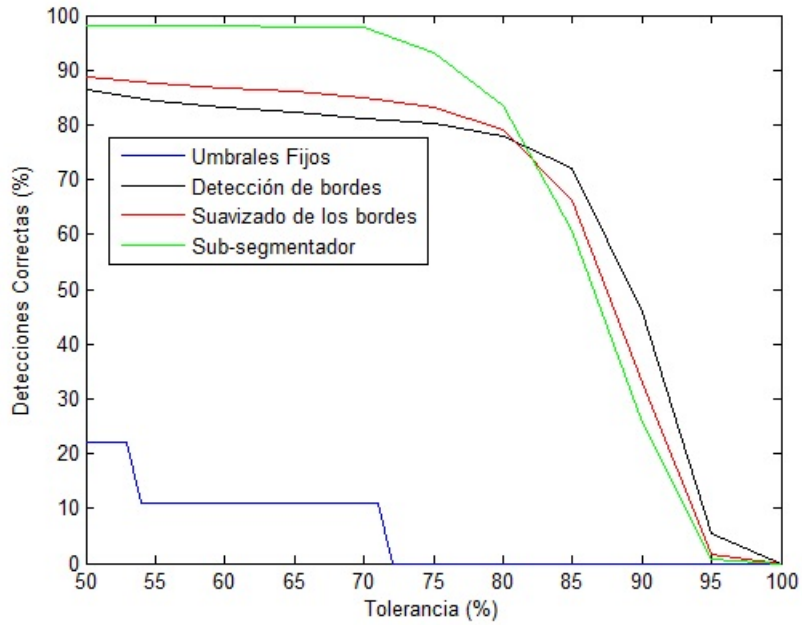


Figura 4.8: Mejoras de las Etapas del Sistema de Segmentación Propuesto.

| | Detecciones Correctas (%) | | Área Bajo la Curva |
|-------------------------|---------------------------|-------|--------------------|
| | T=50% | T=80% | |
| Umbrales Fijos | 22 | 0 | 288.86 |
| Detección de Bordes | 86 | 78 | 698.57 |
| Suavizado de los Bordes | 88 | 79 | 696.86 |
| Sub-segmentador | 98 | 83 | 753.72 |

Tabla 4.6: Rendimiento del Sistema de Segmentación.

Las opciones de estudio para el desarrollo del sistema de segmentación recopiló las ideas de aportes futuros de las investigaciones [6], [8], [51]; en las Figuras 4.9, 4.10 y 4.11 se muestra el desempeño de regiones correctamente segmentadas y sub-segmentadas respectivamente, al igual que en la Tabla 4.7 en contraste con el sistema de segmentación propuesto.




Figura 4.9: Sistema de Segmentación Propuesto en [6].




Figura 4.10: Sistema de Segmentación Propuesto en [8].




Figura 4.11: Sistema de Segmentación Propuesto en [51].

| Sistema de Segmentación | Detecciones Correctas (%) | | Área Bajo la Curva | |
|-------------------------|---------------------------|-------|--------------------|--------------------------------|
| | T=50% | T=80% | Desempeño | Instancias de Sub-segmentación |
| SRG | 71 | 27 | 357.55 | 17 |
| Fuzzy | 70 | 23 | 320 | 202.8 |
| Basado en Textura | 89 | 76 | 626.161 | 105.23 |
| STC-Center | 95 | 83 | 701 | 10.1 |
| Propuesto | 98 | 83 | 753.72 | 0 |

Tabla 4.7: Comparación de Rendimiento de los Sistemas de Segmentación.

Las investigaciones [8] y [6] presentan similitud en los aspectos técnicos de las adquisiciones de las imágenes que conforman la base de datos al igual que la presencia de todos los frutos de variedad Arabica. Por lo que se pueden establecer parámetros comparativos entre los sistemas de segmentación; como primera instancia, se observa que para una tolerancia del 50%, los sistemas de segmentación SRG y Fuzzy presentan un desempeño máximo cercano al 70% de detecciones correctas y a medida que la tolerancia aumenta su desempeño decrece rápidamente y mucho más en el caso del sistema SRG. Caso contrario por el sistema propuesto en [8], el cual mantiene un desempeño alrededor del 85% de las regiones detectadas correctamente ante una tolerancia del 50% al 70%; el sistema de segmentación de [8] fue desarrollado como investigación previa con el objetivo de evaluar la influencia de las características de

textura de los frutos de café en el proceso de segmentación. En la Tabla 4.7 también se encuentra relacionada la capacidad de los sistemas de segmentación que se define como el área bajo la curva, se puede observar que el sistema propuesto presenta una capacidad mucho mayor que los sistemas SRG y Fuzzy mientras que la capacidad del sistema de [6] es muy similar a la del sistema propuesto donde la diferencia radica en la implementación del algoritmo sub-segmentación.

En [51] se alcanzó un desempeño del 95% de detecciones correctas con una capacidad de 701 (Área bajo la curva de segmentación) para el sistema de segmentación STC Center, sin embargo, tanto el desempeño como la capacidad del sistema se encuentran basadas en las hipótesis: 1. El tiempo de cómputo que requiere el sistema de segmentación es muy grande, evitando la implementación a una plataforma hardware y 2. Para lograr obtener un gran desempeño se sacrifica la implementación del algoritmo a causa del aumento en el tiempo de cómputo.

4.5 Complejidad Computacional

La arquitectura hardware del diseño del sistema de segmentación es similar a la diseñada en [8]. Sin embargo, tal como se planteó en la sección 2.7, la complejidad computacional se encuentra directamente relacionada al consumo de los recursos de una máquina, es decir, el consumo de memoria en función al número de operaciones determinan qué tan complejo computacionalmente es un algoritmo con respecto a otro, mientras que el tiempo de cómputo solo demuestra si una plataforma hardware brinda los suficientes recursos para ejecutar el algoritmo.

Para el sistema de segmentación diseñado e implementado se obtienen el número de operaciones realizadas para completar su objetivo (método de evaluación anatómica) y se propone también los métodos de evaluación benchmarking y profiling (métodos de evaluación empíricos) para determinar el tiempo de cómputo asociado al número de operaciones a realizar ante cada instancia o etapa que estructura el sistema (Figura 3.1) con su respectivo consumo de memoria. A continuación se detalla en conjunto a los pseudocódigos correspondientes el número de operaciones realizadas según los algoritmos que integran el sistema de segmentación.

- ▷ **Extracción de Fondo y Objetos de Interés** En el pseudocódigo que se relaciona en la Tabla H.1 se observa el manejo de 4 variables enteras correspondientes a img , $imgrem$, H y S , donde la dimensión de la imagen en análisis es de 640×480 píxeles, Si se asume 2 Bytes por cada variable entera entonces se necesita un espacio de memoria disponible de 2400 KB. El número de operaciones a realizar está dado por la relación $640 \times 480 \times 15$, donde 15 denota las operaciones realizadas en los ciclos para del análisis.
- ▷ **Dector de Bordes** El diseño del algoritmo de detección de bordes (Tabla H.2) se fragmento para su análisis de complejidad computacional en 3 funciones,
1. Espacio de color: donde se obtienen las componentes de interés (R, H, C3) de cada texel para extraer las características de textura,
 2. El cálculo de la matriz de coocurrencia,
 3. La lógica de detección de bordes del clasificador Bayesiano y
 4. Adelgazamiento y etiquetado.
- 1: Convertir un píxel de la imagen en las 3 componentes de color necesaria para el análisis de textura se maneja por 3 variables enteras y 3 reales, indicando así un espacio de memoria de 5400 KB al asumir 2 Bytes por variable entera y 4 Bytes por variable real. El número de operaciones a realizar está dado por la relación $640 \times 480 \times 10$, donde 10 denota las operaciones realizadas en los ciclos para del análisis.
 - 2: El cálculo de las características de textura por medio de la matriz de coocurrencia tiene consigo un consumo de memoria asociado a la función $40 \times f \times c$ KB, donde $f \times c$ es la dimensión del texel al que se le calcula las características de textura y 40 corresponde a 4 asignaciones en variables reales a priori de los ciclos de cálculo de la matriz de coocurrencia y 6 asignaciones en variables reales dentro de los ciclos, el espacio de memoria requerido se calcula con base a la asunción de 4 Bytes por variable. El número de operaciones a realizar está dado por la función $8 \times f \times c$, donde 15 denota las operaciones realizadas en los ciclos para del análisis.
 - 3: El clasificador Bayesiano requiere 48 manejo de variables enteras y 46 variables reales debido a la media, varianza y covarianza que requiere para el cálculo de probabilidad el clasificador para los 160×120 texels. Al asumir 2 Bytes por variable entera y 4 Bytes por variable real, resulta que se necesita un espacio de memoria de 5250 KB. El número de operaciones a realizar está dado por la relación $160 \times 120 \times 25$, donde 25 denota las operaciones realizadas en los ciclos para del análisis.
 - 4: Según el diseño del algoritmo, la función de adelgazamiento se puede presentar como con un consumo de memoria y número de operaciones de $2 \times N$ adicionales al proceso de detección de bordes (item 1, 2 y 3).

- ▷ **Descriptores de Forma** Análogo al proceso descrito de detección de bordes se divide en 1. Recorrido del contorno identificando número de concavidades y 2.

Trazo de la línea divisoria.

- 1: Según la información presentada en el sección 2.7 el algoritmo diseñado se representa por la función $O(N^2 + 3N)$ para el consumo de memoria y $O(N^2)$ para el número de operaciones.
- 2: Análogo al item anterior, $2xN$ para el consumo de memoria y $O(KT)$ para el número de operaciones

En los trabajos referentes al diseño e implementación de sistemas de segmentación de frutos de café relacionados en el estado del arte no se ha estipulado un análisis de la complejidad computacional del sistema. La única estimación que plantean como complejidad computacional es el tiempo cómputo pero tal como se expresó en la sección 2.7, éste proviene de un método empírico dependiente de los recursos computacionales de la plataforma hardware en la que se ejecute. Razón por la cual en esta investigación se propone en detalle por el método analítico el número de operaciones y el consumo de memoria que requiere el sistema de segmentación desarrollado, también se entrega de manera comparativa el tiempo de cómputo que estipula el sistema de segmentación para su ejecución en un equipo cómputo y en un sistema dedicado (BeagleBoard) por medio de los métodos empíricos benchmarking y profiling (Tabla 4.8).

En la Tabla 4.9 se presentan las características técnicas de las plataformas usadas para la ejecución del sistema de segmentación con el fin de comparar los resultados obtenidos y demostrar que el sistema de segmentación propuesto se encuentra diseñado para su ejecución en un sistema de bajos recursos técnicos.

| | Benchmarking | | Profiling | |
|-----------|--------------|-------------|-----------|-------------|
| | PC | BeagleBoard | PC | BeagleBoard |
| Imagen 1 | 0.811 | 0.765 | 0.784 | 0.811 |
| Imagen 2 | 0.729 | 0.773 | 0.717 | 0.752 |
| Imagen 3 | 0.852 | 0.838 | 0.834 | 0.862 |
| Imagen 4 | 0.891 | 0.746 | 0.880 | 0.919 |
| Imagen 5 | 0.903 | 0.974 | 0.901 | 0.915 |
| Imagen 6 | 0.798 | 0.689 | 0.815 | 0.912 |
| Imagen 7 | 0.951 | 1.027 | 0.911 | 1.006 |
| Imagen 8 | 0.827 | 0.921 | 0.789 | 0.908 |
| Imagen 9 | 0.814 | 0.780 | 0.837 | 0.804 |
| Imagen 10 | 0.746 | 0.685 | 0.836 | 0.935 |

Tabla 4.8: Tiempo de Cómputo en Segundos.

| | PC | BeagleBoard |
|---------------|---------------------------------|----------------------|
| Procesador | Intel Core 2 Duo E8500 3.16 GHz | ARM Cortex A8 600MHz |
| Memoria Cache | 6MB L2 | 256 KB L2 |
| RAM | 8 GB | 128 MB |
| MIPS | 38362.3 | 2000 |

Tabla 4.9: Características de Plataforma Hardware.

Los tiempos de cómputos que requiere el sistema de segmentación en completar su tarea en un sistema incrustado (BeagleBoard) presenta un tiempo aproximadamente igual en comparación con un equipo cómputo (PC), a pesar de que la plataforma BeagleBoard presenta una capacidad de procesamiento menor a causa de la estructura del procesador, memoria RAM y que ésta maneja un sistema operativo GNU-LINUX en el que se ejecutan los algoritmos que componen el sistema de segmentación propuesto.

En la Tabla 4.8 se relaciona el tiempo de cómputo estimado por el método de benchmarking que se llevó a cabo tras la conformación de un grupo de 10 imágenes que fueron seleccionadas a criterio del diseñador como imágenes que podrían representar un alto tiempo de cómputo por el número de regiones (frutos de café) a segmentar. La sumatoria de los tiempos cómputos del grupo total de imágenes seleccionadas define el tiempo de cómputo total del sistema. De igual forma, se procedió a estimar por el método profiling el tiempo de cómputo con la premisa de otorgar al total de pesos sinápticos el 90% del promedio por etapa del método de benchmarking con el fin de

diferenciar el método benchmarking del profiling. A partir de la premisa anterior, se observa que el método profiling presenta una menor estimación del tiempo de cómputo en comparación con el método benchmarking debido a que la estructura del algoritmo se secuencial, es decir, se debe completar una tarea de un proceso para comenzar otra.

Capítulo 5

Conclusiones y Trabajos Futuros

El sistema de segmentación propuesto en esta investigación evidenció la importancia de las características de textura de los frutos de café en su proceso de segmentación. Sin embargo, se notó la fuerte dependencia de la información de las características de textura con las condiciones de adquisición de las imágenes. Aunque las imágenes adquiridas son de buena calidad, no están libres de brillo y sombras. El color de selección de fondo azul oscuro presenta un fuerte contraste en los bordes de los frutos de café variedad Coffea Arabica: verde, pintón y maduro pero para el caso de los frutos sobre-maduro y secos, las características de color del fondo coinciden con las características de los frutos, causando pérdida de información. Como solución al contraste del fondo y los frutos sobre-maduros y secos se estudió la percepción del color del sistema de visión humano para diferenciar entre colores y se encontró que las componentes de luminancia y saturación del espacio de color HSV ofrecen la información necesaria para discriminar el fondo de los objetos de interés.

El diseño del detector de bordes se basó en los pilares de extracción de características de textura de la matriz de coocurrencia y la selección efectiva de características por el criterio de relación discriminante de Fisher, del cual se obtuvieron las siguientes 2 especificaciones para la separabilidad de los datos: 1. La información brindada por la varianza en la componente C3 de Báez y el contraste en R de RGB permite la fácil diferenciación entre la clase borde externo y la clase fruto para la detección de los bordes del contorno de los frutos. 2. Existe una alta correlación de los datos pertenecientes a la clase fruto y clase borde unión para los casos de igual características de color en los

frutos por lo que es difícil establecer un conjunto de características de textura para el clasificador sea capaz de detectar los bordes de unión.

El proceso de detección de bordes no tiene como única variable las características de textura, sino también la resolución de los bordes detectados por medio del un elemento estructural (texel), el cual exhibe un compromiso entre tiempo de cómputo de la matriz de coocurrencia y la resolución del texel. En el experimento de establecer la dimensión del texel se concluyó que depende directamente de la longitud en píxeles de los bordes de los frutos y a partir de este criterio se comienza a sacrificar resolución para reducir tiempo de cómputo.

Las instancias de sub-segmentación son causadas por la no detección de los bordes entre los frutos. Este hecho degenera el desempeño del sistema de segmentación por lo que se plantearon 2 enfoques como solución a estas instancias. El primer enfoque se basó en el estudio de la firma del contorno del fruto y el uso de los operadores morfológicos de erosión y dilatación para dividir la instancia de sub-segmentación en sus respectivas regiones, el enfoque brindó resultados satisfactorios a costa de un alto tiempo de cómputo. Mientras que el segundo enfoque, división de las instancias de sub-segmentación por medio de los índices de concavidad y convexidad, presentó un alto desempeño en la división de las instancias en sus respectivas regiones y a un tiempo de cómputo no mayor al 15% del tiempo del detector de bordes.

El sistema de segmentación propuesto alcanzó un desempeño superior al 95% ante una tolerancia del 70% y con una capacidad del 75%, donde el desempeño contabiliza los objetos de una imagen como correctamente segmentados y la capacidad se refiere a la invariabilidad del sistema ante la tolerancia que sometido al ser evaluado.

La motivación de llevar a cabo esta investigación se basó en el hecho de desarrollar un sistema de segmentación escalable a una plataforma hardware con el fin de reducir costos de producción y aumentar la calidad del producto, motivo por el cual se propuso evaluar la complejidad computacional del sistema de segmentación directamente en el sistema incrustado BeagleBoard y estimar por diferentes métodos el tiempo de cómputo y consumo de memoria (requerimientos hardware) del sistema de segmentación teniendo en cuenta que una plataforma como la BeagleBoard no alcanzará

a completar la tarea requerida en un tiempo igual o menor al tiempo de un equipo cómputo. Sin embargo, es posible asignarle las operaciones matriciales las operaciones de los espacios de color y las características de textura al procesador digital de señales (DSP) y el resto del diseño del algoritmo al procesador con el fin de disminuir el tiempo de cómputo. Otra sugerencia a trabajo futuro es optimizar los algoritmos que componen el sistema de segmentación en función de la complejidad computacional estimada por el método profiling.

Por último, se presentan dos ideas de mejora para el sistema de segmentación desarrollado: 1. Integrar el método de segmentación de umbrales fijos para extraer el fondo de los objetos de interés y a partir de estos determinar el número de puntos de concavidad para separar o segmentar las regiones de interés, esto trae consigo un aumento considerable en la capacidad del sistema de segmentación y un acercamiento al concepto de segmentación ideal, siempre y cuando las condiciones de adquisición sean controladas y sobre todo, los frutos de café no deben presentar tallos adheridos. 2. Implementar sobre una plataforma hardware multi-núcleo el sistema de segmentación comenzando por procesamiento GNU/CPU.

Bibliografía

- [1] Al-Muhari, H. Fleury, M y Clark, A. (2006). Computationally Efficient Quantitative Testrin of Image Segmentation with a Genetic Algorithm. University of Essex. Colchester, United Kingdom. 2.6
- [2] Amador, J. (2004). Adquisición y Procesamiento de Imágenes Estereoscópicas y Modelado de Mundos 3D, para su Implementación y Exploración de Ambientes. [Versión Electrónica]. Universidad de las Americas. Puebla - Mexico. 2.3.1, 2.4.1
- [3] Baase, S. Van Gelder, A. (2000). Computer Algorithms. Introduction to Design and Analysis. Addison-Wesley. 2.7
- [4] Bennedsen, B. Peterson, D. (2005). Identification of Apple Stem and Calyx Using Unsupervised Feature Extraction. American Society of Agricultural Engineers. Vol.47 p.889-894 2.8
- [5] Betancur, J. Prieto, F. (2002). Segmentación de Granos de Café Mediante Métodos de Crecimiento de Regiones. Tesis para optar al Título de Ingeniero Electrónico. Universidad Nacional de Colombia Sede Manizales. Manizales - Colombia. 1.1, 1.2, 1.5, 2.2, 2.8
- [6] Betancur, J. Prieto, F. (2006). Segmentación de Granos de Café Mediante Métodos de Crecimiento de Regiones. Rev.Fac.Nal.Agr.Medellín-Colombia. Vol.59, No.1. p.3311-3333. 1.1, 1.2, 2.2, 2.8, 4.4, 4.9, 4.4
- [7] Betancur, J. Marengo, C. Niebles, R. (2008). Segmentación de Imágenes de Frutos de Café Mediante Métodos de Ajuste de Contornos. Tesis para optar al Título de Ingeniero Electrónico. Universidad del Norte. Barranquilla - Colombia. 1.2, 2.8

- [8] Betancur, J. Mora, J. Viera, J. (2008). Segmentación de Imágenes de Frutos de Café Utilizando Información de Textura. Tesis para optar al Título de Ingeniero Electrónico. Universidad del Norte. Barranquilla - Colombia. 1.2, 2.2, 2.4.1, 2.8, 3.2.2, 3.2.2, 3.2.2, 4.4, 4.10, 4.4, 4.5
- [9] Blasco, J. Aleixos, N. Moltó, E. (2007). Computer vision detection of peel defects in citrus by means of a region oriented segmentation algorithm. Science Direct, Journal of Food Engineering. Vol.81 p.535-543 2.8
- [10] Bowyer, K. Min, J. y Powell, M. (2004). Automated Performance Evaluation of Range Image Segmentation. IEEE Workshop on Application of Computer Vision. Pag, 163-168. 1.4, 2.6, 4, 4.2, 4.3, 4.4
- [11] Buitrago, D. (2005). Agente para el Procesamiento Digital de Imágenes en 2D en Ambientes Distribuidos. Universidad Manuela Beltrán. Bogotá- Colombia. 2.4.1
- [12] Bulanon, D. Kataoka, T. Ota, Y. Hiroma, T. (2002). AE-Automation and Emerging Technologies A Segmentation Algorithm for the Automatic Recognition of Fuji Apples at Harvest. Science Direct, Biosystems Engineering. Vol.83 p.405-412 2.8
- [13] Bulanon, D. Hiroma, T. Kataoka, T. Ota, Y. (2004). A machine Vision System for the Apple Harvesting Robot. [Versión electrónica]. Agricultural Engineering International: the CIGR Journal of Scientific Research and Development. 1.1
- [14] Bustos, O. Mallea, A. Herrera, M. (2006). Introducción al Procesamiento de Imágenes Digitales. Universidad Nacional de Córdoba. Argentina. 2.3.1
- [15] Campos, A. Escorcia, J. Nuñez, J. (2009). Algoritmo para el Sub-Segmentador de Imágenes de Granos de Café. Tesis para optar al Título de Ingeniero Electrónico. Universidad del Norte. Barranquilla - Colombia. 1.2, 3.3
- [16] Celenk, M. (June 1988). Proc. Int. Conf. on Computer Vision and Pattern Recognition. Ann Arbor MI. USA, 5-9 p. 437. 2.3.1
- [17] Chen, P. Pavlidis, T. (1989). Segmentation by Texture Using a Cooccurrence Matrix by Split Merge Algorithm. IEEE Transaction Computer Graphic and Image Processing. Vol.10, p.172-182. 2.4.1

- [18] Covarrubias, R. (2001). Sistema de Visión Artificial para el Control de Calidad del Melón. Instituto Tecnológico de Chihuahua. 2.8
- [19] Crelier, R. U.S. 6151703. Scotts Valley: US. Inprise Corporation - Company. 1.4
- [20] Daza, G. y L. Sanchez. (2004). PCA, KPCA y MANOVA sobre señales de voz en imágenes de posturas labiales y audio. Tesis para optar al Título de Ingeniero Electrónico. Facultad de Ingeniería y Arquitectura, Universidad Nacional de Colombia, Manizales. p.78 2.5
- [21] Duda, R. Hart, P. Stork, D. (1998). Pattern Classification. John Wiley and Sons. USA. 2.5
- [22] Eckhardt, U. (2005). Segmentation of Boundaries into Convex and Concave Parts. Hamburger Beiträge zur Angewandten Mathematik. University of Hamburg, Hamburg - Germany. 2.4.2
- [23] Escorcía, J. Escudero, L. Morillo, L. (2009). Análisis Morfológico de frutos de Café en Cereza para la División de Regiones que Corresponden a Instancias de Sub-Segmentación. Tesis para optar al Título de Ingeniero Electrónico. Universidad del Norte. Barranquilla - Colombia. 1.2, 3.3
- [24] Federación Nacional de Cafeteros de Colombia (2007). El Comportamiento de la Industria Cafetera Colombiana durante el 2007. Recuperado Agosto 7, 2010 de <http://www.federaciondecafeteros.org> 1.1
- [25] Ferreira, W. (2004, Junio 17). Piden a Estados Unidos que intervenga para aliviar la crisis del Café. *UITA - Secretaría Regional Latinoamericana*. Recuperado Agosto 6, 2010 de <http://www.rel-uita.org/internacional/crisis-cafe.htm> 1.1
- [26] Filipe, S. Alexandre, L. (2006). Improving Face Segmentation in Thermograms using Image Signatures. University of Beira Interior. 6200-Covilhã, Portugal. 2.4.2
- [27] Flores, A. Mendez, A. (2008). Detección Estable de los Bordes de la Oreja en Imágenes 2D. Lidetea Universidad Lasalle. Mexico-Mexico. Vol.13, No.2, p.195-208. 2.4.1

- [28] García, E. (2001, Junio 15). La Robotización de la Recolección de los Cítricos. *Instituto Valenciano de Investigaciones Agrarias*. Recuperado Septiembre 10, 2010 de http://www.mapa.es/ministerio/pags/biblioteca/revistas/pdf_vrural/Vrural_2001_131_42_44.pdf 2.8
- [29] Gonzalez, R. Woods, R. (2002) Digital Image Processing. Prentice Hall - USA. 2.1, 2.1, 2.2, 2.3.2
- [30] Guevara, J. (2002, Septiembre 12). El Café en la Economía Colombiana. *Federación Nacional de Cafeteros de Colombia*. Recuperado Agosto 6, 2010 de <http://www.colombia.com/especiales/2002/cafe/generalidades.asp> 1.1
- [31] Hans du Buf, J. Reed, T. (1993). A Review of Recent Texture Segmentation and Feature Extraction Techniques. *IEEE Transaction Image Understanding*. Vol.3, p.359-372 2.4.1
- [32] Hayashi, S. Kanuma, T. Sakaue, O. (1997). Study on tomato harvesting robot. [Versión electrónica]. *International symposium on fruit, nut and vegetable production engineering*. 1.1
- [33] Hernandez, J. Prieto, F. (2004). Clasificación de Frutos de Café Según su Etapa de Maduración Basada en Redes Neuronales Artificiales. Tesis para optar al Título de Magister en Automatización Industrial. Universidad Nacional de Colombia Sede Manizales. Manizales - Colombia. 1.1, 1.4, 1.5
- [34] Informe sobre el Comercio y el Desarrollo de 2003 (2003). *Conferencia de las Naciones Unidas sobre el Comercio y el Desarrollo, UNCTAD E-News*. 1.1
- [35] Intervención del presidente de Brazil, Lula Da Silva (2005)., *II Conferencia Mundial del Café*. 1.1
- [36] Jaramillo, M. Fernandez, J. Martinez, E. (2000). Implementación del Detector de Bordes de Canny sobre Redes Neuronales Celulares. Universidad de Extremadura. Badajoz - España. 2.4.1
- [37] Jimenez, A. Osorio, G. (2002). Análisis del Comportamiento de Descriptores de la Matriz de Coocurrencia en la Extracción de Características de Textura en Imágenes

- Digitales. Tesis para optar al Título de Ingeniero Electrónico. Universidad Nacional de Colombia Sede Manizales. Manizales - Colombia. 1.4, 1.5, 2.4.1
- [38] Karch, P. Zolotová, I. (2010). An Experimental Comparison of Modern Methods of Segmentation. 8th IEEE International Symposium on Applied Machine Intelligence and Informatics. 1.2
- [39] Kondo, N. Ling, P. Nishitsuji, Y. Ting, K. (1996). Visual feedback guided Robotic Cherry Tomato Harvesting. [Versión electrónica]. Transactions of the ASAE. 1.1
- [40] Kondo, N. Ahmad, U. Monta, M. Murase, H. (2000). Machine vision based quality evaluation of Iyokan orange fruit using neural networks. Science Direct, Computers and Electronics in Agriculture. Vol.29 p.135-147 2.8
- [41] Koster, A. Muñoz, X. (2009). Graphs and Algorithms in Communication Networks: Studies in Broadband, Optical, Wireless, and Ad Hoc Networks. Springer. 2.7
- [42] Lam, L. Ching, S. Seong, L. (1995). Thinning Methodologies - A Comprehensive Survey. IEEE Transactions on Pattern Analysis and Machine Intelligence. Vol.14 No.9 p.879 3.2.3, 4.4
- [43] Lana, M. Tijskens, L. Van Kooten, O. (2006). Modelling RGB colour aspects and translucency of fresh-cut tomatoes. Science Direct, Postharvest Biology and Technology. Vol.40 p.15-25 2.8
- [44] Latombe, J. (1990). Robot motion planning. Springer. 2.7
- [45] Leemans, V. Destain, M. (2004). A Real-Time Grading Method of Apples Based on Features Extracted from Defects. Science Direct, Journal of Food Engineering. Vol.61 p.83-89 2.8
- [46] Lin, X. Chen, S. (April 1991 1998-2003). Proc. IEEE Conf. on Robotics and Automation Sacramento, California, 991. 2.3.1
- [47] López, E. Altamirano, L. (2007). Componente Determinista de la Descomposición de Wold 2-D para Obtener Descriptores de Textura y Descubrir Geometría. Instituto Nacional de Astrofísica, Óptica y Electrónica. Puebla, 72840, México. 2.4.1, 1

- [48] Maya, C. Prieto, F. Desarrollo de un Algoritmo para la Caracterización y Clasificación de Granos de Café Empleando Técnicas de Visión Artificial. (2001). Tesis para optar al Título de Ingeniero Electrónico. Universidad Nacional de Colombia Sede Manizales. Manizales - Colombia. 1.4
- [49] Miaki, T. Kawamura, T. Sugahara, K. (2006). Active Contour Model with Splitting Characteristics for Multiple Area Extractions and its Hardware Realization. SICE-ICASE International Joint Conference. 1.2
- [50] Montes, N. Prieto, F. Desarrollo de Algoritmos de Segmentación de Frutos Maduros y Verdes de Café en Imágenes Tomadas en Condiciones Controladas, Basados en las Propiedades de Color. (2001). Tesis para optar al Título de Ingeniero Electrónico. Universidad Nacional de Colombia Sede Manizales. Manizales - Colombia. 1.1, 1.2
- [51] Montes, N. Prieto, F. Segmentación de Imágenes de Frutos de Café en el Proceso de Beneficio. (2003). Tesis para optar al Título de Magister en Automatización Industrial. Universidad Nacional de Colombia Sede Manizales. Manizales - Colombia. 1.1, 1.2, 1.4, 2.2, 2.8, 4.4, 4.11, 4.4
- [52] Montes, P. Sánchez, H. (2006). Inspección De Las Diferentes Etapas De Maduración De Los Frutos De Café Presentes En Una Escena Digital Adquirida Bajo Condiciones Controladas. Tesis para optar al Título de Ingeniero Electrónico. Universidad del Norte. Barranquilla - Colombia. 3.1
- [53] Ohlander, R. Price, K. Reddy, D.R. (1978) Computer Graphics and Image Processing 8 313. 2.3.1
- [54] Ortiz, F. (2002). Procesamiento Morfológico de Imágenes en Color. Aplicación a la Reconstrucción Geodésica. Universidad de Alicante. Alicante - España. 3.1
- [55] Pal, N. y Pal, S. (1993). A Review on Image Segmentation Techniques. IEEE Transaction on Pattern Recognition. Vol. 26, pag. 1277-1294. 2.6
- [56] Pavlidis, T. Liow, Y. (1990). Integrating Region Growing and Edge Detection. IEEE Transaction on Patt. and Match. Intelligence. Vol. 3, pag. 12-16 2.4.1

- [57] Poynton, C. (2000, Septiembre 07). Frequently asked questions about color. Recuperado Octubre 20, 2010 de <http://www.inforamp.net/poynton>. 3.1
- [58] Ramos, P. Valdés, C. Gómez, E. Sanz, J. Solarte, E. (2006). Características Espectrales de la Luz Reflejada por Frutos de Café (*Coffea arabica*). Revista Colombiana de Física. Vol.38 No.2 3.1
- [59] Recce, M. Plebe, A. Taylor, J. Tropiano, G. (1998). Visión and neural control for an orange harvesting robot. [Versión electrónica]. Department of Anatomy and Developmental Biology. 1.1
- [60] Riquelme, M. Barreiro, P. Ruiz, M. Valero, C. (2008). Olive classification according to external damage using image analysis. Science Direct, Journal of Food Engineering. Vol.87 p.371-379 2.8
- [61] Robinson, S. (2002). Profesional C#. En Danypress (Ed.). C# para programadores C++. 1.4
- [62] Rosenfeld, A. y Weszka, J. (1978). Threshold Evaluation Techniques. IEEE Transaction on System, Man and Cybernetics. Vol. 8, pag. 622-629. 2.6
- [63] Russ, J. C. (2007). The image processing handbook. CRC/Taylor and Francis - USA. 2.2
- [64] Sampallo, G. (2003). Leaf Type Recognition. Revista Iberoamericana de Inteligencia Artificial. Chaco - Argentina. No.21, p. 55-62 2.4.2
- [65] Sandoval, Z. Prieto, F. (2007). Caracterización y Clasificación de Café Cereza usando Visión Artificial. Tesis para optar al Título de Ingeniero Electrónico. Universidad Nacional de Colombia Sede Manizales. Manizales - Colombia. 1.1, 1.4, 2.4.1, 2.4.2, 2.5, 3.2
- [66] Sandoval, Z. Prieto, F. (2007). Caracterización de Café empleando Técnicas de Visión Artificial. Rev.Fac.Nal.Agr.Medellín - Colombia .Vol.60, No.2. p.4105-4127. 2.4.1, B.1
- [67] Santos, J. (2006). Metadata Assited Image Segmentation. Universidade do Porto. Río de Janeiro, Brasil. 2.6

-
- [68] Sanz, J. (2008). Reconocimiento de Objetos por Descriptores de Forma. Universidad de Barcelona. Barcelona-España. 2.3.1, 2.4.2
- [69] Shih, F. Cheng, S. (2005). Automatic seeded region growing for color image segmentation. New Jersey Institute of Technology, Newark, NJ 07102, USA. 877 - 886. 2.2
- [70] Tellaeché, A. Burgos, X. Pajares, G. Riveiro, A. Fernández, C. (2008). A new vision-based approach to differential spraying in precision agriculture. Science Direct, Computers and Electronics in Agriculture. Vol.60 p.144-155 2.8
- [71] Umbaugh, S.E. Moss, R.H. Stoecker, W.V. Hance, G.A. (1993). IEEE Engineering in Medicine and Biology. 123 75. 2.3.1
- [72] Wilson, R. A. Keil, F. C. (2001). MIT encyclopedia of the cognitive sciences. MIT Press. 2.7
- [73] Zhang, Y. (1996). A survey on Evaluation Methods for Image Segmentation. IEEE Transaction on Pattern Recognition. Vol. 29, pag. 1335-1346. 2.6

Anexo A

Visión Artificial

Como se muestra Figura 2.1, la segmentación es una etapa de los sistemas de visión artificial, por lo cual se hace necesario conocer la funcionalidad de sus diferentes subsistemas.

A.1 Adquisición de Imágenes

En esta etapa se toma la información de un ambiente real y se transforma en datos digitales, haciendo uso de los diferentes tipos de cámaras, filtros e iluminación. Además, se debe seleccionar un ambiente que produzca el mínimo de reflejos posibles y que permita resaltar los objetos que desean analizar, facilitando las etapas posteriores del sistema de visión artificial.

A.2 Preprocesamiento

Con el fin de eliminar errores y ruido, incluidos durante la etapa de adquisición de imágenes, se lleva a cabo un proceso de discriminación resaltando las características de interés de los objetos que se desean analizar dentro de la imágenes, ya sea por color, textura, forma, bordes o posicionamiento.

A.3 Segmentación

La segmentación es una etapa clave de la visión artificial, donde se determinan las regiones en la imagen que corresponden a los objetos de interés. En este proceso se seleccionan regiones con ciertas características específicas, para luego ser reagrupadas y etiquetadas, definiendo así la pertenencia de los píxeles de la imagen a una región u otra.

A.4 Representación y Descripción

En esta etapa del sistema de visión artificial, se extraen características de los diferentes objetos estudiados en la imagen.

A.5 Reconocimiento e Interpretación

En esta etapa final del sistema de visión artificial, se comparan los resultados de las etapas anteriores y se toma una decisión clasificando y etiquetando los diferentes objetos de la imagen. El resultado otorgado por esta etapa, le facilitará a una etapa posterior una toma de decisión con respecto a los diferentes objetos ya identificados y catalogados.

Anexo B

Características de Los Frutos de Café

Existen tres variables principales que describen a un objeto dentro de una imagen:

- ▷ Características de Intensidad (Color o Gris)
- ▷ Características de Textura
- ▷ Características de Forma

A continuación se encuentra una descripción detallada de estas tres características, enfocadas a los frutos de café.

B.1 Características de Color

El principal criterio de selección en cuanto al estado de madurez del fruto de café se basa en la caracterización por color. Específicamente para el café colombiano cereza roja, un típico fruto maduro se identifica por un color rojo intenso homogéneo sobre toda la epidermis, aunque también se encuentran frutos maduros de colores amarillo o naranja. En la etapa previa al estado de madurez completa, el fruto presenta un color verde y en la etapa posterior a la madurez completa el color de los frutos se torna violeta oscuro. En la Figura B.1 se aprecian los diferentes estados de maduración del fruto de café, cereza roja colombiano.



Figura B.1: Estados de Maduración del Café [66].

La caracterización por color del café colombiano cereza roja fue realizada por Sandoval en seis diferentes espacios de color: RGB, HSI, YIQ, YCbCr, Colores oponentes y Ohta. Cada uno representando el color por pixel en tres componentes, entregando así información de 18 variables por pixel para su estudio.

B.2 Características de Textura

La percepción visual de la textura desde el punto de vista del procesamiento digital de imágenes, consiste en la variación del tono dentro de un vecindario de píxeles. Se dice que la textura es dominante o el tono es dominante si se tiene respectivamente alta variación o poca variación del tono dentro de la pequeña área de píxeles analizada. Existen tres variables a tener en cuenta durante la extracción de características de textura: dimensión del área de estudio, el valor relativo de las características discretas de tono y la distribución en el área de las características de tono; obteniendo así descripción sobre la suavidad, regularidad y rugosidad de una región.

La suavidad y rugosidad de la textura también pueden ser tomadas en cuenta para el análisis del estado de madurez en el fruto de café. Durante el proceso de maduración del café, existen diferentes etapas en las que su epidermis muestra una distribución uniforme del color, mientras que en algunas etapas existe una variación ya sea suave o brusca entre un color y otro. El análisis de rugosidad es útil para hallar los granos de café cuando están demasiado maduros o secos.

El problema del análisis de textura, radica en definir qué tipo de textura se está analizando, teniendo en cuenta que la textura en general presenta un comportamiento tanto aleatorio como periódico; para ello existen dos enfoques:

Enfoque Estadístico: La textura es descrita como un proceso estocástico bi-dimensional descritos por sus parámetros estadísticos. Es decir, mediante las

propiedades estadísticas de las intensidades y posiciones de los píxeles.

Enfoque Estructural: Este enfoque introduce el termino texels o texons, utilizados para describir estructuras complejas de textura por medio de matrices de pequeñas estructuras simples, considerando que la textura tiene propiedades periódicas o quasi-periódicas en una región. Un ejemplo de este enfoque es la matriz de cocurrencia (Ver Anexo C).

Enfoque Espectral: Enfoque Espectral: Se encuentra basado en las propiedades del espectro de Fourier y se utilizan primordialmente para detección de la periodicidad global que presenta una imagen mediante a través de la identificación de picos correlacionados de alta energía.

B.3 Características de Forma

La caracterización por forma, se basa en los contornos del objeto estudiado. En el caso del café, su forma es típicamente elipsoidal-esférica. Durante las primeras etapas de maduración, el café se muestra con forma elipsoidal y, a medida que llega a al estado de plena madurez, su forma se va tornando esférica, para luego volverse nuevamente elipsoidal a medida que el fruto se seca.

Existen diferentes descriptores que ayudan a clasificar las características de forma, los cuales se nombran a continuación:

B.3.1 Rectangularidad

Método que compara el área de un objeto contra el área del la menor forma rectangular que lo rodee, como muestra la ecuación B.1.

$$\frac{A_0}{A_r} \tag{B.1}$$

Donde A_0 es el área del objeto, y A_r es el área del rectángulo. Este descriptor cuantiza la similitud de la forma del objeto con un rectángulo, donde un valor igual a la unidad implica la existencia de una forma rectangular en la imagen. Otro parámetro

relacionado con la rectangularidad de un objeto, es la relación entre anchura y altura máxima mostrada en la ecuación B.2. Conocido como la excentricidad del contorno.

$$\frac{\text{Anchura máxima}}{\text{Altura máxima}} \quad (\text{B.2})$$

B.3.2 Circularidad

La circularidad mide el grado de similitud de un objeto a un círculo. Se suele utilizar como método de comparación la ecuación B.3, la cual mide la relación entre el cuadrado del perímetro del objeto y el área que ocupa.

$$\frac{p^2}{\text{Area}} \quad (\text{B.3})$$

B.3.3 Firma

La firma representa la forma de un objeto con referencia al centroide del objeto y en función del ángulo. La firma se mantiene invariante a la traslación del objeto, pero es susceptible a la rotación o escalamiento de este. Para solucionar el problema de cambios en la firma por rotación, se suele tomar como referencia el ángulo correspondiente a la mayor distancia desde el centroide; Y con respecto al escalamiento, la solución consiste en normalizar las distancias con respecto a su varianza o escalar todas las funciones de firma obtenidas, de tal manera que las distancias se encuentren en el mismo intervalo $[0, 1]$.

Filipe presenta el proceso de mejoramiento en la etapa de segmentación de rostros en imágenes térmicas mediante el uso de descriptores de forma, específicamente la firma; el método propuesto por los autores, consiste en examinar la firma horizontal y vertical, con el propósito de remover artefactos (vestimenta) y generar una nueva firma que describa el rostro en la imagen tratada. Dentro de los resultados que presentan, concluyen que la mejora de la etapa de segmentación es de un 28% en el mejor de los casos para un conjunto de imágenes ya tratadas.

El análisis de la firma, no solamente se orienta a mejorar la etapa de segmentación, sino también a realizar reconocimiento de objetos, como el trabajo presentado por

Sampallo.

B.3.3.1 Momentos Estadísticos de la Firma

La forma de los segmentos de contorno o forma de onda de la firma, puede ser descrita cuantitativamente usando momentos estadísticos simples, como la media, la varianza y momentos de mayor orden. Aprovechando la representación en una dimensión de la firma, se obtienen valores de estos descriptores, aportando información simple para una interpretación “física” del objeto analizado.

Otra manera de aprovechar las características unidimensionales de la firma en un objeto para su caracterización, es el análisis espectral a través de la transformada discreta de Fourier o serie de Fourier.

B.3.4 Índices de Convexidad y Concavidad

Una descripción bastante eficiente de un elemento en una imagen puede definirse atribuyéndole a las diferentes partes de su contorno la definición de cóncavo o convexo, y a los cruces de curvatura o puntos de inflexión como el traslape entre cóncavo y convexo.

G. Fernández en su artículo donde explican el procedimiento para la imitación del proceso humano de separación de células solapadas, aplican un algoritmo para detección de puntos coherentes y secciones cóncavas, a lo largo del perímetro de las células. En la ecuación B.4 se representa el modelo matemático aplicado con una máscara de dimensiones 5×5 .

$$\text{concavidad}(j) = \sum_{j-1}^{j+1} \sum_{x=1}^5 \sum_{y=1}^5 M_j \cap B \quad (\text{B.4})$$

Donde B es la imagen sobre la que se aplica el proceso, j recorre el contorno y M_j es la máscara aplicada. Procesos similares de identificación de secciones cóncavas se presentan por K.Z. Mao también sobre células y D. M. Hobson sobre granos de arroz. En el trabajo realizado por N.R. Mudigonda se analizan no solo secciones cóncavas, sino también las convexas y puntos de inflexión sobre tumores.

Anexo C

Matriz de Coocurrencia

La matriz de coocurrencia se basa en el cálculo de los momentos estadísticos de segundo orden para la caracterización de textura. Esta caracterización se apoya en múltiples descriptores que cuantifican la información tomada de la imagen, los cuales, definidos dentro de un clasificador automático, permite separación y clasificación de un conjunto de imágenes en diferentes clases.

La construcción de la matriz de coocurrencia se realiza obteniendo datos sobre frecuencias relativas $C_d(i, j)$, en la cual se tiene información normalizada sobre la frecuencia con la que encuentro un nivel de tono j distanciado a una relación espacial d de otro pixel con valor i dentro de una matriz de muestra $k \times k$. La figura C.1 muestra un ejemplo de tres matrices de coocurrencia resultantes de un espacio de muestra 4×4 con tres niveles de tonalidad.




Figura C.1: Obtención de la Matriz de Coocurrencia.

Un método de obtención de información sobre las características de textura, se

consiste en el análisis estadísticos por medio de la matriz de concurrencia.

C.1 Descriptores de Textura

En total son 11 los descriptores de textura que otorga la matriz de coocurrencia:

- ▷ Energía
- ▷ Entropía
- ▷ Contraste
- ▷ Homogeneidad Local
- ▷ Correlación
- ▷ Tendencia de Cluster
- ▷ Directividad
- ▷ Momento de Diferencia de Orden K
- ▷ Momento Inverso de Diferencia de Orden K
- ▷ Máxima Probabilidad
- ▷ Varianza

Energía: Medida de uniformidad de una textura, definida por la siguiente ecuación:

$$\sum_i \sum_j C_{ij}^2 \quad (\text{C.1})$$

donde C_{ij} es cada elemento de la matriz de coocurrencia, e i y j varían desde 0 hasta n numero de niveles de gris.

La propiedad de Energía da una idea de la suavidad de la textura. El valor del descriptor de energía se maximizará entre mayor sean los valores de la diagonal principal en la matriz de coocurrencia. Por el contrario su valor será menor si las probabilidades se encuentran más dispersas.

Entropía: Medida de aleatoriedad definida por la siguiente ecuación:

$$- \sum_i \sum_j C_{ij} \log C_{ij} \quad (\text{C.2})$$

Entre más se asemejen los valores de las probabilidades, mayor será el valor de la entropía. La diagonal principal de la matriz de coocurrencia contiene la mayor información, donde a mayores probabilidades, el valor de la entropía descenderá, porque la textura es más uniforme.

Contraste: Medida de cambios bruscos en los colores de una imagen, definida por la siguiente ecuación:

$$\sum_i \sum_j |i - j|^2 C_{ij} \quad (\text{C.3})$$

Se presentara un mayor valor en el descriptor de contraste si los mayores valores de probabilidad se encuentran alejados de la diagonal principal en la matriz de coocurrencia. Es decir que presentara valores bajos en superficies lisas, y presentara valores altos para superficies rugosas o irregulares.

Homogeneidad Local: Este descriptor, proporciona información sobre la regularidad de la textura. Se define matemáticamente de la siguiente manera:

$$\sum_i \sum_j \frac{C_{ij}}{1 + (i - j)^2} \quad (\text{C.4})$$

Se aprecia de la ecuación C.4 que el valor de este descriptor será mayor entre menor sea la diferencia $i - j$, interpretada en la matriz de coocurrencia como un agrupamiento en la diagonal principal.

Correlación: La correlación de la textura es una medida que posee información sobre la relación entre las diferentes intensidades de los colores. Se ve definida por la siguiente ecuación:

$$\frac{1}{\sigma_i \sigma_j} \left| \sum_i \sum_j (i - \mu_i)(j - \mu_j) C_{ij} \right| \quad (\text{C.5})$$

Donde,

$$\mu_i = \sum_i \sum_j i C_{ij} \quad (\text{C.6})$$

$$\mu_i = \sum_i \sum_j j C_{ij} \quad (C.7)$$

$$\sigma_i = \sum_i \sum_j (i - \mu_i) C_{ij} \quad (C.8)$$

$$\sigma_j = \sum_i \sum_j (j - \mu_j) C_{ij} \quad (C.9)$$

Su valor está completamente ligado a sus medidas estadísticas, media y varianza, las cuales tienen relación directa con los valores en la diagonal principal de la matriz de coocurrencia y la dispersión de datos con respecto a esta.

Tendencia de Cluster: Descrita por la ecuación:

$$\sum_i \sum_j (i + j - 2\mu)^k C_{ij} \quad (C.10)$$

Su valor será mayor a medida que la media de las frecuencias relativas se acerque más al valor mínimo dentro de los valores en la matriz de coocurrencia. El valor del descriptor de cluster puede variar entre valores positivos y negativos debido a la relación que se pueda presentar entre la media y el resto de valores en la matriz de coocurrencia.

Directividad: El descriptor de directividad extrae información sobre los patrones de dirección en la textura. Se describe matemáticamente de la siguiente manera:

$$\sum_i C_{ii} \quad (C.11)$$

Se conoce como descriptor de probabilidad de diferencia en nivel de gris. Solo analiza la información otorgada por la diagonal principal de la matriz de coocurrencia, con el fin de enfatizar en niveles iguales de intensidad de color coocurrentes a lo largo de las diferentes direcciones analizadas, ya sea horizontal, vertical o diagonal. Su valor aumentará con la aparición de picos o elongaciones sobre la diagonal principal dentro de la matriz de coocurrencia.

Momento de Diferencia de Orden K: El momento de diferencia de orden K provee información sobre la diferencia entre niveles de tonalidad dependiendo del parámetro K:

$$\sum_i \sum_j |i - j|^k C_{ij} \quad (C.12)$$

EL valor de este descriptor aumenta a medida que los elementos presentes en la matriz de coocurrencia se encuentren mas alejados de la diagonal principal. Para $k = 2$ su valor corresponde al del contraste. El momento de diferencia de primer orden otorga información sobre la dispersión.

Momento Inverso de Diferencia de orden K: Contrario al descriptor anterior, este basa su información en la agrupación de los elementos de la matriz de coocurrencia, definido por la siguiente ecuación:

$$\sum_i \sum_j \frac{C_{ij}}{|i-j|^k}, i \neq j \quad (\text{C.13})$$

El valor de la expresión C.13 aumenta si los elementos de la matriz de coocurrencia se encuentran cerca a la diagonal principal, definiendo así una variación suave de colores en la imagen de muestra. A diferencia del descriptor de homogeneidad local, el descriptor de momento inverso de diferencia omite la información otorgada por la diagonal principal en la matriz de coocurrencia.

Máxima Probabilidad: El descriptor de máxima probabilidad identifica la combinación de pixeles con mayor frecuencia de aparición dentro de la imagen muestra, representados dentro de la matriz de coocurrencia y descrito matemáticamente de la siguiente manera:

$$\max(C_{ij}) \quad (\text{C.14})$$

Su valor sera mayor cuando en la matriz de coocurrencia se observe un pico de intensidad, que se podria interpretar como un color dominante en la textura de la muestra.

Varianza: La varianza indica la dispersión dentro de un conjunto de muestras con respecto al valor medio. Su representacion matematica se muestra a continuación:

$$\sum_i \sum_j (i - \mu)^2 C_{ij} \quad (\text{C.15})$$

Entre mas alejados se encuentren los datos del valor medio, mayor sera el valor de la varianza. Para una muestra de una imagen, la media se encontrara ubicada en la diagonal principal, y para un mayor valor de varianza presentara una distribución alargada o dispersa en torno a esta media.

C.2 Construcción de la Matriz

Para la construcción de la matriz de coocurrencia, existen tres aspectos que se tienen en cuenta: Ubicación espacial de los píxeles, relación con el vecindario y el valor de su intensidad. Los siguientes parámetros bien definidos determinarán las características de textura.

Condición: Regla que debe seguir un píxel con relación a su vecino para ser cuantificado.

Dirección: Es la orientación espacial a en cual se evalúa la condición, como casos típicos se utilizan direcciones como 0 grados, 45 grados, 90 grados y 135 grados.

Distancia: Es el número de píxeles entre el par de píxeles evaluados, como distancias típicas se utilizan 1, 3 y 5 píxeles de distancia.

Utilizando los 11 descriptores de textura sobre frutos de café en cada una de las tres componentes de color R, G y B, se obtuvo información de 33 características de textura, en trabajos previos realizados por Zulma Sandoval.

Anexo D

Operadores Morfológicos

Mediante los elementos estructurales de la Figura D.1 se definen los operadores morfológicos tratados por Woods.

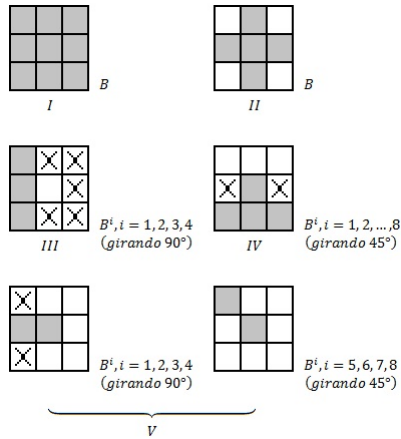


Figura D.1: Ejemplo de Elemento Estructural.

▷ Traslación: Traslada el origen de A al punto x .

$$(A)_x = \{c | c = a + x, \text{ para } a \in A\} \quad (\text{D.1})$$

▷ Reflexión: Refleja todos los elementos de B respecto al origen de este conjunto .

$$B = \{x | x = -b, \text{ para } b \in B\} \quad (\text{D.2})$$

▷ Complemento: Conjunto de puntos que no pertenecen a A .

$$A^c = \{x | x \notin B\} \quad (\text{D.3})$$

- ▷ Diferencia: Conjunto de puntos que pertenecen a A pero no a B .

$$A - B = \{x | x \in A, x \notin B\} = A \cap B^c \quad (\text{D.4})$$

- ▷ Dilatación: Expande el contorno de A (I).

$$A \oplus B = \{x | (\hat{B})_z \cap A \neq \emptyset\} \quad (\text{D.5})$$

- ▷ Erosion: Contrae el contorno de A (I).

$$A \ominus B = \{x | (B)_x \subseteq A\} \quad (\text{D.6})$$

- ▷ Apertura: Suaviza contornos y elimina pequeñas islas y picos agudos (I).

$$A \bullet B = (A \ominus B) \oplus B \quad (\text{D.7})$$

- ▷ Cierre: Suaviza contornos, fusiona interrupciones estrechas y entrantes largos y estrechos, y elimina pequeños huecos (I).

$$A \bullet B = (A \oplus B) \ominus B \quad (\text{D.8})$$

- ▷ Transformación al azar: Conjunto de puntos (coordenadas) en los que, simultáneamente, B , encontró una concordancia con A y B_2 encontró una concordancia en A^c .

$$\begin{aligned} A \odot B &= (A \ominus B_1) \cap (A^c \ominus B_2) \\ &= (A \ominus B_1) - (A \oplus \hat{B}_2) \end{aligned} \quad (\text{D.9})$$

- ▷ Extracción de contornos: Conjuntos de puntos del conjunto A sobre el contorno (I).

$$\beta(A) = A - (A \ominus B) \quad (\text{D.10})$$

- ▷ Relleno de regiones: Rellena una región A , dado un punto p de la región (II).

$$X_k = (X_{k-1} \oplus B) \cap A^c; \quad X_0 = p \quad y \quad k=1,2,3,\dots \quad (\text{D.11})$$

- ▷ Componentes conexas: Encuentra una componente conexa Y de A , dado un punto p de Y (I).

$$X_k = (X_{k-1} \oplus B) \cap A; \quad X_0 = p \quad y \quad k=1,2,3,\dots \quad (\text{D.12})$$

- ▷ Cerco convexo: Encuentra el cerco convexo $C(A)$ del conjunto A , donde “conv” indica convergencia en el sentido que $X_k^i = X_{k-1}^i$ (III).

$$\begin{aligned} X_k^i &= (X_{k-1}^i \odot B^i) \cup A; \quad i=1,2,3,4; \\ k &= 1,2,3,\dots; \quad X_0^i = A; \quad y \quad D^i = X_{conv}^i \\ C(A) &= \bigcup_{i=1}^4 D^i \end{aligned} \quad (D.13)$$

- ▷ Adelgazamiento: Reduce el conjunto A . las dos primeras ecuaciones dan la definición básica de reducción. Las dos últimas ecuaciones indican reducción por una secuencia de elementos de estructura. Este método es el que se utiliza normalmente en la práctica (IV).

$$\begin{aligned} A \otimes B &= A - (A \odot B) \\ &= A \cap (A \odot B)^c \\ A \otimes \{B\} &= ((\dots((A \otimes B^1) \otimes B^2) \dots) \dots) \otimes B^n \\ \{B\} &= \{B^1, B^2, B^3, \dots, B^n\} \end{aligned} \quad (D.14)$$

- ▷ Engrosamiento: Engrosa el conjunto A . Utiliza (IV) con los 0 y 1 invertidos.

$$\begin{aligned} A \odot B &= A \cup (A \otimes B) \\ A \odot \{B\} &= ((\dots(A \odot B^1) \odot B^2 \dots) \odot B^n) \end{aligned} \quad (D.15)$$

- ▷ Esqueleto: Encuentra el esqueleto $S(A)$ del conjunto A . La última ecuación indica que A puede ser reconstruido a partir de sus subconjuntos esqueletos $S_k(A)$. En las tres ecuaciones, k es el valor del paso de iteración tras el cual el conjunto A se desgasta hasta llegar a ser un conjunto vacío. La notación $(A \ominus kB)$ indica la iteración k -ésima de la erosión sucesiva (I).

$$\begin{aligned} S(A) &= \bigcup_{k=0}^K S_k(A) \\ S_k(A) &= \bigcup_{k=0}^K \{(A \ominus kB) - [(A \ominus kB) \odot B]\} \\ &\text{Reconstrucción de } A: \\ A &= \bigcup_{k=0}^K (S_k(A) \oplus kB) \end{aligned} \quad (D.16)$$

- ▷ Pruning: X_4 es el resultado de recortar del conjunto A . Se debe especificar el número de veces que se aplica la primera ecuación para obtener X_1 . Los elementos de estructura (V) se utilizan en las dos primeras ecuaciones. La tercera ecuación se utiliza el elemento de estructura (I).

$$\begin{aligned} X_1 &= A \otimes \{B\} \\ X_2 &= \bigcup_{k=1}^8 (X_1 \odot B^k) \\ X_3 &= (X_2 \oplus H) \cap A \\ X_4 &= X_1 \cup X_3 \end{aligned} \quad (D.17)$$

Anexo E

Matriz de Confusión

La matriz de confusión es una herramienta utilizada para la presentación y el análisis del resultado de una clasificación. Es una matriz cuadrada cuyo orden es el número de clases. En las columnas se presentan las clases reales mientras que en las filas se presentan las clases asignadas por el clasificador. Por ejemplo, en la Tabla E.1 se presenta la matriz de confusión para un clasificador de dos clases.

GT: Imagen de Referencia IM: Imagen Obtenida

| | | IM | |
|----|----------------|--------------------|--------------------|
| | | Clase 1 (Obtenida) | Clase 2 (Obtenida) |
| GT | Clase 1 (Real) | Verdaderos Clase 1 | Falsos Clase 2 |
| | Clase 2 (Real) | Falsos Clase 1 | Verdaderos Clase 2 |

Tabla E.1: Matriz de Confusión. Clasificador de dos Clases.

La suma vertical muestra la distribución real de las clases, mientras que la suma horizontal muestra la distribución de las clases producida por el clasificador.

Se cambia la notación de la matriz de confusión como se muestra en la Tabla E.2 para facilitar la definición de las métricas de desempeño.

Con base en la matriz de confusión E.2 fácilmente se obtienen los siguientes indicadores:

- ▷ Proporción de verdaderos positivos: $PVP = \frac{VP}{VP+FN}$ (efectividad).

| | | IM | |
|----|-----------|-------------------------|--------------------------|
| | | Verdadero | Falso |
| GT | Verdadero | Verdadero Positivo (VP) | Falso Positivo (FN) |
| | Falso | Falso Negativo (FP) | Verdaderos Negativo (VN) |

Tabla E.2: Matriz de Confusión.

- ▷ Proporción de falsos negativos: $PFN = \frac{FN}{VP+FN}$ (error positivo).
- ▷ Proporción de verdaderos negativos: $PVN = \frac{VN}{VN+FP}$ (especificidad).
- ▷ Proporción de falsos positivos: $PFP = \frac{FP}{VN+FP}$ (error negativo).
- ▷ Valor Predictivo positivo: $VPP = \frac{VP}{VP+FP}$ (precisión).
- ▷ Valor Predictivo negativo: $VPN = \frac{VN}{VN+FN}$

Anexo F

Tablas de Fisher

| | | |
|-----------------|----|------------------|
| CONTRASTE | R | 179,434907051612 |
| VARIANZA | C3 | 57,3079358626126 |
| MOM. DIF.K | R | 28,6023334567776 |
| MOM. INV. DIF.K | H | 15,2413985988239 |
| MOM. DIF.K | C3 | 13,1175933376218 |

A. Clase Borde Contorno versus Clase Fruto

| | | |
|-----------------|----|------------------|
| MOM. DIF.K | H | 17,8176182999053 |
| HOMOGENEIDAD | H | 14,169517136233 |
| VARIANZA | I3 | 10,1790086006581 |
| MOM. INV. DIF.K | H | 9,58162871101837 |
| ENERGIA | I3 | 5,99063950870504 |

B. Clase Bordes versus Clase Fruto

| | | |
|-----------------|----|------------------|
| CONTRASTE | I3 | 11,4330670325306 |
| HOMOGENEIDAD | H | 8,44054456296216 |
| VARIANZA | H | 8,35706277528729 |
| MOM. DIF.K | H | 6,49540592854069 |
| MOM. INV. DIF.K | I3 | 6,14116090580869 |

C. Clase Borde Unión versus Clase Fruto

Tabla F.1: Valores mas Altos Obtenidos del Indice Discriminante de Fisher Según las Muestras Tomadas.

| | R | G | B | H | S | V | C1 | C2 | C3 | RG | Yeb | II | I2 | I3 |
|-------------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|--------------|--------------|
| ENERGIA | 0.915388452 | 0.014447969 | 0.003367622 | 0.76476596 | 1.435375011 | 1.250259212 | 0.001549687 | 0.022757574 | 0.253085842 | 0.824004109 | 1.755398258 | 0.079440059 | 2.76213783 | 6.281543783 |
| ENTROPIA | 1.299945888 | 0.03712482 | 0.017411765 | 1.186960053 | 1.99320188 | 1.933916113 | 0.003349142 | 0.08264081 | 0.21103522 | 0.879860622 | 3.019473998 | 0.127526701 | 7.063770252 | 3.278327597 |
| CONTRASTE | 0.008805842 | 0.008805842 | 1.171555036 | 1.897202945 | 4.523372676 | 5.528286051 | 0.088397667 | 0.088397667 | 1.57702628 | 0.203950463 | 3.710909941 | 0.219758341 | 0.743790269 | 8.094446363 |
| HOMOGENEIDAD | 4.700741941 | 0.02194894 | 1.001568698 | 5.45846592 | 5.523372676 | 5.528286051 | 0.043236154 | 0.043236154 | 0.922979793 | 0.521375014 | 3.118634921 | 0.44334921 | 9.796146214 | 3.611152264 |
| CORRELACION | 0.064813458 | 0.259568558 | 0.22428589 | 0.006208418 | 0.096653168 | 0.075883158 | 0.34236154 | 0.34236154 | 0.941768984 | 0.521375014 | 0.035510642 | 0.145991266 | 0.60597959 | 0.4575863 |
| TENDENCIA | 1.595819976 | 0.769725116 | 0.418253032 | 0.057871866 | 0.112718488 | 0.532492327 | 0.045098757 | 0.0522261 | 0.020763407 | 0.837527975 | 0.025279823 | 0.369038507 | 0.161853633 | 1.017945348 |
| MOM. DIFK | 0.014186152 | 1.42828622 | 3.769071153 | 9.563106765 | 2.03219102 | 0.000124443 | 0.002924238 | 0.002924238 | 0.002924238 | 0.002924238 | 6.887512577 | 0.002256304 | 1.437147575 | 8.31522894 |
| MOM. INV. DIFK | 3.036700855 | 0.02547887 | 1.765312308 | 7.862472328 | 5.074012057 | 0.781818194 | 0.375997213 | 1.873156119 | 1.873156119 | 0.017957635 | 0.574605971 | 1.239542153 | 0.423063737 | 1.485674196 |
| MAX. PROBABILIDAD | 1.170537717 | 0.02948886 | 0.009295698 | 1.408382066 | 2.259785826 | 0.334438917 | 0.031734838 | 0.120274914 | 0.192307692 | 0.988135976 | 1.936290323 | 0.18286736 | 5.887309162 | 4.181897302 |
| DIRECTIVIDAD | 2.183239775 | 0.023248705 | 0.393653594 | 1.413886734 | 1.82413726 | 0.019102197 | 0.444420258 | 0.180867599 | 0.893641914 | 3.04900387 | 0.207664179 | 8.457389052 | 3.735943775 | 3.735943775 |
| VARIANZA | 1.40464109 | 0.000974467 | 1.160405066 | 1.6920191 | 4.179809422 | 0.975469454 | 0.039379512 | 0.045963809 | 0.209979126 | 3.661215532 | 0.231788196 | 0.49473161 | 1.7789688814 | 1.7789688814 |

A. Clase Borde Contorno versus Clase Fruto

| | R | G | B | H | S | V | C1 | C2 | C3 | RG | Yeb | II | I2 | I3 |
|-------------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|
| ENERGIA | 0.110238101 | 0.017479699 | 0.000359293 | 1.090027627 | 0.958037346 | 0.221026802 | 0.107252009 | 0.005269355 | 0.203985601 | 0.798882677 | 0.846560496 | 2.161329727 | 0.152743082 | 5 |
| ENTROPIA | 0.104036131 | 0.076714424 | 0.006386641 | 2.054263869 | 0.665670659 | 0.263479813 | 0.119595538 | 0.021791366 | 0.238740652 | 0.844142217 | 0.921495516 | 3.17604767 | 0.090172145 | 1.346608021 |
| CONTRASTE | 0.763287221 | 1.84171829 | 0.13721122 | 5.422681624 | 1.32747405 | 0.702466696 | 0.684661714 | 1.535635184 | 0.381654855 | 0.355676021 | 1.083214101 | 0.149776279 | 0.149776279 | 1.497745277 |
| HOMOGENEIDAD | 0.785879925 | 1.167716959 | 0.043931846 | 1.909256773 | 1.371465872 | 1.23918887 | 0.02324651 | 0.407302543 | 1.028954266 | 0.638240978 | 4.32193542 | 0.086551958 | 3.344636141 | 3.344636141 |
| CORRELACION | 0.096558074 | 0.023603757 | 0.002884981 | 0.256170383 | 0.116569215 | 0.381174895 | 0.194463169 | 0.112635338 | 0.515710975 | 0.010925199 | 0.046108781 | 0.04851389 | 0.157030501 | 0.042403734 |
| TENDENCIA | 1.087091416 | 0.000743845 | 0.124014367 | 0.050336402 | 0.045881015 | 0.049532724 | 0.081660243 | 0.091018968 | 0.408952489 | 0.013629262 | 0.537699539 | 0.075758792 | 0.510538609 | 0.296217193 |
| MOM. DIFK | 0.975264685 | 2.072407051 | 0.11061931 | 1.935372173 | 1.021147861 | 0.905589327 | 0.182083136 | 2.644029025 | 0.594803592 | 0.528801171 | 2.259422255 | 0.083844157 | 2.226627007 | 2.226627007 |
| MOM. INV. DIFK | 0.363140083 | 3.59521884 | 0.006844151 | 2.539761549 | 0.518243857 | 0.854816667 | 0.144722014 | 0.518457679 | 0.579769061 | 0.001543793 | 0.423965148 | 0.066909434 | 1.374378959 | 1.374378959 |
| MAX. PROBABILIDAD | 0.14183353 | 0.018762768 | 0.030890055 | 2.724038248 | 0.280821711 | 0.171450756 | 0.018474411 | 0.000174265 | 0.102368866 | 0.831341269 | 0.654381469 | 3.310799138 | 0.091151485 | 4.148835616 |
| DIRECTIVIDAD | 0.365284167 | 0.336717704 | 0.065433701 | 4.023778828 | 0.80119011 | 0.058789214 | 0.373452536 | 0.000252183 | 0.100160256 | 0.898928866 | 0.852415036 | 4.897840685 | 0.106672936 | 4.231433506 |
| VARIANZA | 0.788665576 | 1.671399493 | 0.249018224 | 5.334564438 | 1.572790201 | 0.763332665 | 0.609200606 | 0.166893997 | 0.097969755 | 0.375427582 | 0.333798573 | 0.533798573 | 0.172587888 | 0.80424039 |

B. Clase Bordes versus Clase Fruto

| | R | G | B | H | S | V | C1 | C2 | C3 | RG | Yeb | II | I2 | I3 |
|-------------------|-------------|-------------|-------------|-------------|-------------|--------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|
| ENERGIA | 0.293372753 | 0.017078172 | 0.001243838 | 0.938856607 | 0.117083981 | 0.575889152 | 0.033912302 | 0.01104209 | 0.256088576 | 0.809811838 | 1.16280534 | 0.736233362 | 0.644367057 | 1.668560409 |
| ENTROPIA | 0.318720724 | 0.058906429 | 0.010707471 | 1.620532789 | 0.081508139 | 0.725698521 | 0.041701552 | 0.04142602 | 0.262754603 | 0.861071286 | 1.506550958 | 0.886823915 | 0.670675028 | 1.371394505 |
| CONTRASTE | 0.305268962 | 0.385354102 | 0.236344536 | 3.103530024 | 0.20380809 | 0.791357512 | 0.278233312 | 0.132686821 | 1.535352704 | 0.057867245 | 0.34819882 | 0.044722642 | 0.336094662 | 1.37138533 |
| HOMOGENEIDAD | 1.510103499 | 0.228813855 | 0.025473906 | 0.097349783 | 0.005275363 | 2.258293309 | 0.002449996 | 0.036647115 | 0.668648991 | 0.890054358 | 1.220090187 | 1.509318922 | 0.67636963 | 3.424147708 |
| CORRELACION | 0.037361523 | 0.04974518 | 0.025473906 | 0.097349783 | 0.005275363 | 2.258293309 | 0.002449996 | 0.036647115 | 0.668648991 | 0.890054358 | 1.220090187 | 1.509318922 | 0.67636963 | 3.424147708 |
| TENDENCIA | 1.293881205 | 0.096496033 | 0.242710272 | 0.05933779 | 0.07955509 | 0.224733164 | 0.060103398 | 0.076686797 | 0.180448486 | 0.142706865 | 0.045489335 | 0.091712791 | 0.294166454 | 0.013430587 |
| MOM. DIFK | 2.075265111 | 0.37635802 | 0.387831403 | 1.365890771 | 0.162203352 | 1.365890771 | 0.342916355 | 0.043748307 | 2.911136677 | 1.28419718 | 1.407790233 | 0.162212988 | 0.358872482 | 2.427992435 |
| MOM. INV. DIFK | 1.064935714 | 0.535144552 | 0.252624508 | 0.80084372 | 1.201135547 | 0.591390842 | 0.066074636 | 0.951159781 | 0.20211457 | 0.085733139 | 0.696880025 | 0.185302075 | 1.432514409 | 1.432514409 |
| MAX. PROBABILIDAD | 0.383742053 | 0.024403763 | 0.021826436 | 2.015905896 | 0.000278427 | 0.2485821942 | 0.026917161 | 0.028258483 | 0.149323229 | 0.861609951 | 1.045986095 | 1.044884944 | 0.682960846 | 4.183815144 |
| DIRECTIVIDAD | 1.028849712 | 0.153000444 | 0.157555898 | 2.543973111 | 0.046619144 | 1.486229842 | 0.202296992 | 0.048030555 | 0.158566351 | 0.335358879 | 1.438195192 | 1.196771257 | 0.742041263 | 3.976649463 |
| VARIANZA | 1.510140129 | 0.178540299 | 0.50566062 | 2.529647794 | 0.356834309 | 0.848974418 | 0.227522671 | 0.104699127 | 0.000464603 | 0.940282259 | 0.053934218 | 0.283273388 | 0.641392957 | 0.641392957 |

C. Clase Borde Union versus Clase Fruto

Tabla F.2: Relación Discriminante de Fisher para las Clases de Muestra de Selección Efectiva de Características.

Anexo G

Adelgazamiento de Borde

El algoritmo planteado para este adelgazamiento es el propuesto por Lam, Ching y Seong; y consiste en el siguiente procedimiento:

1. Se divide la imagen en dos subcampos distintos utilizando un patrón similar al de un tablero de ajedrez.
2. En la primera subiteración, se elimina el pixel p del primer subcampo si y solo si se satisfacen las tres condiciones G1, G2 y G3.
3. En la segunda subiteración, se elimina el pixel p del segundo subcampo si y solo si las tres condiciones G1, G2 y G3' se satisfacen.

▷ Condicion G1:

$$X_H(p) = 1 \quad (\text{G.1})$$

donde

$$X_H(p) = \sum_{i=1}^4 b_i \quad (\text{G.2})$$

$$b_i = \left\{ \begin{array}{l} 1 \\ 0 \end{array} \right. \left. \begin{array}{l} , Si \ x_{2i-1} = 0 \ y \ (x_{2i} = 1 \ o \ x_{2i+1} = 1) \\ , en \ otro \ caso \end{array} \right\} \quad (\text{G.3})$$

x_1, x_2, \dots, x_8 son los valores de los ocho vecinos de p , empezando por el vecino oriental, y numerados en sentido inverso a las manecillas del reloj.

▷ Condición G2:

$$2 \leq \min \{n_1(p), n_2(p)\} \leq 3 \quad (\text{G.4})$$

donde

$$n_1(p) = \sum_{k=1}^4 x_{2k-1} \vee x_{2k} \quad (\text{G.5})$$

$$n_2(p) = \sum_{k=1}^4 x_{2k} \vee x_{2k+1} \quad (\text{G.6})$$

▷ Condición G3:

$$(x_2 \vee x_3 \vee \overline{x_8}) \wedge x_1 = 0 \quad (\text{G.7})$$

▷ Condición G3':

$$(x_6 \vee x_7 \vee \overline{x_4}) \wedge x_5 = 0 \quad (\text{G.8})$$

Las dos subiteraciones expuestas componen una iteración del algoritmo de adelgazamiento. Estas iteraciones se repiten hasta que la imagen deje de cambiar.

Anexo H

Pseudocódigos

- 1: Leer imagen, *img*
- 2: Crear imagen de ceros(0), *imgrem* de igual tamaño que *img*
- 3: Para cada píxel *p* en *img*
- 4: Convertir $p \rightarrow H$ y $p \rightarrow S$
- 5: Si NOT(AND($(X_1 < H < H_2)$, $(X_3 > S)$)), entonces $imgrem(p) = 1$

Tabla H.1: Pseudocódigo de la Extracción de Fondo y Objetos de Interés.

- 1: Leer *img*, leer *imgrem*
- 2: Crear la imagen *imgrem1* con regiones mayores al área de un fruto. Crear la imagen *imgrem2* con regiones correspondientes al área de un fruto. Crear la imagen *imgbordes* con ceros(0) de igual tamaño que *img*
- 3: Para cada cuadro *C* de 4×4 píxeles en *img*
- 4: Se obtiene GLCM en las componentes de color H, R, C3 y se calcula Momento de diferencia de orden K sobre GLCM(H), Momento inverso de diferencia de orden K sobre GLCM(H), Contraste sobre GLCM(R) y Varianza sobre GLCM(C3), sometiéndolos a un Clasificador Bayesiano.
- 5: Si el Clasificador Bayesiano detecta un borde, entonces asignar valores de uno(1) a *C* dentro de *imgbordes*.
- 6: Adelgazar Bordes en *imgbordes*
- 7: Crear $imgseg = AND(imgrem1, NOT(imgbordes))$
- 8: $imgseg = OR(imgseg, imgrem2)$
- 9: Etiquetar Regiones en *imgseg*

Tabla H.2: Pseudocódigo del Detector de Bordes.

- 1: Leer *imgseg*
- 2: Crear la imagen *imgseg1* con regiones mayores al área de un fruto, Crear la imagen *imgseg2* con regiones correspondientes al área de un fruto
- 3: Suavizado de Bordes sobre *imgseg1*
- 4: Separación de regiones, *reg*, dentro de *imgseg1*
- 5: Para cada región *reg* en *imgseg1*
- 6: Detectar puntos concavos de *reg* en *imgseg1*
- 7: Trazado de líneas divisorias en *reg* en *imgseg1*
- 8: $imgfinal = OR(imgseg1, imgseg2)$
- 9: Reetiquetado de regiones en *imgfinal*

Tabla H.3: Pseudocódigo del Sub-segmentador.