

**DISEÑO DE UN SISTEMA AUTOMÁTICO DE SELECCIÓN DE
FRUTOS DE CAFÉ MEDIANTE TÉCNICAS DE VISIÓN ARTIFICIAL**

**JEAN CARLOS HERRERA PÉREZ
SILFRI MANUEL MEDINA ORTÍZ**

**UNIVERSIDAD AUTÓNOMA DEL CARIBE
FACULTAD DE INGENIERÍA
INGENIERÍA MECATRÓNICA
BARRANQUILLA
2015**

**DISEÑO DE UN SISTEMA AUTOMÁTICO DE SELECCIÓN DE
FRUTOS DE CAFÉ MEDIANTE TÉCNICAS DE VISIÓN ARTIFICIAL**

**JEAN CARLOS HERRERA PÉREZ
SILFRI MANUEL MEDINA ORTÍZ**

Proyecto de grado para optar al título de Ingeniero Mecatrónico

**Asesor Disciplinar
Ing. Kelvin Beleño Saenz, M.Sc.**

**Asesora Metodológica
Ing. J. Stephany Berrío Pérez, M.Sc.**

**UNIVERSIDAD AUTÓNOMA DEL CARIBE
FACULTAD DE INGENIERÍA
INGENIERÍA MECATRÓNICA
BARRANQUILLA**

2015

Nota de aceptación

Firma
Nombre:
Presidente del jurado

Firma
Nombre:
Jurado

Firma
Nombre:
Jurado

Barranquilla, Enero 22 de 2015

AGRADECIMIENTOS

Agradezco primeramente a Jehová quien me dio la vida, a mis padres Silfri Medina Barrios y Alba Luz Ortiz Oñate quienes con su amor me educaron y formaron con los valores y principios que me convierten en la persona que soy, por su apoyo y constante atención; y por darme la mejor educación posible. A mi hermano Samir de Jesus Medina Ortiz, quien desde su nacimiento ha estado ahí brindándome su apoyo, animo y amor incondicionales; sin ellos me hubiera sido imposible llegar hasta este punto.

A todos mis profesores quienes me impartieron grandes enseñanzas tanto en mi formación académica como en mi formación personal, un especial reconocimiento a M.Sc. Kelvin Beleño Saenz y M.Sc. Julie Berrio por los consejos, el apoyo y el ánimo que nos brindaron a mi y mi compañero en la realización de este proyecto.

A mi compañero Jean Carlos Herrera Pérez por el apoyo y colaboración en la realización de este proyecto que con dedicación y arduo trabajo hemos podido finalizar.

Silfri Medina

Agradezco a mis padres por su apoyo moral, comprensión y paciencia durante mis estudios, sin su ayuda no sería el profesional ni la persona que soy actualmente.

A los ingenieros Kelvin Beleño y Stephany Berrío por sus sabios consejos, colaboración y dedicación a lo largo de este proyecto y de mi formación académica y personal. De igual manera, al resto de la planta docente del programa de ingeniería mecatrónica, los ingenieros Saúl, Mauricio y Francisco, por todas las enseñanzas dadas durante estos cinco años.

A mis compañeros de estudio y amigos Silfri, Harold, Gabriel, Luis Damián y Luis Nieto, por la ayuda que me dieron cuando más la necesité, por su amistad y por hacer más amenos los momentos de trabajo durante nuestra carrera.

Al señor Orlando Cortés y su familia, por la hospitalidad y ayuda que me ofrecieron, la cual fue de vital importancia para culminar este trabajo de grado.

Jean Herrera Pérez

CONTENIDO

	Pág.
INTRODUCCIÓN	14
1. Planteamiento del Problema	15
2. Objetivos	21
3. Marco de Referencia	22
4. Diseño Metodológico	30
5. Análisis de los Resultados	55
6. Conclusiones y Recomendaciones	59
BIBLIOGRAFÍA	62
ANEXOS	66
A. Clasificadores	67

LISTA DE FIGURAS

	Pág.
1 Imagen de referencia [5].	17
2 Broca en el fruto de café [9].	23
3 Esquema de un sistema de visión artificial [10].	24
4 Histograma y umbral óptimo [15].	27
5 Esquema general del sistema (Fuente: los autores).	31
6 Sistema de visión artificial propuesto (Fuente: los autores).	32
7 Posición de las cámaras (Fuente: los autores).	33
8 Iluminación (Fuente: los autores).	33
9 Diagrama de flujo para clasificación por color (Fuente: los autores).	34
10 Red neuronal (Fuente: los autores).	37
11 Histograma (Fuente: los autores).	39
12 Histograma (Fuente: los autores).	39
13 a.)Captura del fruto de café, b.) Resultado de la segmentación, c.) Detección de la broca (Fuente: los autores).	40
14 a,b)Sombra detectada como broca, c)Sombra eliminada (Fuente: los autores).	40
15 Banda Transportadora (Fuente: los autores).	41

16	De izquierda a derecha y de arriba a abajo, Eje de Banda, Trazo del Esfuerzo, Trazo de Desplazamiento y Factor de seguridad (Fuente: los autores). . . .	43
17	No. de Cilindros que conforman el eje (Fuente: Los autores)	50
18	Motor seleccionado [27].	51
19	Prototipo de Banda transportadora construida (Fuente: Los autores). . . .	51
20	a.) Dispositivo Extractor, b.) Contenedor, c.) Rampa (Fuente: Los autores).	52
21	Dispositivo Extractor (Fuente: Los autores).	52
22	Banda y dispositivo extractor (Fuente: Los autores).	53
23	Flote de los frutos (Fuente: los autores).	55
24	Curva ROC [29].	56
25	Curva ROC de los clasificadores (Fuente: los autores).	57
26	Curva ROC del algoritmo de detección de brocas (Fuente: los autores). . .	57
27	Rendimiento del sistema propuesto (Fuente: los autores).	58

LISTA DE TABLAS

	Pág.
1 Vector de características	37
2 Comparación entre alternativas de material.	42
3 Tipos de Rodamientos y desempeño	44
4 Tabla de valores de carga dinámica y estática equivalente	47
5 Presupuesto	54

RESUMEN

La visión artificial permite extraer características físicas de manera no invasiva, por lo cual es una opción viable para la inspección de alimentos. A través de ella se pueden determinar características del fruto de café, tales como el color, tono, textura y tamaño. Con esto en mente, en el presente trabajo de investigación se propone el desarrollo de un sistema de visión artificial para la detección del fruto de café apto para producción. Para lograr esta detección hay dos aspectos importantes a tener en cuenta, el color y la presencia de broca. La primera determina el estado de maduración del fruto de café, y la segunda es una plaga que ataca a las cosechas de este fruto, provocando daños en el interior del fruto. Esta plaga deja una evidencia de su presencia en el exterior del café, por lo tanto, es posible determinar si un fruto de café ha sido perjudicado por la broca.

Teniendo en cuenta los aspectos de calidad del fruto de café mencionados en el párrafo anterior, se desarrolló un sistema de visión artificial capaz de determinar si un fruto de café se encuentra en estado de maduración, y además, determinar si este presenta broca. El algoritmo implementado para reconocer el estado de maduración del café consta de varias etapas: una base de conocimiento formada por un banco de imágenes de frutos de café maduros y no maduros; un sistema de adquisición de imágenes en un ambiente con iluminación controlada, una etapa de pre-procesado para limpiar impurezas y filtrar ruido en la imagen. Prosigue la segmentación para extraer el objeto de interés a analizar, luego una etapa de extracción de características de color, y por último, el proceso de reconocimiento e interpretación, el cual consta de un algoritmo de clasificación entrenado con el banco de imágenes mencionado previamente; el clasificador discrimina los frutos de café en maduros o no maduros.

Debido a que la evidencia dejada por las brocas sobre el fruto de café es un pequeño orificio negro, el algoritmo de detección de brocas fue implementado para buscar zonas negras presentes en la imagen capturada, equivalentes a los orificios dejados por la broca. Esto es logrado a través de la binarización de la imagen original, utilizando un umbral de 30. Las zonas blancas que resten luego de la binarización son las brocas presentes

en el café. Además del método de umbralización, una buena adecuación del sistema de captura de imágenes es requerida, con el objetivo de garantizar que los orificios hechos por las brocas (en caso de que estén presentes) sean las únicas zonas negras presentes en la captura. En base al resultado provisto por los dos algoritmos mencionados, es posible conocer si el fruto de café analizado es apto para producción.

Además de los algoritmos de visión artificial, se diseñó un prototipo de un mecanismo que separará los frutos de café aptos para producción de los que no lo son. Dicho mecanismo se encuentra dentro del sistema de adquisición de imágenes con iluminación controlada, y consta de una banda que transporta los frutos de café para que las cámaras tomen capturas de ellos para ser analizados por los algoritmos de visión artificial. Además, al final del recorrido de la banda se encuentra un dispositivo mecánico, el cual se encarga de re-direccionar los frutos de café de acuerdo a la decisión tomada por los algoritmos, permitiendo almacenar en dos recipientes distintos los cafés buenos de los malos para producción.

PALABRAS CLAVE:

Fruto de café, broca, extracción de características, análisis de color de imágenes, procesamiento de imágenes, segmentación de imágenes, clasificación de imágenes, visión artificial, binarización, proceso de selección del fruto de café.

ABSTRACT

Machine vision allows extraction of physical characteristics in a non-intrusive demeanor, thus; it is a viable option for food inspection, being capable of extracting characteristics of the coffee fruit, as color, hue, texture and size. With this in mind, in this investigation work is proposed the development of a machine vision system whereby it can be detected whether a coffee fruit is suitable for production or not. In order to achieve this detection, two important aspects must be taken into account, the coffee fruit color and the presence of the "broca" (coffee berry borers). The first determines the ripeness state of the coffee fruit, and the second is a plague which attacks the coffee crops, thus leading to internal damages in the fruit. This plague leaves a trace of his presence in the exterior of the coffee, therefore, is possible to determine if a coffee fruit has been spoiled by the "broca".

Keeping in mind the aforementioned aspects regarding the quality of the coffee fruit, a machine vision system, composed of two algorithms capable of detecting the broca and the ripeness state in the fruit, was developed. The first algorithm consists of several stages: a knowledge database, which has a bank of coffee-fruits images in ripe and unripe state; an image acquisition system with controlled lighting, a stage of pre-processing to clean up noise; next, the segmentation process to extract the object of study, then follows the color-characteristics extraction process, and finally, the classifier (trained with the knowledge database), which decides whether a coffee fruit is ripe or unripe. The second algorithm looks for the dark zones in the image, which are the holes made by the "broca" on the surface of the coffee fruit. By means of binarization, using a threshold of 30, these dark zones are detected and then covered with white; the remaining zones of the image are colored with black. The decision made by the two algorithms determines if the analysed coffee fruit is suitable for production.

In addition to the machine vision algorithms, a mechanical device is needed in order to isolate the damaged coffee from the good one. The mechanism proposed in this document consists of a conveyor belt placed inside an image acquisition system with

controlled lighting, where the coffee fruits are transported, and while they are on the belt, images of those coffees are taken by the cameras for the image processing. Moreover, at the end of the conveyor belt, there is a mechanism in charge to change the course of the coffee, according to the decision made by the computer vision algorithms, allowing to store the bad and the good coffee fruits in two different containers.

KEYWORDS:

Feature Extraction, broca, artificial neural networks, image color analysis, image analysis, image segmentation, image classification, machine vision, binarization, selection process of coffee fruits.

INTRODUCCIÓN

La visión artificial es ampliamente usada en aplicaciones donde sea requerido un control de la calidad de los productos, además, permite la automatización de los procesos en los que sea implementado, mejorando la productividad. Algunos ejemplos de aplicaciones que usen la visión por computadora en agricultura son: la identificación de distintos tipos de granos en Etiopía [1], así como la identificación de las etapas de maduración de la piña [2], la clasificación los granos de trigo y cebada [3], la caracterización del café cereza [4].

En Colombia muchos procesos que pueden ser automatizados se siguen realizando de manera manual o semi-automática, abriendo la posibilidad de una disminución en la calidad del producto final (debido a algún error humano) y además de restar competitividad al mercado colombiano en lo que a tiempo de producción respecta.

La industria del café en Colombia es bastante importante, debido a la alta reputación que tiene esta en el mercado internacional, sin embargo, aún se usan muchas técnicas artesanales para el procesado del café, uno de estos procesos es la selección del café por inspección. Los frutos de cafés son revisados por los caficultores luego de haber sido extraídos de las plantaciones. Los agricultores revisan que el café se encuentre en un estado apropiado de maduración, además de buscar la presencia de la plaga de la broca sobre el fruto.

1. PLANTEAMIENTO DEL PROBLEMA

1.1. ANTECEDENTES

Implementaciones de sistemas de visión artificial en proyectos de agricultura se han estado realizando en distintos países, como alternativas para la optimización de los procesos de recolección y selección de la mejor materia prima. En Etiopía se realizaron distintos sistemas para clasificar los seis tipos de granos de café presentes en dicha región. Cabe resaltar que probaron con diferentes algoritmos de clasificación para poder dar con el que mejor respondiera a sus requisitos de calidad. Se hicieron prueba con los clasificadores bayesianos y con redes neuronales, siendo estas últimas las que mejor se desempeñaron. La calidad de las imágenes y los métodos de limpieza de las mismas, además de las fotografías de la base de conocimiento del sistema, definen en gran manera la efectividad de cada algoritmo de clasificación, lo cual hay que tener en cuenta para el proyecto presente [1].

Se sabe que la visión artificial no sólo ha servido para la identificación de frutos tipo baya, como el café y las cerezas, sino que también puede aplicarse a otros tipos de frutas, como en la investigación hecha por Luis Silva y Sergio Lizcano [2]. Ellos diseñaron un sistema que pudiera seleccionar las frutas que presentaran el grado de maduración más adecuado; con el objetivo de obtener la fruta en su punto de mayor calidad. El sistema fue provisto con fotografías de piñas en sus diversas fases (maduras, verdes, sobre-maduradas). Lo que lo diferencia del proyecto anterior es el análisis hecho de las frutas en un espacio de color diferente al convencional RGB; en su lugar usaron el espacio de color HSV, porque evidenciaron que en dicho espacio se podía analizar de manera más directa las cualidades que definen la maduración de la piña. Posteriormente al procesamiento de las imágenes usaron el algoritmo MBSAS (Modified Basic Sequential Algorithmic Scheme) para clasificar las imágenes en tres etapas de maduración (verde, pintona y madura), con este algoritmo lograron una efectividad del 96.36%, dicha efectividad fue comprobada por expertos en la clasificación manual de las piñas.

Estudios realizados en España por F. Guevara y J. Gómez condujeron a conclusiones parecidas a las de la investigación descrita en el párrafo anterior. Estos autores usaron visión artificial para la clasificación de los granos de trigo y cebada [3]. La investigación consistió de un análisis de la precisión de la clasificación de acuerdo a las características tomadas del trigo y la cebada; tales como las características morfológicas, el color, y la textura. Primero analizaron solo las características morfológicas, luego el color, y por último la textura. El análisis de las dos primeras características proporcionó el resultado con mayor grado de precisión, llegando a la conclusión de que mientras más características de las muestras se tomen, la clasificación de los granos de trigo y cebada será más eficiente.

A nivel nacional ya se han realizados trabajos similares con frutos de café. Para medir el estado de maduración de los granos. Sandoval de la Universidad Nacional sede Manizales en , usó visión artificial empleando 3 tipos de algoritmos de clasificación, no sin antes haber procesado un total de 208 características morfológicas y resumirlas a sólo 9 [4]. La autora utilizó clasificadores bayesianos, redes neuronales y clustering difuso. Los resultados de cada uno fueron diferentes, siendo el clasificador bayesiano el que presentó menor error de clasificación, con un valor de 5%, pero requiriendo un tiempo de proceso de 5.5 ms; mientras que la técnica de clustering difuso tuvo respuesta la más rápida alcanzando un valor de 0.1ms, pero con un error máximo del 19%. Y por último el clasificador por redes neuronales generó un error de 7% con un tiempo de procesado de 0.8 ms.

Otro trabajo hecho a nivel nacional es el de Díaz J. [5]. El realizó un Diseño de un Sistema de Selección de Café Mediante la Caracterización de Imágenes, cuyo objetivo fue identificar el café bueno o malo a través del análisis de su color. Para conseguir diferenciar entre el café malo y bueno se usaron dos técnicas, la de comparación de histogramas y la técnica de "Template Matching" o comparación de plantilla. La última consiste en comparar la imagen tomada actualmente con una de referencia donde se hay una muestra de café bueno. El fruto se encuentra en dos posiciones, una con la cara hacia arriba y la otra hacia abajo, ver figura 1. El autor eligió como referencia el grano de la izquierda. Esto provocó que el algoritmo solamente identificara de forma adecuada aquellos granos que estén en la misma posición al grano de referencia.

La técnica de histogramas consiste en asignar una tonalidad de grises a los granos de acuerdo a su color, siendo esta una buena alternativa debido a la importancia del color

del café para determinar si este es bueno o malo. Aunque este método resultó más efectivo que el "Template Matching" aún se presentaron falsos positivos, ya que en el momento de la conversión a escala de grises; el contraste de algunos cafés malos fue muy parecido al de los buenos, por ello se propuso como mejor alternativa trabajar las imágenes a color, es decir en canal RGB, debido a que si uno de estos tres canales resulta parecido al del café bueno, los otros dos canales restantes deben ser diferentes, por lo que se esperaba una mejora en el resultado final.

Figura 1: Imagen de referencia [5].



Investigadores del Grupo de Control y Procesamiento Digital de Señales de la Universidad Nacional de Colombia, sede Manizales, realizaron comparaciones entre tres distintas técnicas para la extracción de características de los frutos de café. Esto con el fin de identificar los frutos maduros y verdes. Las técnicas usadas fueron las siguientes: filtro con base en análisis multivariado, algoritmo wrapper y el análisis de componentes principales (PCA). El último mostró los mejores resultados y la mejor fiabilidad. Además, concluyeron que la utilización de promedios de los píxeles en cada uno de los canales RGB es adecuado para el reconocimiento de frutos maduros [6].

En la Universidad Autónoma del Caribe, Beleño y Meza diseñaron un clasificador de textura de frutos de café según su estado de maduración. Mediante la Transformada de Wavelet se extrajeron las características de textura de los frutos de café, del cual obtuvieron 665280 características. Al ser muchas características a analizar, debieron seleccionar las que mejor discriminen el proceso, esto se logró mediante el análisis de Fisher. Una vez han sido identificadas las características más discriminadoras, se procedió a entrenar una Red Neuronal, la cual realiza la tarea de clasificador. El tipo de red neuronal utilizado fue una Back-Propagation con 5 salidas, 2 neuronas de entrada y 10 neuronas en la capa oculta [7].

1.2. DESCRIPCIÓN DEL PROBLEMA

El proceso del beneficio del café en Colombia se sigue realizando de manera manual. Las etapas que componen a este proceso requieren un arduo trabajo por parte de los caficultores, en especial los procesos de recolección, selección y despulpado. Esto debido a la vasta cantidad de frutos de cafés que deben ser procesadas. Con esto en mente, en el presente trabajo, como parte del macro proyecto "Automatización del beneficio del café"; se busca contribuir a mejorar una de las etapas que conforman el procesado del café, específicamente la selección. En este proceso se determina si los frutos de café recolectados son aptos para producción, basándose en el estado de maduración del fruto y en la presencia de la plaga de la broca. Con la contribución planteada en este trabajo se busca disminuir el trabajo hecho por los caficultores, y además, puedan redirigir su trabajo a tareas en las que indiscutiblemente se necesite un ser humano.

1.2.1. *Formulación del problema*

Diversos autores (ver Antecedentes) han realizado caracterizaciones de los frutos de café mediante distintos métodos, ya sea analizando el color, la textura o el tamaño de ellos, sin embargo, ninguno de estos autores hasta ahora ha estudiado la detección de la broca en el café mediante técnicas de procesamiento de imágenes. Tomando en cuenta este aspecto y el problema descrito en la sección 1.2., se plantea la siguiente interrogante:

¿Cómo crear un sistema de visión artificial que pueda identificar un café apto para producción en base a su información de color y a la presencia de la broca?

1.3. JUSTIFICACIÓN Y ALCANCE

El procesado del café en Colombia aún se sigue realizando manualmente, lo cual le resta competitividad al mercado cafetero de este país en comparación con el internacional. Por lo tanto, con esta investigación se busca aportar un rejuvenecimiento a la industria cafetera colombiana y mejorar su competitividad, esto a través del desarrollo de

tecnologías automáticas para el procesado del café, en específico la etapa de selección, haciendo uso de visión artificial.

Con esta investigación se planea dar pertenencia institucional, social y generar aporte a la educación. Como pertenencia institucional, para la Universidad Autónoma del Caribe(UAC), la propuesta que se plantea brinda a la UAC la gran oportunidad de reforzar la línea de automatización del Grupo de Investigación en Ingeniería Mecatrónica (GIIM). Este proyecto de carácter multidisciplinario ofrecerá la posibilidad de que tanto estudiantes como profesores de programas afines puedan vincularse al proyecto.

La pertenencia social de este proyecto plantea una mejora al sector cafetero colombiano para reducir tiempos de producción, con la implementación del mismo, se mejoraría en gran medida la selección del café, incrementando la competitividad del mercado colombiano. Además de ser un proyecto cuyo impacto ambiental es mínimo, pues no se requiere alterar el medio en donde crece el café.

La temática de selección del fruto de café a través de visión artificial abarca una diversidad de temas, que dotan a la investigación la capacidad de generar la correspondiente documentación, cuyo contenido muestra los progresos de las actividades del cronograma y los medios para su realización, los cuales serán publicados o mostrados a la comunidad científica por medio de la modalidad de posters, y conforme a los avances se realizarán papers para la participación en ponencias. En cada documento generado se mostrarán los métodos realizados o técnicas empleadas para la recolección de datos, con el objetivo de generar un conocimiento útil para futuras investigaciones en situaciones similares, incentivando a la realización de más proyectos en esta área de la automatización.

1.4. USUARIOS DIRECTOS E INDIRECTOS POTENCIALES DE LOS RESULTADOS DE LA INVESTIGACIÓN

Sector cafetero, el sector cafetero es un usuario directo, ya que es el principal beneficiado con los resultados que se buscan en la investigación, debido a que sus tiempos de producción serán más eficaces.

Sector industrial, la industria que se dedica al café la cual recibe los granos del café,

es un usuario indirecto, la mejora en los tiempos de producción le permitirá obtener dichos granos en mayores cantidades en intervalos o plazos de tiempo muy cortos, lo que le permitirá llevar a los consumidores una mayor oferta en productos.

Los consumidores son usuarios indirectos, debido a que la mejoría en el sector cafetero y el sector industrial permitirán un aumento en la oferta de café disponible en las tiendas.

2. OBJETIVOS

2.1. OBJETIVO GENERAL

Diseñar un sistema de visión artificial que identifique los frutos de café en buen estado y los separe de los frutos no aptos para producción.

2.2. OBJETIVOS ESPECÍFICOS

- Recopilar información acerca de como la broca afecta a los frutos de café.
- Desarrollar algoritmos de clasificación que identifique los frutos de café por su color.
- Desarrollar algoritmos que detecten la presencia de broca en los frutos de café.
- Diseñar un dispositivo de extracción de frutos de café en mal estado.

3. MARCO DE REFERENCIA

3.1. CALIDAD DE LA BEBIDA DEL CAFÉ

Antes de abordar las técnicas que se usarán en este proyecto para resolver el problema planteado, primero se debe esclarecer qué defectos afectan la calidad de la bebida del café.

3.1.1. *Maduración*

La principal característica que afecta la calidad del café es su estado de maduración. Con el objetivo de generar un producto de gran calidad, el café debe estar en un estado óptimo de maduración, es decir ni verde, ni sobremaduro. Un defecto de estos provoca el defecto de sabor y aroma a fermento en la bebida [8]. Por consiguiente, es apropiado implementar en el presente trabajo un algoritmo que identifique a un fruto de café de acuerdo a sus propiedades de color.

3.1.2. *Broca*

Un aspecto de vital importancia que deben afrontar los caficultores es el control de la plaga de la broca. Este es un insecto que ingresa al interior del fruto de café, afectando gravemente la calidad física del grano, su apariencia y color, y además alterando la calidad de la bebida, provocando aromas y sabores nauseabundos [8]. En la figura 2 se observa como ingresa la broca al fruto de café. El orificio hecho por este insecto es de vital importancia en este proyecto. Mediante la detección de este, es posible detectar un fruto de café en el cual hay o hubo presencia de broca.

Figura 2: Broca en el fruto de café [9].

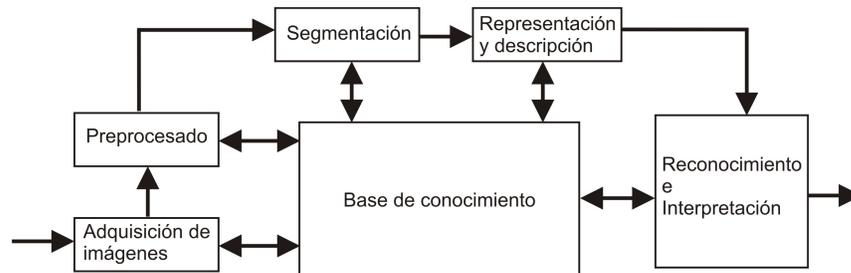


3.2. SISTEMA DE VISIÓN ARTIFICIAL

Un sistema de visión artificial por lo general consta de unas etapas que se deben seguir con el objetivo de lograr un buen resultado. Dicho proceso se describe en la figura 3. El proceso inicia con la digitalización de una escena 3D capturada por una cámara. Luego, viene la etapa de preprocesado, esta etapa es análoga a esa de los circuitos electrónicos que trabajan con señales análogas. Antes de trabajar con la señal, ella debe ser filtrada y eliminar el ruido. En la visión artificial sucede lo mismo, aunque la imagen capturada es digital, esta aún puede presentar distintos tipos de ruidos o imperfecciones que deben ser corregidas antes de efectuar un análisis de la imagen. Una vez la imagen ha sido tratada, es posible proseguir con su análisis, pero antes se deben eliminar los objetos que no son de interés, este proceso es llamado segmentación. Al haber identificado el objeto de estudio y separarlo de lo que no se necesita en la imagen, ya se pueden extraer características de él. Hay muchas características que se pueden extraer de un objeto, como la textura, el color, tamaño y forma. Y por último se encuentra la etapa de reconocimiento. La información recabada de la etapa anterior es almacenada en una base de datos o de conocimiento, la cual posteriormente es utilizada por la etapa de reconocimiento. Esta etapa se encarga de identificar una escena u objeto en la imagen en base a la información previa recopilada [10]. La etapa de reconocimiento consta de un clasificador, del cual hay varios tipos. Estos serán descritos más adelante en este documento.

Sin embargo, en este trabajo se eliminarán algunas etapas descritas arribas, debido a que algunas de las etapas no son necesarias en una de las soluciones presentadas, por lo tanto este esquema se verá ligeramente modificado.

Figura 3: Esquema de un sistema de visión artificial [10].



3.3. ADQUISICIÓN DE LAS IMÁGENES Y ESPACIOS DE COLORES

Teniendo claro las partes de un sistema de visión artificial, se explican con detalles cada una de ellas. Empezando por el proceso de adquisición de la imagen. En esta etapa se hace una captura del entorno a analizar, dicha captura puede ser tomada con una cámara fotográfica o de vídeo. Sin embargo, esta etapa no consta solamente de la adquisición en sí, también se debe tener en cuenta el fondo y el ambiente de tal forma que no se alteren las propiedades de la imagen a analizar. Por lo tanto es importante tener en cuenta la realización de un sistema de iluminación adecuado para la adquisición de la imagen. También hay que tener en cuenta el espacio de color de la imagen. El espacio de color mas común es el RGB, empleado en mayor medida en cámaras digitales. Este espacio de trabajo usa los 3 colores Rojo, Verde y Azul como colores base y obtiene los demás colores por medio de la combinación de intensidades de los colores base. El espacio RGB suele ser una variable tipo matriz de dimensiones $M \times N \times 3$. Donde M y N son el número de píxeles que representa el alto y ancho de la imagen, y el número 3 indica los colores bases del espacio rojo, verde y azul. Además, existen otros espacios de colores aparte del RGB, como el HSI(tono, saturación e intensidad), el CMYK(cian, magenta, amarillo y negro) y el CIE $L^*a^*b^*$ [4, 11, 12].

3.3.1. Espacio de color HSI

El espacio de color HSI esta basado en la forma de percibir el color del ojo humano, debido a que describe los colores como un humano lo haría, por su tono y saturación, en contraste con el modelo RGB, el cual representa un color en base a las proporciones de los colores primarios (rojo, verde y azul). Las ecuaciones 1, 2, 3 y 4 permiten convertir

al espacio de color HSI por medio de las componentes RGB [11].

$$\theta = \cos^{-1} \left(\frac{0.5[(R - G) + (R - B)]}{[(R - G)^2 + (R - B)(G - B)]^2} \right) \quad (1)$$

$$H = \begin{cases} \theta & \text{si } B \leq G \\ 360 - \theta & \text{si } B > G \end{cases} \quad (2)$$

$$S = 1 - \frac{3}{(R + G + B)} [\min(R, G, B)] \quad (3)$$

$$I = \frac{(R + G + B)}{3} \quad (4)$$

3.3.2. Espacio de color $L^*a^*b^*$

El modelo CIE $L^*a^*b^*$ es un estándar internacional para la medición de color, adoptada por la Comisión International d'Éclairage (CIE) en 1976. Al igual que el modelo HSI, $L^*a^*b^*$ separa la información de intensidad de las componentes relacionadas con el color. La componente L^* almacena los valores de intensidad (con un rango de 0 a 100), los valores de a^* oscilan entre verde y rojo; y los valores de b^* varían de azul a amarillo (rango de -120 a 120 para ambas componentes cromáticas). Las ecuaciones 5, 6, 7, 8 y 9 expresan la transformación del modelo RGB a $L^*a^*b^*$ [12, 13].

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0.412453 & 0.357580 & 0.180423 \\ 0.212671 & 0.715160 & 0.072169 \\ 0.019334 & 0.119193 & 0.950227 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (5)$$

$$L^* = 116 * h \left(\frac{Y}{Y_w} \right) - 16 \quad (6)$$

$$a^* = 500 \left[h \left(\frac{X}{X_w} \right) - h \left(\frac{Y}{Y_w} \right) \right] \quad (7)$$

$$b^* = 200 \left[h \left(\frac{Y}{Y_w} \right) - h \left(\frac{Z}{Z_w} \right) \right] \quad (8)$$

$$h(q) = \begin{cases} \sqrt[3]{q} & q > 0.00885 \\ 7.787q + \frac{16}{116} & q \leq 0.00885 \end{cases} \quad (9)$$

Donde X_w, Y_w, Z_w son los valores triestímulo CIE XYZ del punto blanco de referencia.

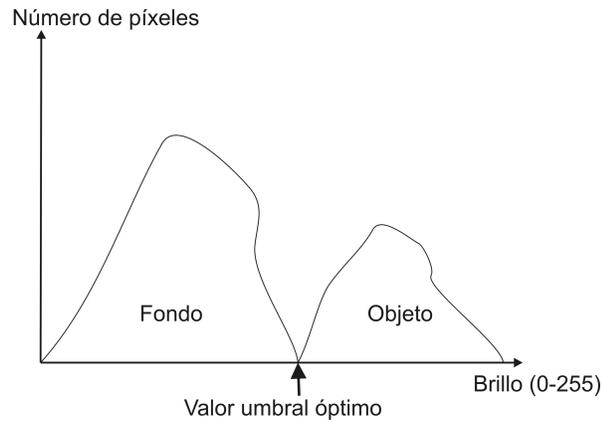
3.4. SEGMENTACIÓN

El proceso de segmentación consiste en distinguir y separar cada uno de los objetos presentes en la escena de la imagen. En el caso particular de este trabajo, se requiere separar el fruto de café del fondo. De esta manera, en la etapa de extracción de características se obtendrán las propiedades relacionadas únicamente con el fruto de café y no de objetos ajenos que puedan perturbar el proceso de clasificación. La segmentación de una imagen es lograda a través de dos rutinas básicas. Una de ellas se basa en la detección de bordes, identificando cambios drásticos entre píxeles se puede determinar si un dicho píxel hace parte del fondo o del objeto analizado. Y la otra metodología usada es basada en la detección de regiones. Esto mediante la asignación de píxeles a regiones con una similaridad compartida [14]. Aunque existen distintos tipos algoritmos de segmentación, en este trabajo se usarán específicamente dos de ellos. Uno de ellos utiliza la primera metodología mencionada, y el otro es basado en detección de regiones.

3.4.1. Método del valor umbral

Este método básicamente necesita un valor umbral de intensidad. Si en la imagen un píxel es mayor que dicho valor, el píxel perderá su antiguo valor en escala de grises y será blanco. Por otro lado, si el píxel tiene un valor de intensidad menor al umbral, este será negro. La gran desventaja de este método es que se deben conocer los valores de intensidad de la imagen para seleccionar un valor umbral adecuado. Sin embargo, hay una técnica que permite hallar un valor óptimo para el umbral. Este es llamado el método de Otsu. Este método, básicamente halla un umbral óptimo de manera automática que separe un objeto del fondo en una imagen [15]. En la figura 4 se observa de manera gráfica la explicación provista anteriormente.

Figura 4: Histograma y umbral óptimo [15].



3.5. OPERACIONES MORFOLÓGICAS

Las operaciones morfológicas son aquellas que modifican la forma de las estructuras (regiones u objetos) presentes en la imagen. Entre las operaciones morfológicas podemos encontrar la dilatación, erosión, apertura y reconstrucción [16]. Todas estas operaciones requieren un elemento estructural, el cual es usado sobre la imagen de entrada. Dicho elemento es una matriz de unos y ceros con un tamaño arbitrario, aunque normalmente mucho más pequeña que la imagen a procesar [17]. Estas operaciones se pueden usar para adecuar la imagen antes de extraer las características que se necesiten de ella.

3.5.1. Dilatación

La operación de dilatación sobre imágenes binarias incrementa el tamaño de los objetos presentes en ella. Este incremento es determinado por un elemento estructural, el cual funciona como una máscara que es convolucionada con la imagen a procesar. La diferencia radica en que la convolución utiliza operaciones aritméticas y no operaciones de conjuntos como la dilatación [11, 18].

3.5.2. Erosión

La erosión es la operación contraria a la dilatación, reduce el tamaño de los objetos de la imagen. Esta operación es ideal para eliminar pequeños puntos en la imagen binaria, funcionando adecuadamente como un filtro de detalles irrelevantes. Al igual que la dilatación, la erosión es análoga a la convolución, pero usando operaciones de conjuntos [18].

3.5.3. Apertura

Esta operación es simplemente la ejecución secuencial de una erosión seguida por una dilatación, ambos usando el mismo elemento estructural. Esta operación es funcional a la hora de eliminar pequeños objetos y preservar la forma de los objetos de gran tamaño en la imagen [17].

3.6. EXTRACCIÓN DE CARACTERÍSTICAS

Luego de la adquisición y adecuación de la imagen sigue la caracterización. Esta permite extraer información de los objetos en la imagen. Este proceso se debe llevar a cabo debido a que las imágenes segmentadas contienen una gran cantidad de información que puede ser redundante para el proceso. Por lo tanto se extrae la información cualitativa de los objetos de la imagen, estos rasgos se llaman patrones o modelos. Estas características son las entradas de los algoritmos que se encargan de la identificación de los objetos. Todo este proceso descrito anteriormente permite obtener características morfológicas, como la textura, color, forma, dimensiones físicas, entre otras. Mediante la extracción de estas características podemos obtener información relacionada al color. El modelo matemático que identifica los colores son los espacios de colores ya mencionados anteriormente en este documento, y para obtener información relevante de ellos se definen unas variables estadísticas como la media y la desviación estándar [19], las cuales están representadas por 10 y 11 respectivamente, donde N es la cantidad total de píxeles en la imagen, X_i el píxel analizado, σ es la desviación estándar, y μ es la media aritmética [20, 21].

$$\mu = \frac{1}{N} \sum_{i=0}^{N-1} X_i \quad (10)$$

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=0}^{N-1} (X_i - \mu)^2} \quad (11)$$

3.7. MÉTODOS DE CLASIFICACIÓN

Con el objetivo de preparar la información para la clasificación, se reduce la cantidad de datos obtenidos hasta el momento midiendo ciertas propiedades de los objetos de la imagen. El resultado del proceso anterior pasa al clasificador, cuya labor consiste en decidir a qué clase pertenece cada objeto. Los métodos de clasificación se pueden dividir en tres grandes tareas: estadístico, estructural o sintáctico; y el cognitivo. Los métodos estadísticos se basan en la teoría de Bayes del mínimo error, resolviendo el problema de clasificación a través de la probabilidad, es decir, clasificando un objeto si sus características son más probables de pertenecer a una clase que a otra. El método sintáctico trabaja con objetos que se describen mejor por propiedades cualitativas. Y el último es el cognitivo, que aborda temas como las redes neuronales artificiales (RNA). Estas simulan el comportamiento del cerebro, es decir su control se basa en el aprendizaje y en el seguimiento de patrones, de la misma manera como una persona lo haría. Este último método tiene varias ventajas sobre las demás, debido a su adaptabilidad, procesamiento paralelo y tolerancia a los errores [4]. Además de los ya clásicos métodos de clasificación, existe otro llamado máquinas de vectores de soporte (SVM por sus siglas en inglés, *Support Vector Machines*). El cual es un clasificador definido por un hiperplano que separa los dos grupos de datos a clasificar. Este método solo funciona cuando se tienen dos clases para clasificar [22].

4. DISEÑO METODOLÓGICO

4.1. TIPO DE ESTUDIO

El tipo de estudio implementado es de tipo descriptivo, debido a que se observan y miden las características importantes del fruto del café, como la forma y el color; con las cuales se desarrolla el algoritmo para la identificación de los frutos buenos y malos, por lo que se deben seguir ciertas etapas que permitan alcanzar los objetivos propuestos en esta investigación.

4.2. FUENTES DE INFORMACIÓN

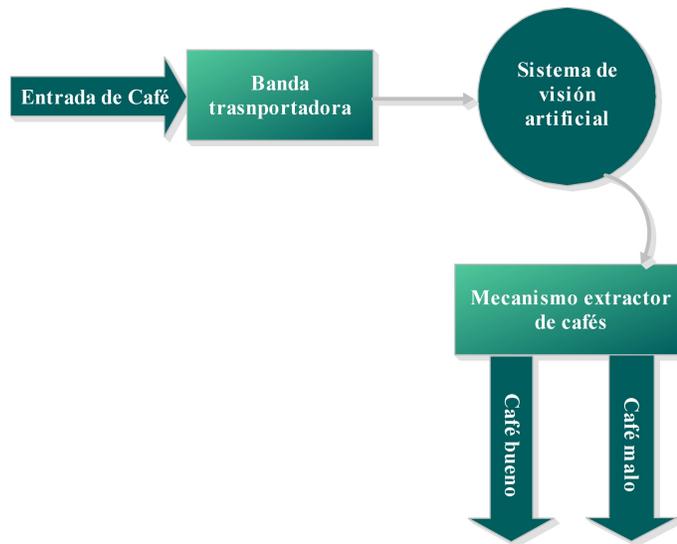
Para la realización de estas etapas es necesario contar con las teorías relacionadas con la temática de procesamiento de imágenes, las cuales son posibles de encontrar en distintas fuentes, dentro de las cuales destacan libros y manuales cuyo contenido esté relacionado con este proyecto. Como fuentes secundarias, el Internet y artículos científicos. Todas estas fuentes pueden ser vistas de manera detallada en la bibliografía de este documento.

4.3. METODOLOGÍA

El método usado es el deductivo ya que se parte desde una análisis general de las imágenes obtenidas de los frutos de café, dichas imágenes contienen información necesaria de los objetos presentes, llegando a un análisis particular etiquetando cada objeto presente en la imagen: café bueno o café malo.

A continuación se detallan los pasos metodológicos para el proceso de selección de frutos de café mediante visión artificial. Primero se explicará de manera general el proceso (ver figura 5), y luego se detallarán cada una de las etapas y pasos hechos para completar cada una de ellas.

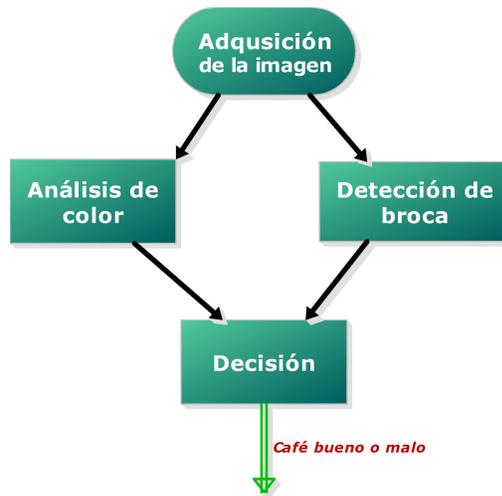
Figura 5: Esquema general del sistema (Fuente: los autores).



Primero, los frutos de café entran a la banda uno por uno y son transportados hasta el sistema de visión artificial, donde se tomarán fotos bajo un ambiente de luz controlada, además, en esta misma etapa se hará el procesado de la imagen y se decidirá si el café es bueno o malo. Una vez el fruto pase por esta etapa, resta la extracción, etapa en la cual se posicionará al final de la banda transportadora un dispositivo que dirigirá los frutos a dos contenedores distintos, dependiendo si el fruto es bueno o malo. El café caerá desde la banda hacia este dispositivo, el cual consta de una contenedor que almacena momentáneamente un café a la vez, el dispositivo cambiará de posición de acuerdo a la orden dada por el algoritmo de visión artificial, provocando que el café caiga del dispositivo.

Una vez descrito de manera general el funcionamiento del proyecto, se procederá a explicar las partes que componen a este, empezando con los algoritmos de procesamiento de imágenes; en la figura 5 se observan las fases que lo componen. El proceso empieza con la adquisición de la imagen a analizar, luego esta es procesada por dos algoritmos, uno de ellos detectará si el café tiene brocas; y el otro extraerá características de color con el objetivo de conocer si el fruto se encuentra en un estado de maduración ade-

Figura 6: Sistema de visión artificial propuesto (Fuente: los autores).



cuado. En base a los resultados obtenidos por los dos algoritmos se conoce si el fruto estudiado es apto para producción. Los algoritmos de visión artificial implementados fueron realizados en el lenguaje de programación Python 2.7.8 con las librerías de visión artificial OpenCV 2.4.9, las cuales presentan licencia BSD, es decir, son libres de usar tanto para fines comerciales y académicos [23].

4.3.1. Sistema de adquisición de Imágenes

Como ya se mencionó en la sección 3.3., el proceso de adquisición es la primera etapa a realizar antes de procesar una imagen, además, se debe tener en cuenta las condiciones y configuración en las que las imágenes son obtenidas.

Para la captura de las imágenes se usaron dos cámaras, cada una ubicada paralelamente con respecto a la otra (flechas en la figura 7), garantizando el análisis de los dos lados del fruto de café en busca de broca, y además, comprobar que el estado de maduración del fruto.

Con el objetivo de tomar una imagen óptima para su procesamiento posterior, se realizaron los siguientes ajustes:

- La cámara está situada aproximadamente a 5 centímetros del fruto de café. Esta distancia es utilizada con el objetivo de poder capturar una posible broca, debido

a que la evidencia de su presencia es un pequeño punto negro.

- Para efectos de optimización de la velocidad del algoritmo, las imágenes fueron capturas con una resolución de 320x240.
- Iluminación LED blanca, en formato de tira, fue usada como fuente de luz, ver figura 8.
- Se usó un fondo blanco para facilitar la detección de la broca.

Figura 7: Posición de las cámaras (Fuente: los autores).

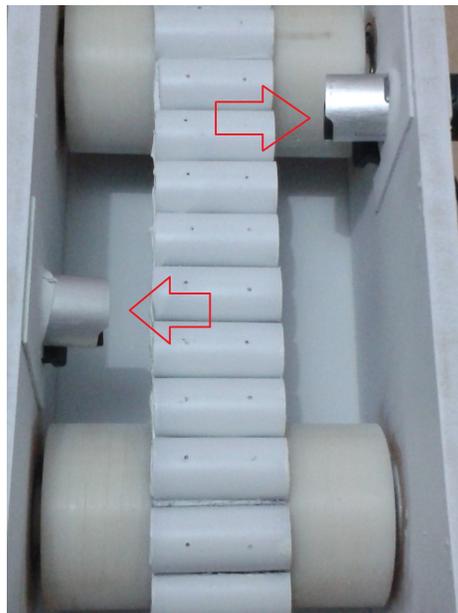


Figura 8: Iluminación (Fuente: los autores).



4.3.2. Análisis de Color

Una vez seleccionado el fondo apropiado para la captura de las imágenes y establecida la configuración de las cámaras, es posible proceder a las fases de procesamiento de la imagen. La primera fase a explicar será el análisis de color, el cual establece si un fruto de café se encuentra en el estado de maduración adecuado, el algoritmo de esta fase se encuentra descrito en el diagrama de flujo de la figura 9.

El análisis de color consta de tres etapas principales: segmentación, extracción de características y algoritmo de clasificación. La primera, como se mencionó en la sección 3.4., consiste en separar el objeto de estudio del fondo. Seguido de este proceso se encuentra la etapa de extracción de características, la cual se encuentra dividida en unas sub-etapas, como las conversiones de los espacios de colores, la normalización de los datos, los cálculos de la media y la desviación estándar; y la conformación del vector de características.

Figura 9: Diagrama de flujo para clasificación por color (Fuente: los autores).



4.3.2.1. Segmentación

Debido a que en la etapa de conversión de los espacios de colores y extracción de características solo se necesita la información concerniente al café, es imperativo pasar primero por un proceso de segmentación. Para lograr dicho proceso, primero se convierte la imagen original a escala de grises, el cual es igual al promedio aritmético de las componentes RGB [11]. Antes de proceder a binarizar la imagen, se pre-procesa la

captura en escala de grises con una operación morfológica de dilatación. El objetivo de esta es mejorar el proceso de binarización y evitar posibles defectos. Seguidamente, se usó el método de Otsu para hallar el umbral óptimo para binarizar la imagen. Una vez binarizada la imagen, se efectuó una multiplicación punto a punto entre las matrices de la imagen original y la binarizada. De esta manera el fondo de la imagen original es eliminado, como se puede apreciar en la figura 9. Una vez completado el proceso de segmentación ya es posible trabajar con la imagen y procesarla para la extracción de características.

4.3.2.2. Extracción de Características

Como ya se mencionó en el marco teórico de este trabajo, los espacios de colores $L^*a^*b^*$ y HSV separan la información cromática de la luminosidad, propiedad que los hace más adecuados que el espacio RGB para estudiar los colores de un objeto. Es por esta razón que se opta por usar estos dos espacios de colores para el análisis de color del café, sin embargo, el formato de las fotos adquiridas por las cámaras es el RGB, por lo tanto, la imagen adquirida se debe convertir a los espacios de colores $L^*a^*b^*$ y HSV a través de unas operaciones matemáticas, ver secciones 3.3.1. y 3.3.2..

Al realizar las conversiones requeridas, se obtienen dos matrices nuevas que representan a la imagen original, pero una de ellas en el espacio HSV y la otra en el CIE $L^*a^*b^*$. Una vez hechas las conversiones a los espacios de colores se procede a extraer las características, debido a que el color es vital para determinar si un café es apto para el proceso de producción. A través de la media y la desviación estándar se puede cuantificar la información con respecto al color de los frutos, pero para lograrlo se deben seleccionar las componentes de los modelos de color adecuados para dicho proceso. Como se mencionó en la sección 3.3., las componentes a^* y b^* del espacio de color $L^*a^*b^*$ determinan que cantidad de color hay en la fruta, siendo a^* la variación entre rojo y verde; y b^* entre amarillo y azul. De igual manera, las componentes H y S del espacio HSV son las componentes que guardan la información de color en este espacio de color, por lo tanto, estas cuatro componentes son analizadas. No obstante, para poder estudiarlas se necesita una medida de ellas, por consiguiente, se calcula la media y la desviación estándar de las componentes a^* , b^* , H y S (ver sección 3.6.); obteniendo un total de 8 características (ver tabla 1), dos por cada componente de la captura analizada.

No obstante, los valores que manejan estos espacios de colores son distintos, y por consiguiente, al extraer las características de color de ellos se manejarían distintos rangos de valores. Este problema afecta a la clasificación, debido a que valores grandes tienen una mayor influencia que los valores pequeños, y por ende, afectaría el correcto funcionamiento del clasificador [19]. Por lo tanto, se realiza una normalización estadística no lineal de las características extraídas de las imágenes representadas en HSV y CIE L*a*b*, con el objetivo de que manejen un mismo rango de valores. Esta normalización se puede realizar a través de las ecuaciones 12, 13, 14 y 15.

$$\bar{x}_k = \frac{1}{N} \sum_{i=1}^N x_{ik} \quad k = 1, 2, \dots, l \quad (12)$$

$$\sigma_k^2 = \frac{1}{N-1} \sum_{i=1}^N (x_{ik} - \bar{x}_k)^2 \quad (13)$$

$$y = \frac{x_{ik} - \bar{x}_k}{r\sigma_k} \quad (14)$$

$$\hat{x}_{ik} = \frac{1}{1 + \exp(-y)} \quad (15)$$

La tabla 1 representa al vector de características que ingresa al entrenamiento del clasificador. Por cada muestra de imagen que se ingrese, esta tendrá su vector de características correspondiente. Una vez el clasificador haya sido entrenado y se encuentre en funcionamiento, el proceso será similar. Todos los pasos descritos anteriormente se realizarán de nuevo. Se obtendrá el vector de características y se ingresará al clasificador, por último este decidirá si la imagen en estudio actualmente es de un fruto de café en el estado de maduración adecuado; basándose en la experiencia previa del entrenamiento.

4.3.2.3. Clasificador

Para la etapa de clasificación se implementaron tres tipos de clasificadores, uno por redes neuronales, un clasificador bayesiano y una máquina de vectores de soporte; entre estos tres algoritmos se seleccionará uno en base a unos índices de desempeño que se obtendrán a partir de una curva ROC (Receiver Operating Curve).

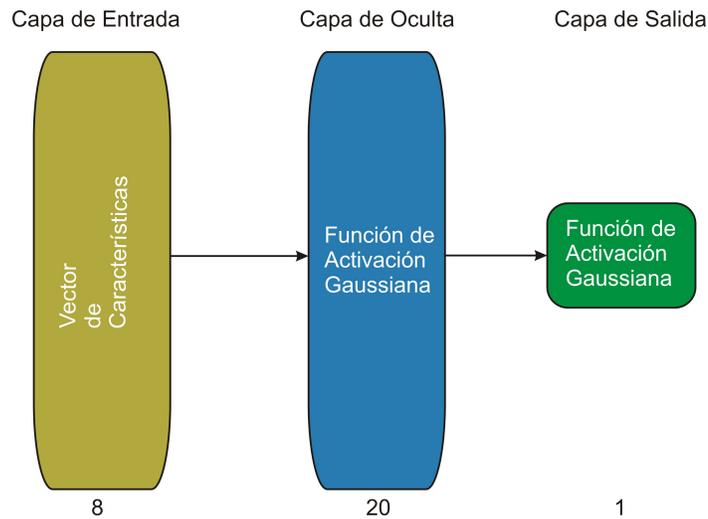
La red neuronal usada fue entrenada mediante el método de back-propagation, y consta de una capa de entrada de ocho neuronas y una capa oculta con veinte. Además, todas

las neuronas de la red constan de una función de activación de Gauss. En la figura 10 se observa la arquitectura usada.

Tabla 1: Vector de características

#	Características
1	Desviación estándar componente a^* de $L^*a^*b^*$
2	Media componente a^* de $L^*a^*b^*$
3	Desviación estándar componente b^* de $L^*a^*b^*$
4	Media componente b^* de $L^*a^*b^*$
5	Media componente H de HSI
6	Desviación estándar componente H de HSI
7	Media componente S de HSI
8	Desviación estándar componente S de HSI

Figura 10: Red neuronal (Fuente: los autores).



La máquina de vectores de soporte (SVM) usada es de tipo C, la cual permite clasificar dos clases o más. Además, la SVM tipo C es capaz de tratar con una imperfecta separación de las clases cuando los conjuntos de entrenamiento no son linealmente separables, permitiendo un mejor entrenamiento. Además, se usó un kernel de base radial, el cual realiza un mapeo al conjunto de entrenamiento con el fin de que se parezca a un grupo de datos linealmente separable, y así realizar un entrenamiento adecuado [22].

Concerniente al clasificador bayesiano, este presenta una ventaja sobre los demás, y es su facilidad de configuración; debido a que todos los valores e información necesitada por él son adquiridos desde el conjunto de entrenamiento, por lo tanto no requiere de otras entradas o ajustes aparte del conjunto de entrenamiento [24].

La implementación de todos estos clasificadores fue realizada con las funciones provistas por las librerías de OpenCV.

4.3.3. *Detección de broca en el café*

Para la detección de la broca en el café se utilizó segmentación por umbralización. La imagen original fue transformada a escala de grises, y luego se aplicó a esta imagen un criterio de binarización. Todos los píxeles que presentan un valor de intensidad menor o igual a 30 serán tomados como uno, y los demás serán catalogados como 0, ver ecuación 16. Es decir las partes oscuras de la imagen capturada serán detectadas como brocas, esto es posible gracias a la adecuación del sistema de adquisición de imágenes. Al colocar un fondo blanco y los frutos de café tener tonos claros, las únicas zonas oscuras restantes serían los orificios de las brocas.

$$g(x, y) = \begin{cases} 1 & I(x, y) < 30 \\ 0 & I(x, y) \geq 30 \end{cases} \quad (16)$$

Para la elección de este umbral para la detección de la broca, se hizo primero un estudio del histograma de la imagen de la figura 13a.) en escala de grises. Al observar este histograma, es evidente que la mayoría de píxeles tienen valores mayores a 50. Por otro lado, si se hace zoom a este histograma en la zona de 0 a 30, claramente se observa la baja cantidad de píxeles negros, esta zona corresponde a los píxeles más oscuros de la imagen. En base a esta premisa es factible concluir que dichos píxeles oscuros corresponden a las brocas presentes en el café. Por esta razón se binariza la imagen en base al criterio de la ecuación 16.

En la figura 13a.) se observa una captura de un fruto de café verde, esta imagen es segmentada por el método descrito en el párrafo anterior, y como resultado se obtiene la figura 13b.). Una vez segmentada la broca se cuenta el número de zonas blancas presentes en la imagen, si el conteo es cero; significa que no se encontraron brocas en el

Figura 11: Histograma (Fuente: los autores).

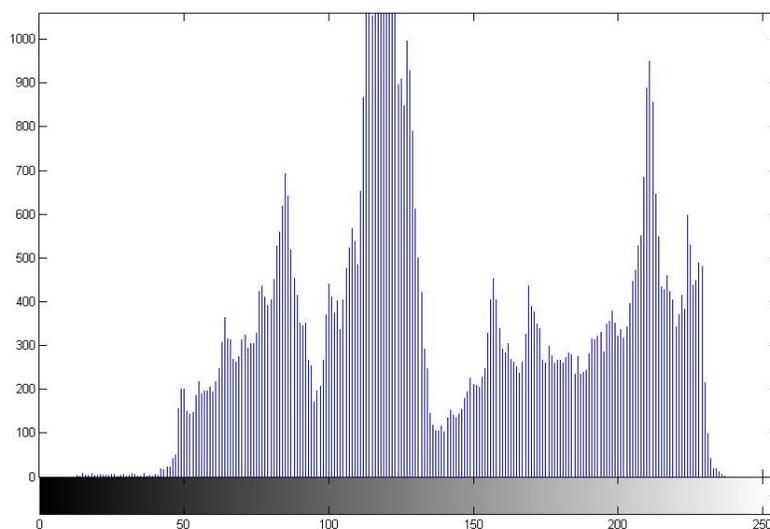
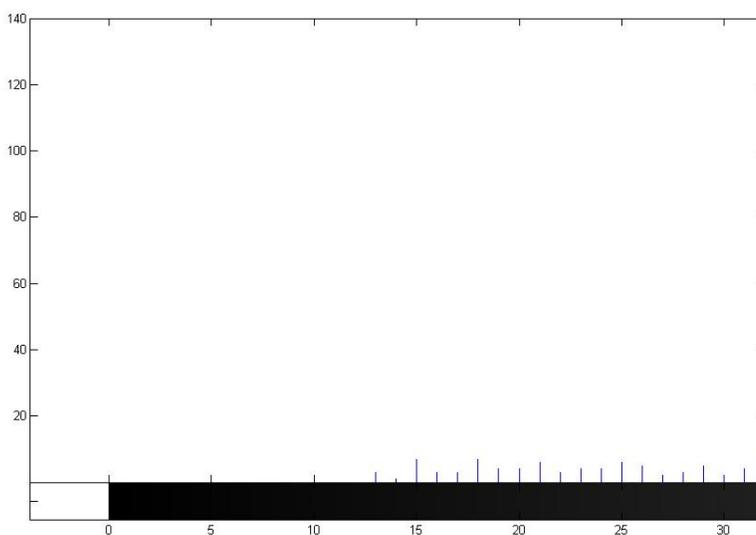


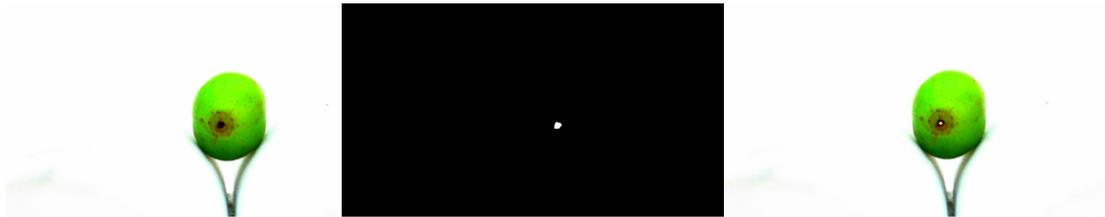
Figura 12: Histograma (Fuente: los autores).



fruto. Sobre la imagen original son colocados unos puntos amarillos sobre la broca, con el fin de identificar si esta fue detectada o no, como se puede apreciar en la figura 13c.). De esta manera se comprueba la viabilidad del método descrito en párrafos anteriores

para lograr la detección de la broca en el fruto de café.

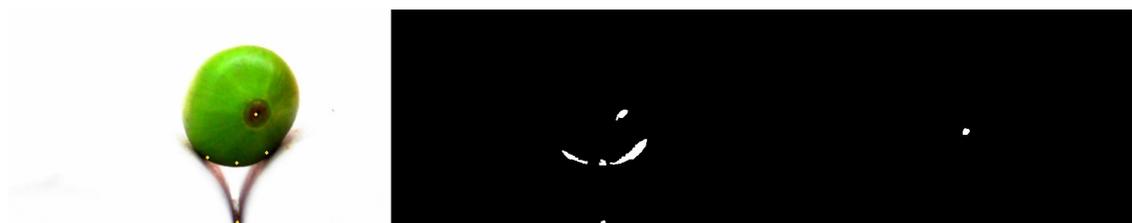
Figura 13: a.) Captura del fruto de café, b.) Resultado de la segmentación, c.) Detección de la broca (Fuente: los autores).



Sin embargo, este método al estar basado en buscar zonas negras en la imagen, las sombras dejadas por el fruto pueden ser detectadas como brocas también, como se aprecia en las figuras 14a y 14b. Para solucionar este inconveniente se calculó el centroide del fruto de café y de cada una de las zonas detectadas como brocas, a partir de las coordenadas de estas zonas, se calcula la Distancia Euclidiana (ver ecuación 17) desde cada una de ellas hasta el centroide del café. Aquellas zonas con una distancia mayor a 40 píxeles no son consideradas como brocas, por el contrario; aquellas cercanas al centro del café son tomadas como brocas. De esta manera se genera una nueva imagen con la zona de la sombra eliminada, como en la figura 14c. La solución parte del hecho de que las brocas siempre entran por el ombligo del fruto, por lo tanto, aquellas zonas detectadas aledañas a dicho ombligo (el centro del café) son las brocas.

$$d = \sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2} \quad (17)$$

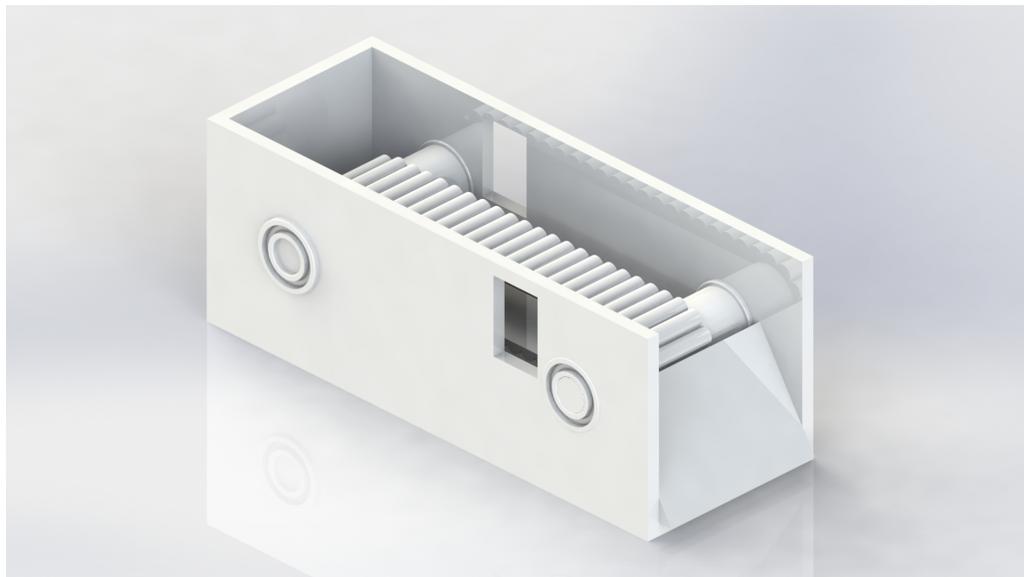
Figura 14: a,b) Sombra detectada como broca, c) Sombra eliminada (Fuente: los autores).



4.3.4. *Diseño del Prototipo de la Banda Transportadora*

Como se ha mencionado anteriormente, las cámaras deben captar todos los granos de café para su procesamiento en un ambiente de luz controlado. Además, los granos de café deben ser transportados para que cada uno de ellos pueda ser analizado y extraído. En el presente trabajo se propone el uso de una banda transportadora para lograr este fin, figura 15.

Figura 15: Banda Transportadora (Fuente: los autores).



La banda está conformada por diferentes partes, entre las cuales se tienen los ejes, cuya función es ser un apoyo para la banda, además de transmitir el movimiento de los motores; los rodamientos que le proporcionan a los ejes el grado de libertad para rotar; la banda donde se ubican los granos de café para ser trasladados; y la estructura, donde se acopla el resto de elementos mencionados anteriormente. A continuación se detalla el diseño y selección de dichos elementos.

4.3.4.1. Estructura

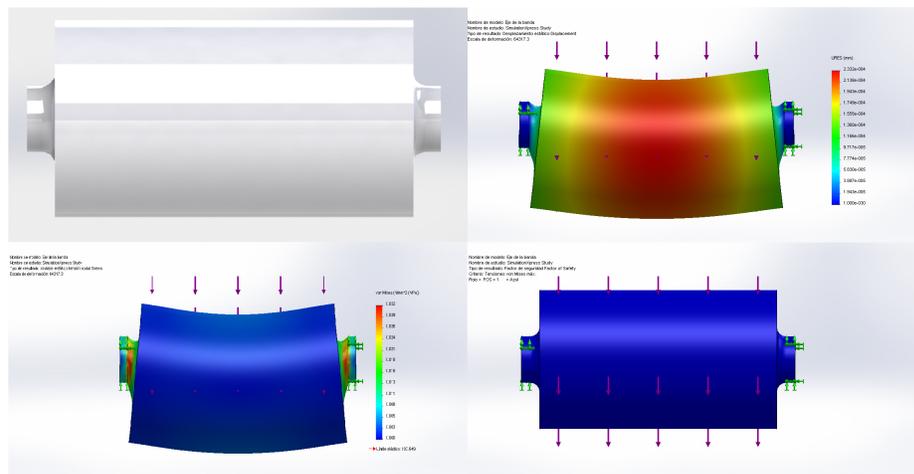
Para de la estructura se disponen de dos opciones para la selección del material, acero y madera. Los factores determinantes son el precio, formato o normalización en la que se compra el material, facilidad de manipulación y peso. Estos factores se comparan en la tabla 2.

Tabla 2: Comparación entre alternativas de material.

Material	Acero	Madera
Precio	Muy elevado, ronda alrededor de los \$100.000 - \$200.000, dependiendo del espesor.	Bajo, ronda alrededor de los \$20.000 a \$50.000, dependiendo de los espesores y el tipo de madera.
Formato	Usualmente las láminas tienen unos tamaños definidos de fábrica. El más pequeño es de 1,20x2,40 m, aunque se puede optar por retales, los cuales son más pequeños y económicos.	Las medidas de las láminas son más variadas, incluso se puede comprar solo el material necesario y dimensionado.
Nivel de Manipulación	Alto, requiere de varias herramientas de trabajo pesado, las cuales tienen un alto costo.	Medio, requiere de herramientas que se pueden encontrar en una casa y son menos costosas en comparación a las usadas con el acero.
Peso	Muy pesado, aumentaría los gastos del transporte.	Liviano, gastos de transporte bajos.
Resistencia	Muy resistente, posee una gran durabilidad.	Buena resistencia, es un material que es fácilmente afectado por la humedad y el medio.

Los ejes, fabricados en nylon macizo de 3 pulgadas, un material resistente y económico. De manera general las características del nylon son: buena dureza, capacidad de amortiguar golpes, ruido y vibraciones; resistencia al desgaste, al calor, a la abrasión, anti-adherente, excelente dieléctrico, y por último, una excelente abrasión [25]. El eje fue maquinado para formar un rodillo, el cual puede resistir una fuerza mayor a 10N; tal como se ve en la figura 16.

Figura 16: De izquierda a derecha y de arriba a abajo, Eje de Banda, Trazo del Esfuerzo, Trazo de Desplazamiento y Factor de seguridad (Fuente: los autores).



4.3.4.2. Selección de Rodamientos

Para elegir el rodamiento adecuado se usó la selección basados en la carga. Se determina el tipo de carga a las que se someterán los rodamientos, en este caso solo serán cargas radiales, esto se debe a que no se aplica ninguna fuerza a lo largo del eje del rodamiento, según la tabla 3.

Tabla 3: Tipos de Rodamientos y desempeño

						
Tipo de Rodamiento	Series	Carga Radial	Carga Axial	Cargas Combinadas	Velocidad Alta	Desalineación Angular
 Deep Groove Ball Bearing	600-6000- 6200-6300- 16000- 16100- 6800-6900- BL	Buena	Media 2 direcciones	Buena	Excelente	Buena
 Double Row Deep Groove Ball Bearing	4200-4300	Buena	Media 2 direcciones	Media	Media	Pobre
 Angular Contact Ball Bearing	7200-7300	Buena	Buena 1 dirección	Buena	Excelente	Pobre
 Double Row Angular Contact Ball Bearing	3200-3300- 5200-5300	Buena	Buena 2 direcciones	Buena	Media	Pobre

 Four-Point Contact Ball Bearing	QJ200- QJ300	Pobre	Buena 2 direcciones	Media	Buena	Pobre
 Self- Aligning Ball Bearing	1200-1300- 2200-2300	Media	Pobre 2 direcciones	Pobre	Buena	Excelente
 Cylindrical Roller Bearing	NU-N200- 300-400- 1000-2200- 2300	Buena	Ninguna	Ninguna	Excelente	Media
 Cylindrical Roller Bearing	NJ-NF200- 300-400- 1000-2200- 2300	Buena	Media 1 sola dirección	Media	Buena	Media
 Cylindrical Roller Bearing	NUP200- 300-400- 1000-2200- 2300	Buena	Media 2 direcciones	Media	Buena	Media
 Tapered Roller Bearing	HR30200- 30300- 30300DJ- 32000- 32200- 32300- 33000- 33100- 33200	Buena	Buena 1 sola dirección	Buena	Media	Media

 Spherical Roller Bearing	21300- 22200- 22300- 23000- 23100- 23200- 23900- 24000- 24100	Excelente	Media 2 direcciones	Buena	Media	Excelente
 Thrust Ball Bearing	51100- 51200- 51300- 51400- 52200- 52300- 52400	Ninguna	Buena 1 sola dirección	Ninguna	Pobre	Ninguna

La carga radial máxima a la que será sometido el rodamiento es 10N. Esta carga elegida como parámetro de diseño, será empleada en el método de selección de rodamiento basado en carga, haciendo uso de la ecuación 18 [26].

$$L_{10h} = \frac{1,000,000}{60n} \left(\frac{c}{p} \right)^3 \quad (18)$$

Donde, L_{10h} es la vida del rodamiento en horas antes de que aparezca la fatiga en el metal. p es la carga equivalente del rodamiento. n es la velocidad rotacional en RPM. En este caso 80 RPM. c es la tasa de carga básica. Se encuentra en las tablas de los catálogos. Para los rodamientos de bola $C = C_r$.

El valor de p se calcula con la ecuación 19:

$$p = XF_r + YF_a \quad (19)$$

X es el factor radial. F_r es la carga radial constante actual. En este caso $F_r = 10N$. Y

Tabla 4: Tabla de valores de carga dinámica y estática equivalente

Carga dinámica equivalente $p = Xf_r + YF_a$					
$\frac{f_0 F_a}{C_{or}}$	e	$\frac{F_a}{F_r} \leq e$		$\frac{F_a}{F_r} > e$	
		X	Y	X	Y
0.172	0.19	1	0	0.56	2.30
0.345	0.22	1	0	0.56	1.99
0.689	0.26	1	0	0.56	1.71
1.03	0.28	1	0	0.56	1.55
1.38	0.30	1	0	0.56	1.45
2.07	0.34	1	0	0.56	1.31
3.45	0.38	1	0	0.56	1.15
5.17	0.42	1	0	0.56	1.04
6.89	0.44	1	0	0.56	1

Carga estática equivalente

$\frac{F_a}{F_r} > 0.8, p_o = 0.6F_r + 0.5F_a$ $\frac{F_a}{F_r} \leq 0.8, p_o = F_r$

es el factor axial. F_a es la carga axial constante actual. En este caso $F_a=0N$. Tanto X como Y , se de terminan usando la tabla 4.

f_0 Factor del coeficiente de rodamiento. C_{or} Tasa de carga radial estática. C_r Tasa de carga radial dinámica.

En este caso se usó el rodamiento 6006 de la serie 6000. Se trata de un rodamiento de bola, que cumple con las dimensiones requeridas de diámetro interno de 1 pulgada y diámetro externo de 3 pulgadas.

Los datos de carga y velocidad a emplear son los siguientes:

- $f_0 = 14,7$
- $C_{or} = 1860 Lbs$
- $C_r = 2980 Lbs = 13.255,70 N$
- $F_a = 0 N$
- $F_r = 2 N$
- $n = 80 RPM$

Con lo que es posible calcular lo siguiente y compararlo con los datos de la tabla 4.

$$\frac{f_0 F_a}{C_{0r}} = \frac{14,7 \times 0}{1860} = 0 \quad (20)$$

$$\frac{F_a}{F_r} = \frac{0}{2} = 0 \quad (21)$$

Si $\frac{F_a}{F_r} \leq 0.8$ entonces $p_0 = F_r$. Esto se debe a que no existe una carga axial a considerar, entonces.

$$L_{10h} = \frac{1'000.000}{60n} \left(\frac{c}{p} \right)^3 = \frac{1'000.000}{60 \times 80 RPM} \left(\frac{13.255,70 N}{2N} \right)^3 = 6.064 \times 10^{13} \text{ horas} \quad (22)$$

La vida útil es increíblemente alta por lo que este rodamiento es de total confianza.

La banda fue realizada de caucho con cilindros nylon cortados en media luna. La funcionalidad de estas medias lunas es mantener los granos de café separados y que no se muevan de su posición al encontrarse en movimiento la banda. Al igual que los ejes, se decidió por nylon por su fácil maquinado, además de su bajo precio.

4.3.4.3. Selección de Motor

Una vez construida la banda, resta la selección del motor que la moverá. Este motor debe ser capaz de vencer la inercia de ambos ejes que sostienen la banda, para que estos efectúen el movimiento. Por lo tanto, se debe calcular el torque mínimo requerido del motor para mover los ejes de la banda.

$$\tau = I\alpha \quad (23)$$

Donde: τ : Torque. I : Inercia. α : Aceleración angular.

Datos conocidos:

$a_0 = 0,02 m/s^2$, Aceleración de la banda en el arranque.

$\rho_{nylon} = 1120Kg/m^3$, Densidad del nylon PA6.

$r_{Eje} = 0,0381m$, Radio más grande del eje.

$r_{CP} = 0,0127m$, Radio más pequeño del eje.

Datos calculados:

La aceleración angular se calcula como,

$$\alpha = \frac{a}{r} \quad (24)$$

Donde: a: es la aceleración de de la banda al momento de arrancar. r: radio de giro o radio más grande del eje.

Aplicando la ecuación 24 se tiene que la velocidad angular es,

$$\alpha_0 = 0,525 \text{ rad/s}^2$$

La inercia del eje se puede calcular usando la ecuación de inercia para un cilindro.

$$I_{Cilindro} = \frac{1}{2}mr^2 \quad (25)$$

Donde: m: masa del cilindro. r: radio del cilindro.

Dado a la forma de los ejes para calcular la inercia total es necesario hacer la sumatoria de la inercia de los 3 cilindros que conforman al eje. Tal como se ve en la figura 17

Por lo que la Inercia total del eje es:

$$I_{Eje} = I_{C1} + I_{C2} + I_{C3} \quad (26)$$

Dado que el cilindro 1 y el 2 son exactamente iguales, entonces $I_{C1} = I_{C2} = I_{CP}$, la ecuación 26 queda,

$$I_{Eje} = 2I_{CP} + I_{C3} \quad (27)$$

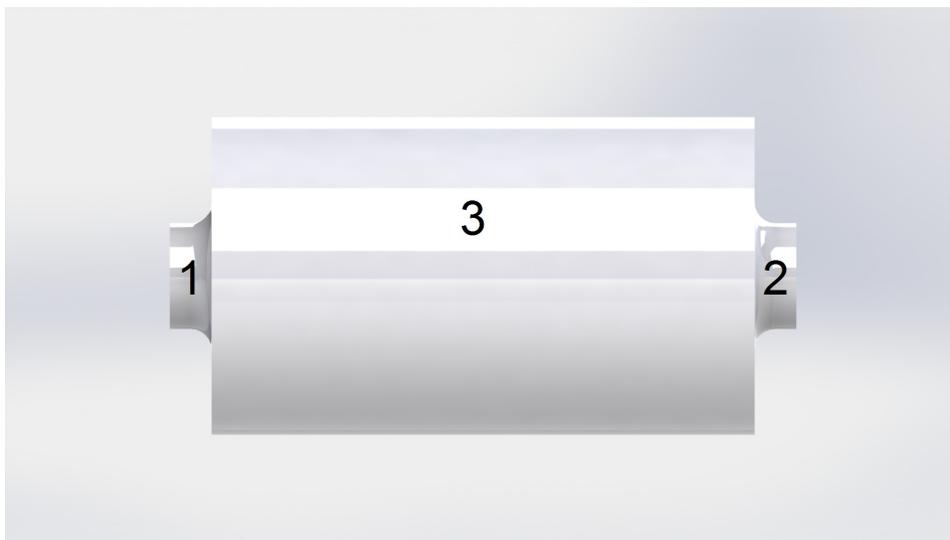
reemplazando 25 en 27 se obtiene:

$$I_{Eje} = m_{CP}r_{CP}^2 + \frac{1}{2}m_3r_3^2 \quad (28)$$

Antes de aplicar la ecuación 28 se debe calcular la masa de los cilindros, para esto se tiene la siguiente ecuación:

$$m = \rho V \quad (29)$$

Figura 17: No. de Cilindros que conforman el eje (Fuente: Los autores)



Donde: ρ : es la densidad del material con la que está hecha el cilindro en este caso nylon PA6. V : volumen del cilindro.

El volumen de un cilindro está dado por,

$$V_{Cilindro} = \frac{\pi r^2}{4} h \quad (30)$$

Aplicando la ecuación 30 se obtiene:

$$V_{CP} = 5,067 \times 10^{-6} m^3$$

$$V_3 = 6,840 \times 10^{-4} m^3$$

Utilizando los valores de los volúmenes se obtienen las masas.

$$m_{CP} = 5,675 \times 10^{-3} Kg$$

$$m_{C3} = 0,766 Kg$$

Un vez con estos valores de masas se procede a calcular la inercia total del eje,

$$I_{Total} = 5,57 \times 10^{-4} Kgm^2$$

Finalmente con la inercia se puede calcular el torque en la ecuación 23 obteniendo,

$$\tau = 2,924 \times 10^{-4} Nm$$

Concluyendo, cualquier motor cuyo torque sea mayor a $2,924 \times 10^{-4} Nm$ será capaz de mover la banda. Por lo tanto se escoge un servomotor PowerHD 1501 MG (ver figura

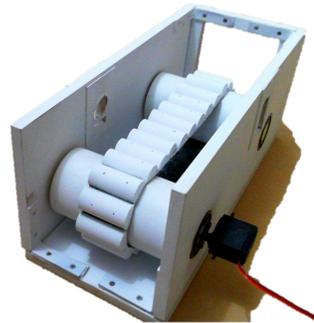
18), con un torque igual a 15 Nm [27]. Este servomotor fue modificado con el objetivo de eliminar la restricción de giros entre 0° y 180° , sin esta restricción el motor puede girar libremente.

Figura 18: Motor seleccionado [27].



En la figura 19 se observa el prototipo construido a partir del diseño planteado anteriormente.

Figura 19: Prototipo de Banda transportadora construida (Fuente: Los autores).



4.3.5. Prototipo del Dispositivo Extractor de Frutos de Café

El dispositivo extractor que se encarga de separar los frutos buenos de los malos consta de dos partes, una rampa y un pequeño contenedor accionado por un servomotor (ver figura 20a). Al caer los frutos desde la banda, estos son almacenados momentáneamente en el pequeño contenedor (ver figura 20b). En la rampa se encuentra situado un sensor de presencia (ver figura 20c), este detecta si el fruto ha llegado al contenedor, una vez

detectado, un servomotor ubicado en la parte de abajo de la rampa se acciona, provocando que el contenedor se mueva y el café caiga a un recipiente donde se almacenarán los frutos correspondientes, dependiendo si es un café apto para producción o no. El contenedor tiene tres posiciones definidas: una en estado normal, es decir, preparado para recibir un nuevo fruto de café; la otra posición se encuentra a 90° en sentido de las manecillas del reloj y la otra a 90° en sentido contrario a las manecillas. El servomotor recibe órdenes de un microcontrolador, que a su vez se comunica con el software de visión artificial implementado en la computadora.

Figura 20: a.) Dispositivo Extractor, b.) Contenedor, c.) Rampa (Fuente: Los autores).

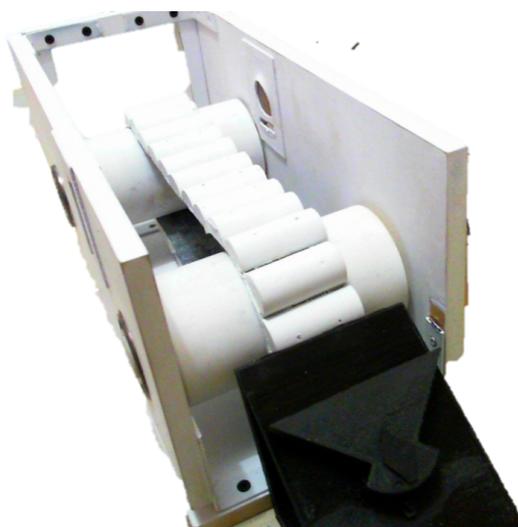


En la figura 21 se observa el dispositivo separador construido, el cual fue fabricado a través de impresión 3D. En la figura 22 el dispositivo extractor se encuentra posicionado al final de la banda, lugar donde recibe los frutos de café.

Figura 21: Dispositivo Extractor (Fuente: Los autores).



Figura 22: Banda y dispositivo extractor (Fuente: Los autores).



4.3.5.1. Electrónica

La electrónica que se emplea en la banda consta de 3 partes, cada una de ellas con una gran importancia para el funcionamiento del sistema. Dos de estas partes implementadas con un elemento común, el arduino, cuya función es la de controlar distintos aspectos fundamentales para el funcionamiento del sistema de adquisición de imágenes, las 3 partes se detallan a continuación.

Debido a los diferentes ambientes en lo que se puede emplear la banda la iluminación debe tener la capacidad de cambiar el valor de la intensidad lumínica emitida por los LEDs. La intensidad de la luz es regulada a través del código de arduino, modificando el ancho de pulso de la señal PWM enviada.

De igual manera, el motor ha de tener una velocidad adecuada para garantizar el correcto funcionamiento de los algoritmos de procesamiento de imágenes, con tal de que las fotos no queden borrosas al ir el motor muy rápido. Al igual que la iluminación, la velocidad del motor es manipulada a través de una señal PWM modificada en el código del arduino.

En el dispositivo de extracción se encuentra posicionado un servomotor, el cual es accionado por el arduino mencionado anteriormente, el cual se encuentra conectado al

PC. La respuesta enviada por el arduino al servomotor está ligada a la decisión tomada por los algoritmos de visión artificial, permitiendo que los cafés sean extraídos. Sin embargo, la sola decisión de los algoritmos de visión artificial no es suficiente, dado que se requiere conocer si en el dispositivo extractor está posicionado un fruto de café. La detección del café se realiza a través de un sensor CNY70 [28], una vez el sensor se active el servomotor se acciona en la dirección comandada por los algoritmos de visión artificial.

4.3.6. Presupuesto

En la tabla 5 se detallan los gastos hechos para la realización de este proyecto. En esta lista no se incluyen los materiales adquiridos previamente por los investigadores antes de la realización de este trabajo.

Tabla 5: Presupuesto

Concepto	Valor Unitario (COP)
Materiales	
Nylon 3"	\$32.000
Nylon 1"	\$53.000
Madera	\$65.000
Insumos	
Pintura	\$40.000
Equipos	
(2) Microsoft Lifecam Studio	\$160.000
Servicios	
Impresión 3D	\$44.000
Maquinado de Nylon de 1"	\$20.000
Maquinado de Nylon de 3"	\$40.000
Transporte	
Gastos no facturables	\$43.700
Pruebas de campo	\$400.000
Total	\$898.000

5. ANÁLISIS DE LOS RESULTADOS

Antes de medir el rendimiento del sistema total, se realizó una prueba mediante el método tradicional de flotes (ver figura 23), el cual consiste en almacenar en agua los frutos de café, y aquellos que floten serán los cafés malos. El objetivo de esta prueba es conocer de antemano que cafés están malos y poder analizar el rendimiento del clasificador propuesto. De los frutos recolectados se tomaron aleatoriamente 58 para probar el algoritmo propuesto.

Figura 23: Flote de los frutos (Fuente: los autores).

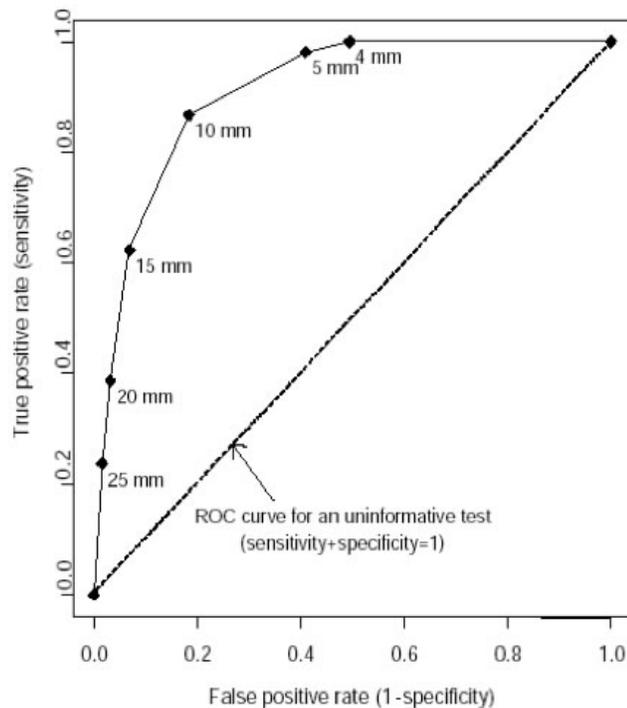


Una vez realizada la prueba mediante el método de flotes, se procede a analizar el desempeño de cada uno de los clasificadores con las muestras tomadas, y en base al rendimiento obtenido elegir el clasificador con el menor error de clasificación. Para ejecutar este análisis se usa la curva ROC (*Receiver operating characteristic curve*), de la cual se obtienen los índices de desempeño de los clasificadores estudiados. Con la curva ROC se puede observar la relación entre las muestras clasificadas adecuadamente (PVP, proporción de verdaderos positivos) y las muestras que no están clasificadas correctamente (PFP, proporción de falsos positivos) [19].

En el eje X de la curva ROC es representada por PFP y el eje Y por PVP. Los puntos

mínimos y máximos son $(0,0)$ y $(1,1)$ respectivamente. La curva de un clasificador perfecto empieza en el punto $(0,0)$ y sube hasta la esquina superior izquierda, luego va hacia el punto $(1,1)$. Con esto dicho, se puede conocer que el clasificador que se acerca más a este comportamiento será el más adecuado. Otra forma de medir el rendimiento del clasificador es obteniendo el área bajo la curva (AUC, *Area Under Curve*). En el caso del clasificador perfecto, dicha área sería igual a 1. Por otro lado, una diagonal que atraviesa la gráfica desde el origen hasta el punto $(1,1)$, indica una curva de un clasificador no funcional (ver figura 24). Cualquier curva bajo esta línea no es adecuada para su uso [29].

Figura 24: Curva ROC [29].



En la figura 25 se trazaron las tres curvas ROC de los clasificadores utilizados. El Bayesiano, la red neuronal multicapa y la máquina de vectores de soporte (SMV). En la gráfica se puede observar claramente que el clasificador Bayesiano es el mejor de los tres, presentando un área bajo la curva de 1. Por otro lado, la red neuronal y la SVM, tuvieron un área de 0.5 y 0.69 respectivamente, por lo tanto se decidió usar el clasificador Bayesiano. De igual forma, se midió la capacidad de detección del algoritmo de brocas, mediante otra curva ROC, obteniendo un área bajo la curva de 0.76, como

se aprecia en la figura 26.

Figura 25: Curva ROC de los clasificadores (Fuente: los autores).

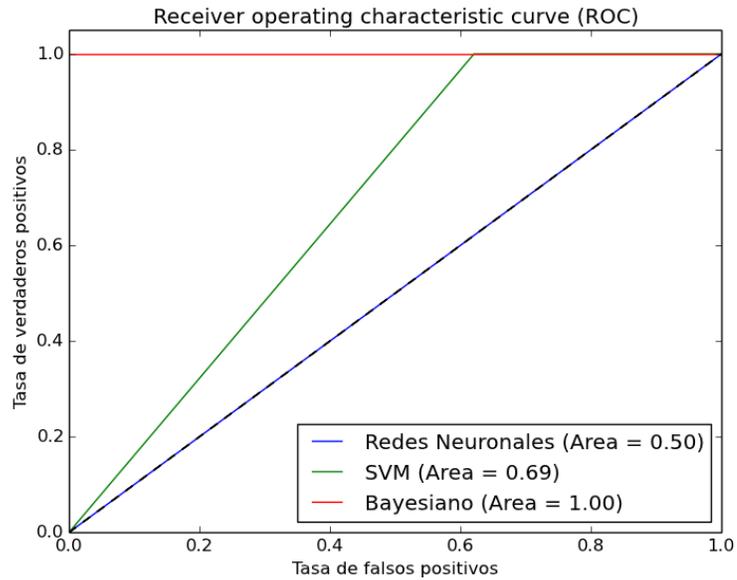
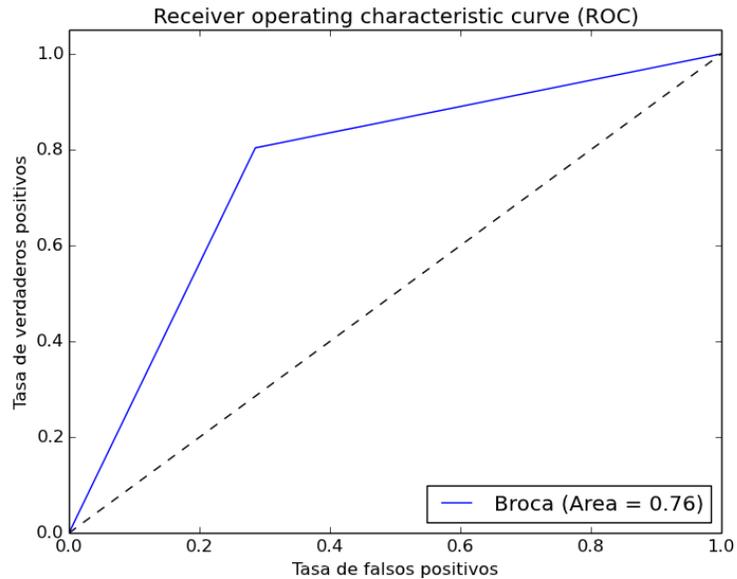


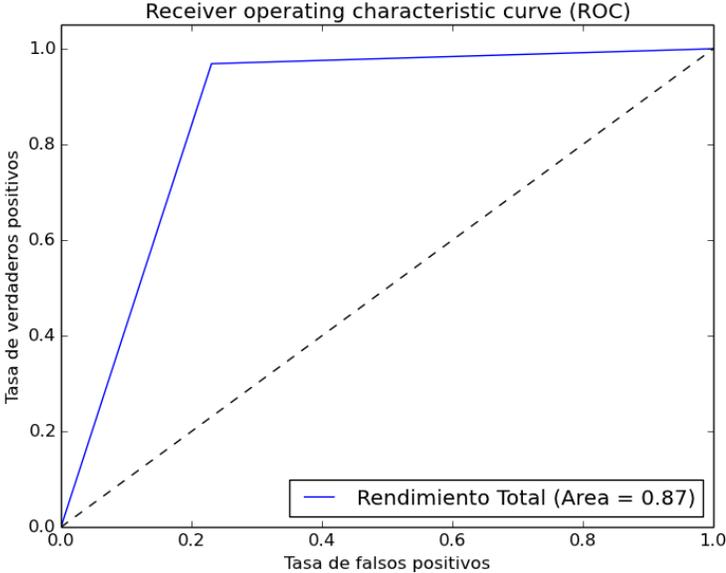
Figura 26: Curva ROC del algoritmo de detección de brocas (Fuente: los autores).



Al analizar los frutos de café mediante el método propuesto en esta investigación, se obtuvo un 87% de efectividad, medidos a través de la curva ROC de la figura 27, en

este caso incluyendo la detección de la broca y la clasificación bayesiana por color en conjunto.

Figura 27: Rendimiento del sistema propuesto (Fuente: los autores).



6. CONCLUSIONES Y RECOMENDACIONES

En este trabajo de investigación se detallaron los pasos metodológicos seguidos para el diseño de un prototipo de un sistema de visión artificial de selección de frutos de cafés buenos. El sistema se compone de tres principales componentes: el algoritmo de detección de brocas, un algoritmo de detección por color, y un dispositivo mecánico de transporte y extracción de los frutos.

Para desarrollar el algoritmo de detección de broca fue imperativo conocer como esta plaga afecta los frutos de café. La broca entra al café por su ombligo dejando un orificio negro, situación ideal para su detección mediante técnicas de procesamiento de imágenes. Para lograr detectar el orificio dejado por la broca se utilizó la segmentación por umbralización, la cual toma la imagen en escala de grises y separa el fondo de la imagen del objeto en análisis (el café), pero el resultado de la segmentación varía de acuerdo al umbral escogido. Para escoger el umbral adecuado se tomó una imagen de prueba de un fruto con broca en escala de grises y se calculó su histograma, esto con el fin de encontrar los valores de los pixeles más oscuros en la imagen; los cuales representan los orificios dejados por la broca sobre el fruto de café. Sin embargo, este algoritmo es susceptible a fallas, porque puede detectar las sombras que se encuentran en la parte baja del café como brocas. Para mejorar la detección de las brocas se implementó un algoritmo que a partir del centroide del fruto de café y de las brocas detectadas, pueda discernir entre sombras y brocas; esto a través de la obtención de la distancia euclidiana del centroide del café hacia cada una de las brocas detectadas, aquellas a una mayor distancia a la establecida del centro del fruto son tomadas como sombras, y el resto como brocas. Para conocer la efectividad de este algoritmo se tomaron 58 muestras de café, las cuales se analizaron con el algoritmo en cuestión. Con los resultados obtenidos se trazó una curva ROC, la cual obtuvo un área bajo la curva de 0.76, es decir, el algoritmo detectó brocas falsas. Esta situación se debe a la gran variedad de tamaños de los frutos de café, provocando que se detecten brocas donde no las hay.

En relación al algoritmo de detección de color se utilizó un clasificador bayesiano, el

cual fue escogido por su mejor rendimiento en comparación con los clasificadores por redes neuronales multicapa y las SVM (Support Vector Machines). Se tomaron 50 muestras de café verde y 50 de café maduro para entrenar los clasificadores, cada foto pasó por un proceso mediante el cual se extraen las características de color de cada fruto. Para caracterizar cada fruto, primero se segmentó la imagen con el fin de extraer el fondo y solo se mantenga el objeto en estudio (el fruto de café), luego se realizaron dos conversiones de espacios de colores, de RGB a HSV y de RGB a $L^*a^*b^*$; después se obtuvieron medidas de los colores a partir de las componentes H, S, a^* , y b^* . Para medir el color se calculó la media y la desviación estándar de cada una de las componentes utilizadas, conformando un vector de características de 8 posiciones el cual fue normalizado para que los valores de todas sus componentes tuvieran dentro del mismo rango de valores, y además de mejorar el proceso de entrenamiento de los clasificadores. Por último los vectores de características de cada imagen fueron utilizados como base de conocimiento de los tres clasificadores usados. Una vez entrenados los clasificadores, fueron probados con 58 fotos de cafés que no hicieron parte del entrenamiento. Con los resultados obtenidos se trazó una curva ROC para cada clasificador para efectos de comparación y seleccionar el mejor de ellos. El mejor clasificador fue el bayesiano, el cual obtuvo un rendimiento del 100%.

Por último, se usaron los algoritmos de detección de broca y color en conjunto. De igual forma que al probar los algoritmos por separados, se trazó una curva ROC para medir el rendimiento de los algoritmos en conjunto, y se obtuvo una efectividad del 87%.

Además de los algoritmos desarrollados, se diseñaron dos mecanismos, uno para poder transportar los frutos y tomar fotos de ellos, y el otro para separar los cafés buenos de los malos. El sistema de transporte consta de una banda transportadora, en la cual el café, uno por uno, es trasladado mientras los algoritmos hacen su trabajo con las fotos de este. El dispositivo extractor fue hecho de tal forma que pudiera recibir un café a la vez, y una vez recibido este y basándose en la decisión tomada por los algoritmos, el mecanismo se mueve haciendo que el café caiga en la dirección acorde a su estado, bueno o malo.

A partir de los resultados obtenidos se puede concluir que el sistema propuesto en esta investigación es capaz de discriminar entre cafés buenos para producción y los malos, sin embargo, no es efectivo totalmente. El algoritmo de detección de brocas, a pesar de las medidas tomadas, sigue tomando las sombras como brocas, provocando falsas

lecturas. Para trabajos futuros se propone hacer una mejora del sistema de adquisición de imágenes, con el objetivo de minimizar las sombras creadas por el fruto de café, y así, incrementar el rendimiento del sistema.

BIBLIOGRAFÍA

- [1] M. Habtamu, *IMAGE ANALYSIS FOR ETHIOPIAN COFFEE CLASSIFICATION*, [Accessed 2014-03-15]. [Online]. Available: <http://etd.aau.edu.et/dspace/bitstream/123456789/1335/1/Habtamu%20Minassie.pdf>
- [2] L. A. Silva and S. Lizcano, “Evaluación del estado de maduración de la piña en su variedad perolera mediante técnicas de visión artificial.” *Iteckne*, vol. 9, no. 1, 2012.
- [3] F. Guevara-Hernandez and J. Gomez-Gil, “A machine vision system for classification of wheat and barley grain kernels,” *Spanish Journal of Agricultural Research*, vol. 9, no. 3, pp. 672–680, 2011.
- [4] Z. L. S. Niño and F. A. P. Ortiz, “Caracterización de café cereza empleando técnicas de visión artificial,” *Revista Facultad Nacional de Agronomía-Medellín*, vol. 60, no. 2, pp. 4105–4127, 2007.
- [5] J. A. D. Acevedo, “Diseño de un sistema de selección de café mediante la caracterización de imágenes,” *ENGI Revista Electrónica de la Facultad de Ingeniería*, vol. 1, no. 2, 2013.
- [6] G. Daza, L. G. Sánchez, and J. F. Suárez, “Selección de características orientada a sistemas de reconocimiento de granos maduros de café.” *Scientia et Technica*, vol. 3, no. 35, 2007.
- [7] O. Alvarez and N. Beleño, “Clasificador de Textura de los Frutos de Café Según su Etapa de Maduración Utilizando Transformada de Wavelet ,” 2012.
- [8] G. Puerta, “Cómo garantizar la buena calidad de la bebida del café y evitar los defectos,” *Avances técnicos Cenicafé*, Febrero 2001. [Online]. Available: <http://www.cenicafe.org/es/publications/avt0284.pdf>

- [9] C. N. de Investigaciones de Café (Cenicafé), *Cultivemos café, Manejo Integrado del Cultivo*, [Accessed 2014-10-05]. [Online]. Available: http://www.cenicafe.org/es/index.php/cultivemos_cafe/plagas
- [10] J. Orozco and B. Triana, “Segmentación de Imágenes de Frutos de Café Mediante el Análisis de Forma de los Índices de Concavidad y Convexidad,” 2011.
- [11] R. Gonzalez and R. Woods, *Digital Image Processing*. Pearson Prentice Hall, 2008. [Online]. Available: <http://books.google.com.co/books?id=8uGOnjRGEzoC>
- [12] V. S. M. Neelamma K. Patil, “Color and texture based identification and classification of food grains using different color models and haralick features,” *International Journal on Computer Science and Engineering (IJCSE)*, vol. 3, no. 12, Dec 2011.
- [13] L. Rastislav and N. Konstantinos, *Fundamentals of Artificial Neural Networks*. CRC Press, 2006. [Online]. Available: <books.google.com.co/books?isbn=1420009788>
- [14] C. Solomon and T. Breckon, *Fundamentals of Digital Image Processing: A Practical Approach with Examples in Matlab*. Wiley, 2011. [Online]. Available: <http://books.google.com.co/books?id=NoJ15jLdy7YC>
- [15] M. Nixon, *Feature Extraction & Image Processing*, ser. Feature Extraction and Image Processing Series. Elsevier Science, 2008. [Online]. Available: <http://books.google.com.co/books?id=97QebyNxyaYC>
- [16] W. Pratt, *Digital Image Processing: PIKS Scientific Inside*. Wiley, 2007. [Online]. Available: <http://books.google.com.co/books?id=cBG9J5LVSc8C>
- [17] Mathworks, *Morphology Fundamentals: Dilation and Erosion*, [Accessed 2014-09-07]. [Online]. Available: <http://www.mathworks.com/help/images/morphology-fundamentals-dilation-and-erosion.html>
- [18] G. Dougherty, *Digital Image Processing for Medical Applications*. Cambridge University Press, 2009. [Online]. Available: http://books.google.com.co/books?id=WICeP-9c_fgC

- [19] Z. Sandoval, “Caracterización y Clasificación de Café Cereza usando Visión Artificial,” 2005.
- [20] D. Savakar, “Identification and classification of bulk fruits images using artificial neural networks,” *International Journal of Engineering and Innovative Technology (IJEIT)*, vol. 1, no. 3, March 2012.
- [21] M. Hassoun, *Fundamentals of Artificial Neural Networks*. A Bradford Book, 1995. [Online]. Available: books.google.com.co/books?isbn=026208239X
- [22] O. D. Team, *Introduction to Support Vector Machines*, [Accessed 2014-09-15]. [Online]. Available: http://docs.opencv.org/doc/tutorials/ml/introduction_to_svm/introduction_to_svm.html
- [23] OpenCV, *OPENCV (OPEN SOURCE COMPUTER VISION)*, Accessed 2014-12-02]. [Online]. Available: <http://opencv.org/>
- [24] O. D. Team, *Normal Bayes Classifier*, [Accessed 2014-11-28]. [Online]. Available: http://docs.opencv.org/modules/ml/doc/normal_bayes_classifier.html
- [25] Inalcoa, *Plásticos Poliamida 6 EXTRUSION*, [Accessed 2014-10-15]. [Online]. Available: <http://www.inalcoa.net/catalogo/plasticos-2/plasticos-poliamida-6/>
- [26] NSK, *Bearing And Linear Replacement Guide*, 2013. [Online]. Available: http://www.nskamericas.com/cps/rde/xbcr/mx_es/Bearing_and_Linear_Replacement_Guide_Web.pdf
- [27] Pololu, *Power HD High-Torque Servo 1501MG*, [Accessed 2014-11-22]. [Online]. Available: <http://www.pololu.com/product/1057>
- [28] Vishay, *CNY70 Reflective Optical Sensor with Transistor Output*, [Accessed 2014-11-22]. [Online]. Available: <http://www.vishay.com/docs/83751/cny70.pdf>
- [29] T. U. o. G. Institute for Evidence-Based Health Professions Education, *Receiver Operating Characteristic Curves*, [Accessed 2014-10-05]. [Online]. Available: <http://ebp.uga.edu/courses/Chapter%20-%20Diagnosis%20I/8%20-%20ROC%20curves.html>

- [30] D. Jayas, J. Paliwal, and N. Visen, “Review paper (ae automation and emerging technologies) Multi-layer neural networks for image analysis of agricultural products,” *Journal of Agricultural Engineering Research*, vol. 77, no. 2, pp. 119–128, 2000.
- [31] R. Duda, P. Hart, and D. Stork, *Pattern Classification*. Wiley, 2012. [Online]. Available: <http://books.google.com.co/books?id=Br33IRC3PkQC>
- [32] S. Theodoridis and K. Koutroumbas, *Pattern Recognition*. Elsevier Science, 2008. [Online]. Available: <http://books.google.com.co/books?id=QgD-3Tcj8DkC>
- [33] N. Murty and V. Devi, *Pattern Recognition: An Algorithmic Approach*, ser. Undergraduate Topics in Computer Science. Springer, 2011. [Online]. Available: <http://books.google.com.co/books?id=uBWD3HnzYFUC>
- [34] S. Agrawal, N. K. Verma, P. Tamrakar, and P. Sircar, “Content based color image classification using svm,” in *Information Technology: New Generations (ITNG), 2011 Eighth International Conference on*. IEEE, 2011, pp. 1090–1094.
- [35] L. Wang, *Support Vector Machines: Theory and Applications*, ser. Studies in Fuzziness and Soft Computing. Springer, 2005. [Online]. Available: <http://books.google.com.co/books?id=uTzMPJjVjsMC>

ANEXOS

A. CLASIFICADORES

A.1. RED NEURONAL MULTICAPA

Una red neuronal es un arreglo de de elementos de proceso interconectados llamados neuronas o nodos. Una neurona tiene varias señales de entrada $x = [x_i], i = 1, 2, \dots, N$ y un valor de salida y , el cual representa la respuesta de la neurona a dichas entradas. La relación entre las entradas y la salida de una neurona es descrita por una función de transferencia, ver ecuación 31. Donde K es una constante y ϕ es una función no lineal que toma el valor de 1 para argumentos positivos o -1 para argumentos negativos. El término w_i es llamado peso sináptico y θ es un valor umbral.

$$y = f[x] = K\phi\left(\sum_{i=1}^N w_i x_i - \theta\right) \quad (31)$$

Para entrenar una red neuronal multicapa se usa el algoritmo de Backpropagation. Este algoritmo consta de dos pasos. En el primero, las entradas x_i se presentan y se propagan hacia adelante a través de la red y de esta forma se encuentra la salida $y_k(n)$ en la iteración n para cada unidad k , como descrito en la ecuación 32.

$$y_k(n) = f_k[net_k(n)] \quad (32)$$

Donde,

$$net_k(n) = \sum_j w_{kj}(n)y_j(n) \quad (33)$$

siendo w_{kj} el peso de la conexión desde la neurona j de la capa anterior a una neurona k en cualquier capa en la presentación n , y $f_k[\]$ es la función de transferencia de la neurona k .

La función de transferencia usada es la sigmoïdal, descrita en la ecuación 34.

$$f_k[net_k(n)] = \frac{1}{(1 + e^{-[net_k(n)+\theta_k]})} \quad (34)$$

Donde θ_k es el umbral para la neurona k .

La segunda fase del entrenamiento implica ir hacia atrás a través de la red. Se genera una diferencia entre la salida actual y la deseada, esta diferencia es una señal de error $\delta_k(n)$. Con base a esta señal de error se actualiza el peso de cada conexión de la red neuronal de acuerdo con la ecuación 35.

$$w_{jk}(n+1) = w_{jk}(n) + \epsilon \delta_k(n) y_j(n) + \alpha [w_{jk}(n) - w_{jk}(n-1)] \quad (35)$$

Donde ϵ es un escalar que determina la velocidad del entrenamiento, y α determina el efecto del peso anterior sobre la convergencia de la red en el espacio de los pesos [30].

A.2. CLASIFICADOR BAYESIANO

Los clasificadores Bayesianos se basan en la teoría de decisión Bayesiana, la cual es un método estadístico fundamental para el problema de clasificación de patrones. Este enfoque está basado en cuantificar las probabilidades de varias decisiones de clasificación [31].

A.2.1. Teoría de la decisión de Bayes

Concerniente al clasificador usado en esta investigación, el de dos clases, el enfoque de la teoría a presentar estará basado en el clasificador de dos clases. Asumiendo que ω_1, ω_2 son las dos clases a las cuales los patrones a clasificar pertenecen. Las *probabilidades a priori*, $P(\omega_1), P(\omega_2)$ se asumen conocidas. Incluso si no son conocidas, pueden ser estimadas fácilmente a partir del vector de características de entrenamiento disponible. Si N es el número total de patrones de entrenamiento, y N_1, N_2 pertenecen a ω_1 y ω_2

respectivamente, entonces $P(\omega_1) \approx N_1/N$ y $P(\omega_2) \approx N_2/N$.

Las otras cantidades estadísticas asumidas como conocidas son las funciones de probabilidad de densidad (PDF por sus siglas en inglés) de clase condicional $P(\mathbf{x} | \omega_i)$, $i = 1, 2$, las cuales describen la distribución de los vectores de características de cada clase. Al igual que las probabilidades a priori, estas funciones también pueden ser calculadas a partir del conjunto de entrenamiento, en el caso de que dichas distribuciones no sean conocidas de antemano [32, 33].

Con esto en mente, ya es posible aplicar la regla de Bayes, ver ecuación 36.

$$P(\omega_i | \mathbf{x}) = \frac{P(\mathbf{x} | \omega_i)P(\omega_i)}{P(\mathbf{x})} \quad (36)$$

Donde $P(\mathbf{x})$ es la *pdf* de \mathbf{x} , expresada en la ecuación 37.

$$P(\mathbf{x}) = \sum_{i=1}^2 P(\mathbf{x} | \omega_i)P(\omega_i) \quad (37)$$

La regla de clasificación de Bayes para dos clases es expresada en la ecuación 38.

$$\begin{aligned} Si \quad P(\omega_1 | \mathbf{x}) > P(\omega_2 | \mathbf{x}), \quad \mathbf{x} \in \omega_1 \\ Si \quad P(\omega_1 | \mathbf{x}) < P(\omega_2 | \mathbf{x}), \quad \mathbf{x} \in \omega_2 \end{aligned} \quad (38)$$

A.3. MÁQUINAS DE VECTORES DE SOPORTE (SVM)

Una máquina de vectores de soporte es un sistema de aprendizaje que usa funciones lineales en un hiper-espacio, con el objetivo de separar adecuadamente dos grupos de datos a clasificar. Esto se logra a través de la búsqueda de un hiper-plano óptimo que separa las dos clases de datos que se quieren clasificar [22].

Un hiper-plano que cumpla las condiciones dadas en el párrafo anterior, es aquel en el cual todos los puntos de una clase se encuentren en el mismo lado de dicho hiper-plano.

Este se resume a hallar un valor de w y b , de tal manera que:

$$y_i = (\mathbf{w} \cdot \mathbf{x}_i + b) > 0, i = 1, \dots, N \quad (39)$$

Si un hiper-plano cumple la condición de la ecuación 39, el conjunto de datos es linealmente separable. Por lo tanto es posible re-escalar w y b de tal manera que:

$$\min_{1 < i < N} y_i (\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1, i = 1, \dots, N \quad (40)$$

Es decir, de manera que el punto más cercano al hiper-plano tiene una distancia de $\frac{1}{\|\mathbf{w}\|}$. Entonces la ecuación 39 se convierte en:

$$y_i = (\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1 \quad (41)$$

Entre el grupo de hiper-planos hallados, aquel con la mayor distancia hasta el punto más cercano, es llamado *optimal separating hyperplane* (OSH). Dado que la distancia al punto más cercano es $\frac{1}{\|\mathbf{w}\|}$, para hallar el OSH se debe minimizar $\frac{1}{2} \|\mathbf{w}\|^2$ bajo los límites establecidos por la ecuación 41. El OSH está definido por la siguiente expresión [34]:

$$\mathbf{w}^0 = \sum_{i=1}^N a_i^0 y_i \mathbf{x}_i \quad (42)$$

Los vectores de soporte son los puntos para los que $a_i > 0$, satisfaciendo la ecuación 41.

Entonces, de la ecuación 42, el hiper-plano de decisión puede ser expresado de la siguiente forma [35]:

$$f(\mathbf{x}) = \text{sgn} \left(\sum_{i=1}^N a_i^0 y_i \mathbf{x}_i \cdot \mathbf{x} + b^0 \right) \quad (43)$$