

# **Evaluación de un método de Aprendizaje Supervisado para la detección de las enfermedades, *Antracnosis* y *Phytophthora Infestans* en cultivos de fruta de Risaralda.**

Juan Pablo Aristizabal Galvis

Trabajo de Grado presentado para optar al título de Ingeniero Electrónico

Director:

M. Sc. Andrés Felipe Calvo



Universidad Tecnológica de Pereira

Facultad de Ingenierías

Ingeniería Electrónica

Pereira, Colombia

2017



## **Dedicatoria**

Inicialmente quiero agradecerle a DIOS. Por haberme permitido llegar hasta este punto y haberme dado salud para lograr mis objetivos propuestos, además de su infinita bondad y amor.

A mis padres. Por el apoyo en todo momento, por sus consejos, sus valores, por la motivación constante que me ha permitido ser una persona de bien, pero más que nada, por su amor y el resto de mi familia por apoyarme en momentos difíciles, de darme ejemplos de perseverancia y constancia que los caracterizan y que me ha infundado siempre.

## **Agradecimientos**

Quiero agradecer en primer lugar a mi director, M.Sc. Andrés Felipe Calvo por, todo el trabajo, tiempo y dedicación que me ha ofrecido. Gracias darme la oportunidad de formar parte de este proyecto, y guiarme en el proceso de aprendizaje, también por la confianza que deposito en mí. A los profesores que apoyaron el desarrollo de este trabajo, especialmente a M.Sc. Arley Bejarano Martínez y a M.Sc. Leidy Pamplona por brindar el apoyo y los consejos, que sin duda me han sido y serán de mucha ayuda. Al jardinero de Don Aníbal por brindar la ayuda en el manejo de los cultivos de tomate y de mora.

<b>Tabla de Contenido</b>	<b>Pág.</b>
1. INTRODUCCIÓN .....	8
2. PLANTEAMIENTO DEL PROBLEMA .....	9
3. OBJETIVOS .....	11
4. ESTADO DEL ARTE.....	12
5. MARCO TEORICO.....	18
5.1. Visión por Computador .....	18
5.2. Transformación a escala de grises .....	19
5.3. Binarización de imágenes .....	19
5.4. Modelos de Color .....	20
5.4.1. Modelo RGB .....	20
5.4.2. Modelo TSL .....	20
5.4.3. Modelo HSV .....	21
5.4.4. Modelo Lab .....	22
5.5. Transformada Rápida de Fourier (FFT- Fast Fourier Transform).....	23
5.6. Transformada discreta Wavelet (DWT). .....	24
5.7. Transformada discreta Wavelet en dos dimensiones.....	25
5.8. Máquina de soporte vectorial (SVM).....	25
5.9. Enfermedades de los cultivos .....	26
5.9.1. Sigatoka negra:.....	26
5.9.2. Antracnosis: .....	26
5.9.3. Phytophthora Infestans: .....	26
6. METODOLOGIA .....	27
6.1. CONSTRUCCIÓN DE LA BASE DE DATOS .....	28
6.2. SEGMENTACIÓN .....	30

6.3. EXTRACCIÓN DE CARACTERÍSTICAS .....	31
6.2.1 Descriptor RGB .....	31
6.2.2. Descriptor TSL.....	31
6.2.3. Descriptor HSV .....	31
6.2.4. Descriptor Lab .....	31
6.2.5. Descriptor FFT.....	32
6.2.6. Descriptor Wavelet .....	32
6.2.7. Método para eliminar el tallo en la planta de tomate.....	33
6.3. ENTRENAMIENTO Y VALIDACION.....	34
7. ANÁLISIS Y RESULTADOS .....	35
7.1. Cultivo de Plátano .....	36
7.2. Cultivo de Tomate .....	41
7.3. Cultivo de mora .....	48
8. CONCLUSIONES .....	54
9. REFERENCIAS.....	55

## Índice de Tablas

Tabla 1. Modelos estadísticos para obtener el vector de características FFT. ....	32
Tabla 2. Matriz de confusión del plátano método RGB-SVM con 5 bins. ....	36
Tabla 3. Matriz de confusión del plátano método RGB-SVM con 10 bins ....	37
Tabla 4. Matriz de confusión del plátano método RGB-SVM con 20 bins. ....	37
Tabla 5. Matriz de confusión del plátano método TSL-SVM con 10 bins. ....	38
Tabla 6. Matriz de confusión del plátano método TSL-SVM con 15 bins. ....	38
Tabla 7. Matriz de confusión del plátano método Lab-SVM con 15 bins. ....	39
Tabla 8. Matriz de confusión del plátano método fft-SVM. ....	40
Tabla 9. Matriz de confusión del plátano método Wavelet-SVM.....	40
Tabla 10. Matriz de confusión del tomate método RGB-SVM con 5 bins. ....	41
Tabla 11. Matriz de confusión del tomate método RGB-SVM con 10 bins. ....	41
Tabla 12. Matriz de confusión del tomate método TSL-SVM con 5 bins. ....	42
Tabla 13. Matriz de confusión del tomate método TSL-SVM con 10 bins. ....	42
Tabla 14. Matriz de confusión del tomate método fft-SVM. ....	43
Tabla 15. Matriz de confusión del tomate método Wavelet-SVM. ....	43
Tabla 16. Matriz de confusión del tomate método para detectar Phytophthora Infestans. ....	47
Tabla 17. Matriz de confusión de mora método RGB-SVM con 5 bins. ....	48
Tabla 18. Matriz de confusión de mora método RGB-SVM con 10 bins. ....	49
Tabla 19. Matriz de confusión de mora método TSL-SVM con 10 bins. ....	49
Tabla 20. Matriz de confusión de mora método Lab-SVM con 10 bins. ....	50
Tabla 21. Matriz de confusión de mora método fft-SVM.....	50
Tabla 22. Matriz de confusión de mora método Wavelet-SVM. ....	51
Tabla 23. RESULTADOS DE TEST DE PLATÁNO .....	52
Tabla 24. RESULTADOS DE TEST DE TOMATE.....	52
Tabla 25. RESULTADOS DE TEST DE MORA.....	53

## LISTA DE FIGURAS

Figura 1. Diagrama de bloques del sistema de visión por computador.....	19
Figura 2. Planta de tomate RGB a escala de grises. ....	19
Figura 3. Planta de tomate en el umbral binarizado. ....	20
Figura 4. Esquema general de implementación. ....	28
Figura 5. Base de datos anotadas de las plantas de tomate. ....	29
Figura 6. Base de datos anotadas de las hojas de plátano. ....	30
Figura 7. Base de datos anotadas de los tallos de mora. ....	30
Figura 8. Diagrama de Flujo para eliminar todo lo que no sea amarillo ni verde de la imagen. ...	33
Figura 9. Planta de tomate imagen original.....	44
Figura 10. Segmentación de la planta. ....	44
Figura 11. Segmentación de la enfermedad. ....	45
Figura 12. Eliminación de las zonas oscuras del tallo.....	45
Figura 13. Eliminación de las áreas restantes de verde. ....	46
Figura 14. Operación morfológica para quitar el resto zonas del tallo. ....	46
Figura 15. Porcentaje del área afectada de la enfermedad. ....	47

## 1. INTRODUCCIÓN

Las enfermedades de las plantas son unos de los factores que más afectan a los cultivos alimentarios, lo que causa pérdidas significativas a los agricultores y amenaza la seguridad alimentaria.

La propagación enfermedades de las plantas ha aumentado drásticamente en los últimos años. La globalización, el comercio y el cambio climático, así como la menor capacidad de recuperación de los sistemas de producción debido a la intensificación de la agricultura durante años contribuyen a ello [1].

En algunos casos es relativamente fácil hacer el diagnóstico de la enfermedad, debido a que los síntomas de la misma son tan característicos y exclusivos, que no hay posibilidad de error, por ejemplo: El hongo *Fusarium* presente en buena parte de las zonas productoras, en el cual se observa Amarillamiento y marchitez de hojas, ramas, tallos o pecíolos [2, 3]. El hongo *Cladosporium*, que inicia su ataque en hojas bajas, observándose manchas cloróticas (amarillas), las manchas se van expandiendo hasta producir quemazón de la hoja [4].

Sin embargo, muchas de las enfermedades que se encuentran en las plantas requieren de un diagnóstico preciso del patógeno o patógenos que los causa, bien sea porque los síntomas que se producen en la planta sean variables o imprecisos que pueden dar lugar a confusión de la muestra o por el contrario diferentes patógenos causen un síntoma similar en la misma planta [1]. Por lo cual se plantea un estudio comparativo de técnicas y métodos para detectar las enfermedades de *Antracnosis* y *Phytophthora infestans* en los cultivos de tomate, plátano y mora.

## 2. PLANTEAMIENTO DEL PROBLEMA

En Colombia el área sembrada de frutas se ha expandido durante estas últimas décadas, lo que ha originado una alternativa de ingresos para los cafeteros del departamento de Risaralda, en especial los diferentes municipios como Apía, Mistrató, Pereira, entre otros. Por medio de convenios con universidades, municipios, agricultores y el comité de cafeteros se impulsa la siembra de frutas de la región. Así mismo, Risaralda ha buscado posicionarse en el campo tecnológico para adaptarse a los cambios y condiciones que exige el mercado agrícola y a su vez establecerlo como fuente económica del sector; pero han sucedido graves pérdidas en la producción de los cultivos y en la seguridad alimentaria en Colombia como también en otros países, causado por las epidemias de enfermedades en las plantas, reduciendo significativamente la calidad y cantidad de los productos agrícolas [5].

Por esta razón, se han desarrollado diferentes investigaciones sobre el reconocimiento de enfermedades en plantas, donde se han planteado metodologías basadas en visión por computador y aprendizaje de máquina: Las técnicas de K-Means, red neuronal pre-entrenada y otra técnica son los histogramas de color RGB, TSL, Lab donde se calcula una distancia estadística para obtener una función de separación entre la enfermedad; los métodos de orientation code matching (OCM), máquinas de soporte vectorial (SVMs) para detectar y reconocer las enfermedades en sus primeras etapas.

Sin embargo, las enfermedades de las plantas se proliferan debido a que no están en condiciones ambientales aptas, donde dependen de variables como la humedad relativa, temperatura ambiente, incidencia de luz y cantidad de lluvia; la cual aparecen las enfermedades más comunes en los cultivos de fruta en Colombia como: la *Antracnosis*, causada por el hongo Fitopatógeno *Colletotrichum*, que puede afectar diversos tejidos de las plantas, como tallos, hojas, flores y frutos. El *Phytophthora infestans*, el cual es un parásito presente en plantas y produce la enfermedad del Tizón tardío.

Además, el problema radica en los métodos tradicionales para identificar y diagnosticar las enfermedades en las plantas, se basa en la observación a simple vista del profesional y técnico

capacitados, pero este proceso es lento y tedioso por lo tanto está ligado a que se genere varios errores humanos y que no siempre se detecte la enfermedad en su etapa más temprana de desarrollo.

Por tal motivo, se propone implementar una metodología basada en visión por computador que pueda detectar en su etapa más temprana las enfermedades en los cultivos de fruta utilizando un método de aprendizaje supervisado; empleando una base de datos de los cultivos de las frutas del departamento de Risaralda.

Así las diferentes entidades adscritas del ministerio de agricultura podrían implementar esta metodología para la prevención de las enfermedades *Antracnosis* y *Phytophthora Infestans*, para el cuidado en los cultivos de fruta en el momento adecuado y además, da la solución práctica al problema de la detección temprana de enfermedades en los cultivos sin necesidad de que el supervisor este constantemente monitoreando.

### 3. OBJETIVOS

#### *A. Objetivo general*

Evaluar una metodología de aprendizaje supervisado para la detección de enfermedades, *Antracnosis* y *Phytophthora Infestans* en cultivos de fruta.

#### *B. Objetivos específicos*

- Seleccionar una población significativamente estadística de frutos sembrados en la región que presenten las enfermedades de *Antracnosis* y *Phytophthora Infestans*.
- Escoger una base de datos que contengan las imágenes de las enfermedades de *Antracnosis* y *Phytophthora Infestans*.
- Implementar la metodología para la detección temprana de las enfermedades utilizando Aprendizaje Supervisado.
- Validar estadísticamente el funcionamiento del prototipo experimental.

#### 4. ESTADO DEL ARTE

Muchas de las investigaciones que se han realizado en los campos de visión por computador, aprendizaje de máquina, procesamiento digital de imágenes y de señales y reconocimiento de patrones, se han utilizado para el reconocimiento de rostro, de huellas dactilares, de caracteres, enfermedades, etc. También en la industria se encuentra que la visión por computador y el Aprendizaje de Máquina han aportado grandes avances para el control de calidad.

En 1993, el trabajo realizado por los autores TV Price, R Gross, Wey J Ho y CF Osborne, compararon los métodos de procesamiento de imágenes para cuantificar la severidad del roya en la hoja del café. Probaron dos técnicas diferentes para la captura de los datos, la primera técnica consistía en capturar las imágenes por una cámara de carga acoplada (CCD) en blanco y negro, en la segunda, se capturaron las imágenes con una cámara CCD de color. En ambas técnicas, la segmentación se realizó estableciendo un umbral. donde se concluyó que los sistemas que fueron tratados con el procesamiento digital de imágenes tuvieron un mejor desempeño que los análisis visuales, principalmente en casos con síntomas más graves. También analizaron que la imagen de color tenía un mayor potencial en la discriminación entre el follaje que estaba afectado y no afectado [5].

Luego en [6] en el año de 1994 se trató de observar el estado de las plantas, este trabajo consistía en la detección y el diagnóstico de los desórdenes en el crecimiento de las plantas cultivadas en un ambiente controlado. Capturando las imágenes por medio de una cámara análoga, posteriormente se digitalizaban las imágenes, donde se identificaban las deficiencias de Hierro, Zinc y Nitrógeno de las hojas de lechuga. Además, se realizó una segmentación entre la hoja y el fondo. fondo, extrayendo las características de color y tamaño para pasarlas del espacio de color RGB a HSI, posteriormente estos parámetros se entrenaron en una Red Neuronal para determinar en qué condición estaba la planta.

En 1997, los autores Tucker y Chakraborty, propusieron un método que tuvo como objetivo identificar y caracterizar, el tipo de lesión y el porcentaje del área enferma afectada en las hojas de girasol y avena. Evaluaron la utilidad y adaptabilidad del software de las dos enfermedades, la Alternaria de Tizón de Girasol y la Roya de la hoja de Avena. En la segmentación de las imágenes

del umbral varía de acuerdo con la enfermedad que se está analizando, ya sea tizón o roya. Luego clasifican la enfermedad dependiendo de las características del área afectada por la enfermedad, si es tipo *a* es Tizón o *b* si es la Roya. En esta investigación se tuvo buenos resultados, pero se les presentaron algunos problemas en el clasificador, ya que no se identificaron de forma correcta las lesiones del tizón por el software de imágenes, dando lugar a una sobreestimación del número de lesiones, debido a que la iluminación no era la apropiada cuando estaban capturando las fotos [7]. En 1998, la Universidad Cape Town del departamento de Microbiología, los autores Artin y Rybicki, propusieron técnicas de análisis de imágenes para cuantificar los síntomas causados por el virus de la raya de maíz (MSV). Compararon los resultados obtenidos mediante la evaluación visual, utilizando un paquete de software comercial y empleando un sistema personalizado desarrollado por ellos mismos. Luego llegaron a la conclusión que el software comercial y los personalizados tenían aproximadamente el mismo rendimiento, y que ambos métodos alcanzaron una precisión mejor que el enfoque visual con porcentajes de acierto del 2,3% y 4,4 respectivamente [8].

Otra función principal de la visión por computador y el aprendizaje de máquina enfocada a la industria agrónoma, es la de automatizar los cultivos, monitoreando la siembra y la recolección de los frutos sin estar presente el agricultor. Por lo tanto, en el año 2000, los autores Prasher y Landry trabajaron en la aplicación de redes neuronales artificiales en el reconocimiento de imágenes y clasificación de cultivos y malezas; Aunque sólo con los índices de color de la imagen no eran suficientes para entrenar la red neuronal, se utilizó también la forma de las plantas. Para la prueba capturaron 40 imágenes de maíz y 40 de las malas hierbas; el entrenamiento de la red neuronal se realizó con 20 imágenes, con un resultado del clasificador del 100% en las plantas de maíz y un 80% en la detección de las malezas [9].

Así mismo, en el año 2003 el autor Guillermo Sampallo también trabajó en el área de la detección de hojas; el cual desarrolló un sistema experto, basado en 10 reglas, para reconocer 8 tipos de hojas de plantas, de la cual extrajo 10 ejemplares de cada hoja, la adquisición se realizó a través de un escáner de página en escala de grises, para el reconocimiento de las hojas se seleccionaron las siguientes características: Área, perímetro, circularidad, firma, densidad superficial e histograma, luego fueron evaluadas, con estos valores y su rango de variación, posteriormente se construyó una base de datos.

En este caso se verificó que el reconocimiento no produce resultados falsos dentro del conjunto de los objetos seleccionados [10].

En 2005, los autores Pydipati, T. F. Burks, W. S. Lee propusieron y evaluaron un método de análisis de textura denominado método de co-ocurrencia de color (CCM) para clasificar la hojas enfermas y sanas de los cítricos. Primero recogieron 39 características de textura y crearon cuatro subconjuntos diferentes de esas características utilizando dos enfoques para el clasificador. El primer enfoque fue el clasificador Mahalanobis que utiliza el principio del vecino más cercano. El segundo enfoque fue la red neuronal de funciones de base radiales (RBF) entrenados con el algoritmo de backpropagation. El clasificador estadístico y el análisis textural de CCM logró precisiones de clasificación de más del 95% para todas las clases cuando utilizaron las características de tono y textura de saturación. Del mismo modo, la red neuronal tuvo una precisión de más del 90% para todas las clases cuando utilizaron las características de matiz y saturación. El clasificador estadístico de Mahalanobis y el clasificador backpropagation de redes neuronales se desempeñaron igualmente bien al utilizar diez tonalidades y características de textura [11].

En ese mismo año, en la Universidad Nacional de Colombia se realizó un proyecto que caracteriza y clasifica el café usando visión por computador. El software clasifica los frutos de café en once categorías dependiendo de su estado de madurez, y están descritos por forma, tamaño, color y textura de un fruto de café, en total extrajeron 208 características. Luego, se realizó una reducción de características de 208 a 9, esto se pudo realizar debido a los dos métodos de selección de características, uno es univariado y otro multivariado. El conjunto final de características se evaluó con tres técnicas de clasificación: Bayesiano, redes neuronales y clustering difuso, usando el clasificador Bayesiano se obtuvo un error de clasificación del 5,43 %, con redes neuronales el error de clasificación fue de 7,46 % y por último obtuvieron un error de 19,46 % usando clustering difuso [12].

En 2007, en Taiwán se utilizó técnicas de procesamiento digital de imágenes y redes neuronales para la detección y clasificación de tres tipos diferentes de enfermedades que afectan las plántulas de orquídeas *Phalaenopsis*. Las áreas afectadas se segmentaron mediante una transformada exponencial con un parámetro ajustable, la metodología está compuesta por cuatro pasos, el

primero es la extracción de los vasos de la planta con la utilización de un clasificador de Bayesiano, luego se ecualizó la imagen mediante la transformada exponencial, después estimó aproximadamente la ubicación del área enferma, y por último se ecualizó la subimagen centrada en esa localización rugosa. A continuación, se extraen una serie de características de color y textura del área de la lesión por medio de la matriz de co-ocurrencia de nivel de gris (GLCM). Finalmente, esas características se someten a una red neuronal artificial con una capa oculta, que realiza la clasificación final. La metodología efectivamente detectó y clasificó estas lesiones de plántulas de *Phalaenopsis* con una precisión del 89,6% y la capacidad de detección del sistema, sin clasificar el tipo de enfermedad, es del 97,2% [13].

En 2008, en la Universidad de Tecnología de Suranaree, proponen un trabajo para identificar y clasificar las enfermedades que afectan a las hojas de la planta de uva. Se utilizó varias representaciones de color como la HSI, Lab, UVL y YCbCr. Para la separación entre las hojas y el fondo se realizó por medio de un método de la red neural de MLP, que se une con la biblioteca de color construida a priori mediante un mapa de auto-organizado sin supervisión (SOM) para reconocer los colores de la hoja de uva. El SOM modificado con algoritmos genéticos para la optimización determina el número de agrupación que se adoptarán en cada caso. Las áreas enfermas y saludables son separadas por una Máquina de Soporte Vectorial (SVM). La imagen segmentada es filtrada por medio de una wavelet de Gabor que permite al sistema analizar las características de color de la enfermedad foliar más eficientemente, la imagen segmentada se somete a una SVM multiclase, la cual realiza tres clasificaciones: enfermedad de la costra, enfermedad de la roya y ninguna enfermedad. [14].

En 2009, El método que propuso la Universidad de Warmia y Mazury tiene como objetivo analizar el color de las hojas de 3 especies de leguminosas (hojas de haba, guisante y altramuces amarillos), entre cuatro tipos de deficiencias de minerales como el nitrógeno, fósforo, potasio y magnesio. Para el análisis de color, las imágenes se convierten a los espacios de color HSI y Lab. Las 3 especies de plantas presentaron una respuesta más fuerte al nitrógeno y magnesio. La deficiencia de potasio tuvo el efecto más significativo sobre los cambios en el color de las hojas de frijol, mientras que el lupino amarillo respondió en mayor grado a la deficiencia de fósforo. Estas

diferencias se cuantifican mediante distancias euclidianas calculadas en ambos espacios de color [15].

Además, detectar enfermedades en las plantas también hay estudios para identificar qué tipo de fruto es, como el trabajo realizado por los autores Juan Anthony Báez Páez y Henderson Bermúdez Rincón en el 2010, donde su principal objetivo fue el detectar las naranjas maduras en el árbol por medio de técnicas de visión artificial. La metodología que se utilizó fue la siguiente: Se creó una base de datos con 240 imágenes adquiridas en diferentes condiciones de luz, luego convirtieron las imágenes a un espacio de color conveniente (HSV, HLS, YCrCb...), después se segmentaron mediante histogramas aplicando el método de Otsu y para extraer las regiones de interés utilizando el análisis de Blobs. el algoritmo propuesto por los autores es efectivo bajo condiciones iluminación diferentes para reconocer las naranjas en el árbol [16].

En [17] se propone un método para detectar las deficiencias de nitrógeno y potasio en plantas de tomate en el año 2011. El algoritmo comienza con extraer las características de color y textura de las hojas con técnicas y métodos tales como el porcentaje de histograma de intensidad y el porcentaje de histograma diferencial, transformada de Fourier y la descomposición de paquetes Wavelet. La selección y combinación de las características se llevó a cabo mediante un algoritmo genético para obtener la mejor información para diagnosticar la enfermedad. Los experimentos mostraron que la exactitud de este sistema de diagnóstico es superior al 82,5% y que puede diagnosticar la enfermedad de 6 a 10 días antes de que los expertos pudieran determinarla.

En 2013, Bannari Instituto de Tecnología de Amman de la India, se propuso un nuevo algoritmo para la detección de Bacterial Leaf Scorch (BLS) en las áreas infectadas de la planta, por lo tanto, al hacer análisis temprano con lleva a la eliminación de la propagación de la enfermedad. El esquema que utilizaron fue la segmentación de las hojas de la planta por agrupamiento utilizando el clasificador por K-means y el histograma en el espacio de color RGB para obtener los diferentes centros de los conglomerados y así segmentar la región de interés (ROI) [18].

En el 2014 en [19], proponen un modelo para identificar la severidad de la enfermedad del Anillo del punto en la caña de azúcar utilizando técnicas de procesamiento de imágenes. Para realizar la

segmentación se utiliza el canal a del espacio de color Lab. Las manchas de enfermedades se extraen con la máxima desviación estándar del punto segmentado que se utiliza para la detección del tipo de enfermedad y con el descriptor GLCM, con esta información se entrena el modelo SVM que permite clasificar el fenómeno. Este modelo propuesto es capaz de determinar los tipos de enfermedades por manchas con una precisión del 80% y un promedio de estimación de la severidad del error de 5,73.

En 2015, los autores Yogesh Dandawate, Radha Kokare de India, realizaron un estudio que se enfoca en aportar insumos para el Sistema de Apoyo a la Decisión (DSS), que se desarrolla para proporcionar asesoramiento a los agricultores, donde se clasifican las imágenes de las hojas de soja como sanas y enfermas utilizando la SVM, se compone de cuatro pasos principales: adquirir las imágenes, extraer la hoja del fondo, análisis estadístico y por último utilizar un clasificador. Después de adquirir las imágenes, se transforman al espacio de color RGB a HSV para extraer la ROI con el multi-thresholding de la imagen original y la rotación como lo son SIFT y SURF. El resultado experimental puede clasificar las hojas con una exactitud media del 93.79 % [20].

En 2016, en la Universidad Autónoma del Caribe, se desarrolló dos algoritmos para la identificación del café idóneo para producción, uno de acuerdo al estado de maduración y otro para detectar la plaga de la broca. Primero se extraen características de colores, específicamente de los modelos de color RGB, HSI y Lab. Para el proceso de reconocimiento e interpretación, se utiliza una red neuronal artificial (RNA) que clasifica los frutos en maduros o verdes. Por otro lado, en el algoritmo de detección de broca se segmentó la imagen estableciendo un umbral, para poder detectar el orificio dejado por esta plaga sobre el fruto de café. El clasificador por redes neuronales propuesto tuvo una eficiencia de 97% al detectar los estados de madurez de los frutos de café [21].

Como se pudo observar existen diferentes métodos y técnicas para reconocer dichos patrones en las imágenes que ayudan a la problemática planteada, obteniendo buenos resultados y ofreciendo un sinnúmero de aplicaciones para la automatización de los cultivos.

## 5. MARCO TEORICO

En la actualidad los sistemas de reconocimiento y detección de patrones, se pueden clasificar en dos tipos: Los que hacen uso de sensores como los infrarrojos, de proximidad, térmicos, entre otros y el otro tipo son los que se basan en cámaras ópticas, utilizando diferentes técnicas de visión por computador, con el fin de que un sistema de procesamiento pueda entender el mundo exterior, distinguiendo las propiedades y la forma del mundo tridimensional, a partir de una o varias imágenes en segunda dimensión [22].

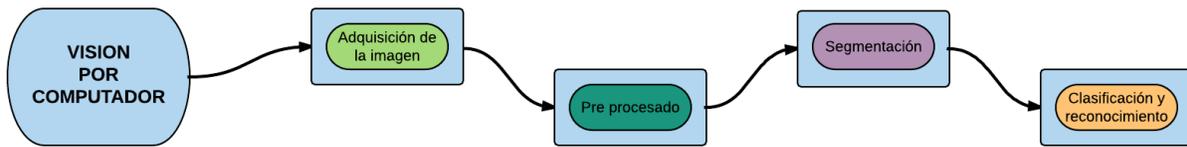
Por tal motivo es necesario entender y utilizar métodos de la visión por computador para el reconocimiento de las enfermedades en las hojas de las plantas, con el fin de diferenciar el color y la textura que produce la enfermedad de la hoja. Estas características se pueden aprovechar para detectar estos patrones, por lo que la literatura propone usar técnicas de análisis de señales como la transformada rápida de Fourier, y la transformada wavelet, entre otras.

### *5.1. Visión por Computador*

Campo de la ingeniería enfocado a la interpretación del mundo físico por medio de una computadora a partir de imágenes extraídas. Mediante técnicas y métodos adecuados, se analiza el tipo de información para ofrecer soluciones a problemas que estén presentes en la escena. Se compone de un conjunto de procesos destinados a realizar el procesamiento de las imágenes digitales [22].

- El primer proceso, consiste en la adquisición de las imágenes digitales a partir de un tipo de sensor óptico.
- El segundo proceso, consiste en la etapa de pre-procesado de la imagen, que es donde, mediante filtros y transformaciones geométricas, se organiza la imagen para eliminar áreas que no sean de interés.
- El siguiente proceso es la segmentación de la misma, que consiste en resaltar los elementos de interés y aislar el fondo de esa escena para entenderla mejor.
- Por último, en este proceso es el de reconocimiento o clasificación. Donde se pretende distinguir los objetos segmentados, debido al análisis previo con las características principales extraídas del objeto.

En la figura 1, se puede observar el funcionamiento de un sistema de visión por computador



**Figura 1. Diagrama de bloques del sistema de visión por computador.**

### **5.2. Transformación a escala de grises**

Para facilitar el análisis de la imagen, generalmente no se necesita el espacio de color RGB, por lo cual reduce la cantidad de información en la imagen. La mayoría de la información se mantiene, como bordes, regiones y así sucesivamente [23].

Para transformar la imagen a escala de grises se utiliza la siguiente ecuación:

$$I_g(x, y) = 0.2989 * R(x, y) + 0.5870 * G(x, y) + 0.1140 * B(x, y) \quad (1)$$

Donde, R, G y B son las canales de la imagen en el espacio de color RGB.



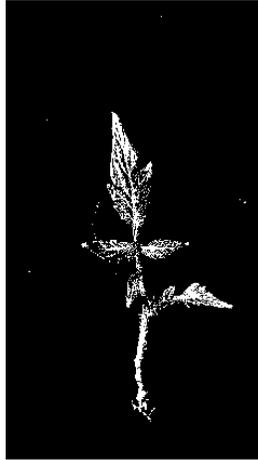
**Figura 2. Planta de tomate RGB a escala de grises.**

### **5.3. Binarización de imágenes**

Es una técnica que es una variante de la umbralización y se aplica como una forma de “distinguir” un objeto de interés del resto de la imagen. Esto con el fin de reducir la escala de grises a dos únicos valores, es decir, cuando el valor es igual a cero, los pixeles son de color negro y por otra parte,

cuando el valor es igual a uno, los píxeles son de color blanco, por lo tanto, la matriz queda constituida de unos y ceros [24].

$$b(f, c) = \begin{cases} 0 & \text{si } I(f, c) < T \\ 1 & \text{si } I(f, c) \geq T \end{cases} \quad (2)$$



**Figura 3. Planta de tomate en el umbral binarizado.**

#### **5.4. Modelos de Color**

Los modelos de color representan un conjunto de colores primarios, y a partir de estos se generan otros colores hasta cubrir todo el espectro visible múltiples con componentes denominados espacios de color. Estos modelos son muy utilizados para discriminar de forma precisa y eficiente los píxeles, o zonas de una imagen, que corresponden al suelo o la vegetación. [22, 25].

##### **5.4.1. Modelo RGB**

El modelo de color RGB se basa en los tres colores primarios de una imagen, que son el Verde (G), el Rojo (R) y el Azul (B) con lo cual la combinación de estos da como resultado el color blanco y si hay ausencia de estos tres colores el color será negro, por tal motivo es el espacio de color más común, utilizado para la representación de imágenes digitales [22].

##### **5.4.2. Modelo TSL**

Es un espacio de color perceptual que define el tono de color (T) como el grado en que se puede describir un estímulo o diferentes estímulos que se compraren con la tonalidad de blanco, la

saturación (S) es el colorido de un estímulo que tiene relación a su propio brillo, y la ligereza (L) es la iluminación de un estímulo relacionado al blanco). Este modelo se ha utilizado para la detección de rostros y piel humana [26], ya que es un modelo robusto a cambios drásticos de iluminación y resulta muy eficiente a la segmentación.

Función de transformación:

$$T = \begin{cases} \frac{1}{2\pi} \arctan \frac{r'}{g'} + \frac{1}{4}, & \text{if } g' > 0 \\ \frac{1}{2\pi} \arctan \frac{r'}{g'} + \frac{3}{4}, & \text{if } g' < 0 \\ 0, & \text{if } g' = 0 \end{cases} \quad (3)$$

$$S = \sqrt{\frac{9}{5}(r'^2 + g'^2)} \quad (4)$$

$$L = 0.299R + 0.587G + 0.114B \quad (5)$$

Donde

$$r' = r - \frac{1}{3} \quad (6)$$

$$g' = g - \frac{1}{3} \quad (7)$$

$$r = \frac{r}{(R+G+B)} \quad (8)$$

$$g = \frac{g}{(R+G+B)} \quad (9)$$

Generalmente la información que contiene el canal L que es el de iluminación no se tiene en cuenta para el procesamiento de la imagen, dejando a los canales T y S que corresponden al tono y saturación.

### 5.4.3. Modelo HSV

El modelo de color HSV es una transformación no lineal del modelo RGB en coordenadas cilíndricas de manera que cada color viene definido por las siguientes dimensiones [27]:

Tono: Ángulo que representa el matiz, normalmente definido entre 0° y 360°.

Saturación: El nivel esta dado entre 0 y 1, 0 representa sin saturación alguna (blanco), hasta 1 que sería el matiz en toda su intensidad.

Brillo: Nivel del brillo entre 0 y 1. 0 es negro; 1 es blanco. Al igual que la saturación puede darse en porcentaje.

Para convertir una imagen representada con el espacio de color RGB al espacio de color HSV, se utilizan las siguientes funciones:

$$H = \begin{cases} 0^{\circ} & \Delta = 0 \\ 60^{\circ} \times \left( \frac{G' - B'}{\Delta} \text{mod} 6 \right) & , C_{max} = R' \\ 60^{\circ} \times \left( \frac{B' - R'}{\Delta} + 2 \right) & , C_{max} = G' \\ 60^{\circ} \times \left( \frac{G' - B'}{\Delta} + 4 \right) & , C_{max} = B' \end{cases} \quad (10)$$

$$S = \begin{cases} 0 & , C_{max} = 0 \\ \frac{\Delta}{C_{max}} & , C_{max} \neq 0 \end{cases} \quad (11)$$

$$V = C_{max} \quad (12)$$

Donde:

$$R' = R/255, G' = G/255, B' = B/255 \quad (13)$$

$$C_{max} = \max(R', G', B') \quad (14)$$

$$\Delta = C_{max} - C_{min} \quad (15)$$

#### 5.4.4. Modelo Lab

Es un modelo cromático que describe todos los colores que percibe el ojo humano, fue modelado en base de la teoría que dos colores no pueden ser rojo y verde al mismo tiempo o amarillo y azul al mismo tiempo [28]. El espacio L indica la luminosidad, en cambio a y b son las coordenadas cromáticas. Como se muestra a continuación:

L= luminosidad.

a = coordenadas rojo/verde (+a indica rojo, -a indica verde).

b = coordenadas amarillo/azul (+b indica amarillo, -b indica azul).

Para representar una imagen en el espacio de color RGB al espacio Lab se utiliza las siguientes ecuaciones:

$$L = 100 \sqrt{\frac{Y}{Y_n}} \quad (16)$$

$$a = K_a \left( \frac{\frac{X}{X_n} \frac{Y}{Y_n}}{\sqrt{\frac{Y}{Y_n}}} \right) \quad (17)$$

$$b = K_b \left( \frac{\frac{Y}{Y_n} \frac{Z}{Z_n}}{\sqrt{\frac{Y}{Y_n}}} \right) \quad (18)$$

Donde

X, Y y Z son los valores triestímulos CIE, X<sub>n</sub>, Y<sub>n</sub> y Z<sub>n</sub> son los valores triestímulos para la iluminancia, Y<sub>n</sub> es igual a 100.00, X<sub>n</sub> y Z<sub>n</sub> dependen de ciertos parámetros de la imagen, K<sub>a</sub> y K<sub>b</sub> son los coeficientes de cromaticidad para la iluminancia y dependen de ciertos parámetros de la imagen.

### 5.5. Transformada Rápida de Fourier (FFT- Fast Fourier Transform)

La transformada rápida de Fourier es un eficiente algoritmo que permite calcular de manera rápida la transformada discreta de Fourier (DFT) y así conocer la frecuencia de las diferentes componentes de una señal discreta [29]. Esta herramienta elimina una gran parte de los cálculos repetitivos de la DFT, por lo tanto, se pierde información de tipo temporal, pero determina que frecuencias tiene la señal.

Teniendo en cuenta que las enfermedades *Antracnosis* y *Phytophthora Infestans* en su etapa temprana aparece los síntomas en las hojas o tallos, este patrón ofrece unas variaciones que pueden caracterizarse según la componente de frecuencia que aparezca la enfermedad en la planta. Esta transformada contiene solo un conjunto de muestras lo suficientemente grande para describir completamente la imagen en el dominio espacial. Por lo tanto, este número de frecuencias corresponde al número de píxeles de la imagen.

Para realizar el cálculo de la FFT se debe aplicar ecuación:

$$F(u, v) = \frac{1}{M*N} \sum_{c=1}^N \sum_{f=1}^M I(c, f) * e^{-2\pi i * \left( \left( \frac{u*c}{N} \right) + \left( \frac{v*f}{M} \right) \right)} \quad (19)$$

Dónde:

M es el número de filas

N es el número de columnas

I(c,f) es la imagen en escala de grises

u es la coordenada espacial de fila en el espacio de Fourier

v es la coordenada espacial de columna en el espacio de Fourier

Al aplicar el cálculo de la FFT (2) da como resultados variables complejas. Pero para el análisis de la imagen se debe conocer la magnitud de estos datos como se observa en la ecuación (20).

$$|F(u, v)| = \sqrt{[Re(u, v)]^2 + [Im(u, v)]^2} \quad (20)$$

### 5.6. Transformada discreta Wavelet (DWT).

La transformada Wavelet es una herramienta matemática que permite la caracterización de señales obteniendo una representación en función de cambios repentinos en sus componentes de tiempo-frecuencia, se descompone una señal de este tipo en un número igual o menor del coeficiente de wavelet. El espectro de wavelet proporciona detalles de la imagen en diferentes escalas, que se pueden extraer los detalles contenidos en varias partes de la imagen desde diferentes niveles de resolución. Esto logra una mayor precisión de baja frecuencias en los segmentos donde los intervalos son de un tiempo mayor y la información más alta en los intervalos que son pequeños. Esta transformada permite seleccionar los detalles más relevantes para la detección de la enfermedad en las hojas, y las ventanas que toma van creciendo exponencialmente [30].

Para representar DWT en función del dominio del tiempo en una serie de sumatorias, se debe cambiar la forma del mapeo continuo, a un análisis de un conjunto de valores, es decir discretizar la señal, como se observa en la ecuación (21).

$$f(t) = \sum_k \sum_j C_{j,k} \Phi(t) + \sum_k \sum_j d_{j,k} \Psi(t) \quad (21)$$

Ecuación. Transformada discreta de wavelet.

Donde  $\Phi(t)$  son las funciones de escala que se encargan de realizar la aproximación y  $\Psi(t)$  son las funciones de wavelet las cuales realizan los detalles de la función.

### 5.7. Transformada discreta Wavelet en dos dimensiones.

La DWT permite la representación en función de cambios repentinos en sus componentes de tiempo-frecuencia, pero para el análisis de las imágenes digitales se requiere de la DWT en dos dimensiones.

Su función bidimensional de tamaño  $M \times N$ , se representa por las siguientes ecuaciones [30]:

$$DWT_h(j_0, m, n) = \frac{1}{\sqrt{MN}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} F(x, y) * h_{j_0, m, n}(x, y) \quad (22)$$

$$DWT_\psi^i(j, m, n) = \frac{1}{\sqrt{MN}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} F(x, y) * \psi_{j, m, n}^i(x, y) \quad (23)$$

Como en el DWT,  $j_0$  es la escala de inicio arbitraria y los coeficientes  $DWT_h(j_0, m, n)$  definen la aproximación de la función en la escala  $j_0$ . Los coeficientes  $DWT_\psi^i(j, m, n)$  suman los detalles horizontales, verticales y diagonales para la escala de  $j \geq j_0$ .

Normalmente  $j_0$  es cero y  $N=M=2^J$  de tal manera de que  $j = 0, 1, 2, 3, \dots, J-1$  y  $m, n = 0, 1, 2, 3, \dots, 2^{J-1}$ .

Su funcionamiento es el siguiente: Separa las líneas de las columnas y realiza el mismo proceso de la DWT de una dimensión, teniendo en cuenta a las señales unidimensionales en cada fila y columna.

### 5.8. Máquina de soporte vectorial (SVM)

Las máquinas de soporte vectorial han mostrado un gran desempeño y están relacionadas con problemas de clasificación y regresión. La SVM construye un hiperplano o un conjunto de hiperplanos en un espacio de alta dimensionalidad, donde los vectores de soporte lo que hacen es encontrar un hiperplano optimo que separe la mayor cantidad de datos posibles, en el caso en que los datos sean no lineales, se utiliza la función de kernel que es el producto punto con funciones en el espacio de características [31].

La SVM se considera un clasificador binario, el cual calcula una etiqueta  $y \in \{-1, 1\}$ ; utilizando el siguiente modelo:

$$y = w^T \phi(x) + b \quad (11) \quad (24)$$

Donde,  $\phi(x) : \mathbb{R} \rightarrow \mathbb{H}$  es una transformación del conjunto de entrada a un conjunto con igual o mayor dimensión, lo que se supone que facilita la separación de las clases. El vector  $w$  define el hiperplano de separación en espacio  $\phi(x)$ .  $b$  representa el sesgo con respecto al origen de coordenadas

Además de las técnicas descritas anteriormente, se debe conocer las enfermedades que se van a detectar en el proyecto.

## **5.9. Enfermedades de los cultivos**

### **5.9.1. Sigatoka negra:**

Es causada por el hongo *Mycosphaerella fijiensis*, esta enfermedad foliar se desarrolla principalmente en los cultivos de plátano y banano a nivel mundial. afectando el área foliar de la planta y, por lo tanto, baja la calidad del producto. Adicional a esto, las infecciones por esta enfermedad causan la madurez prematura del fruto [33].

### **5.9.2. Antracnosis:**

Es una de las enfermedades más frecuentes en los cultivos de frutales ubicados tanto en los climas fríos como en los cálidos. Esta enfermedad es producida por hongos que causa la desintegración de los tejidos. En su etapa inicial se observan manchas negras y hundidas en forma de úlcera que aparecen sobre hojas, tallos, flores y frutos de numerosas plantas de los jardines [34].

### **5.9.3. Phytophthora Infestans:**

La enfermedad puede identificarse fácilmente en su primera etapa, examinando la cara inferior de las hojas infectadas, donde se observa una eflorescencia blanquecina en el límite entre el tejido sano y el enfermo, donde aparecen manchas pardas que se van agrandando. Afecta a los frutos inmaduros, manifestándose como grandes manchas pardas [32].

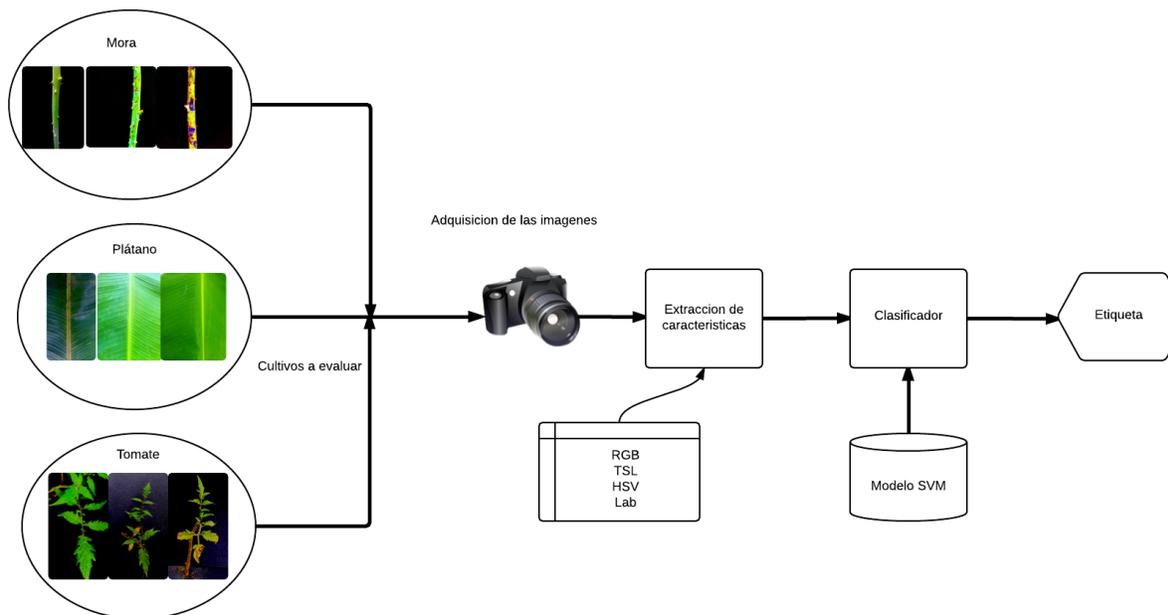
## 6. METODOLOGÍA

Este proyecto hace parte de un macro proyecto titulado “diseño e implementación de un sistema automático para la detección de enfermedades en cultivos de fruta”, la primera parte del macro proyecto fue el diseño de una red de sensores utilizando sistemas embebidos y la segunda parte que es la que hace parte de este proyecto, consiste en la de evaluar una metodología para la detección de enfermedades en cultivos de frutas.

Por lo tanto, para el desarrollo de este proyecto se sigue la consecución de los objetivos propuestos en el macro proyecto, con lo cual se analiza los modelos de color y textura basados en histogramas, para la detección de patrones en las plantas de tomate, mora y plátano, proporcionando un análisis eficiente en la detección de las enfermedades en los cultivos. Posteriormente se explicará los conceptos, pasos y consideraciones de los métodos utilizados, luego se propone una metodología estructurada que consta de tres etapas fundamentales que permiten evaluar el desempeño de cada método de aprendizaje supervisado, además, se propone una metodología de mas, para la detección de la enfermedad *Phytophthora Infestans* en la planta de tomate, con el fin de eliminar el tallo que es del mismo color que la enfermedad para mejorar el proceso de extracción de características.

Inicialmente se realiza la construcción de la base de datos anotada con la captura de imágenes de los tres cultivos, después en la segunda etapa, se analiza los patrones que entregan los descriptores (RGB, TSL, Lab) y se realiza la extracción de características basada en diferentes funciones de transformación espacio frecuencia (Wavelet, FFT).

En la última etapa se plantea el entrenamiento y validación de modelos de clasificación mediante el uso de una SVM para establecer a qué clase pertenece el conjunto de características y observar el método propuesto. Se observa en la figura 4 el diagrama de bloques de la implementación de la metodología.



**Figura 4. Esquema general de implementación.**

### **6.1. CONSTRUCCIÓN DE LA BASE DE DATOS**

Para construir la base de datos, se utilizó el dispositivo desarrollado en el proyecto “Diseño e implementación de un prototipo de una red de sensores inalámbricos para cultivos de frutas utilizando beaglebone black”. Donde se implementó en los cultivos de fruta en varias fincas de la región de Risaralda. Por lo cual el objetivo principal del proyecto, es el de evaluar una metodología de aprendizaje supervisado.

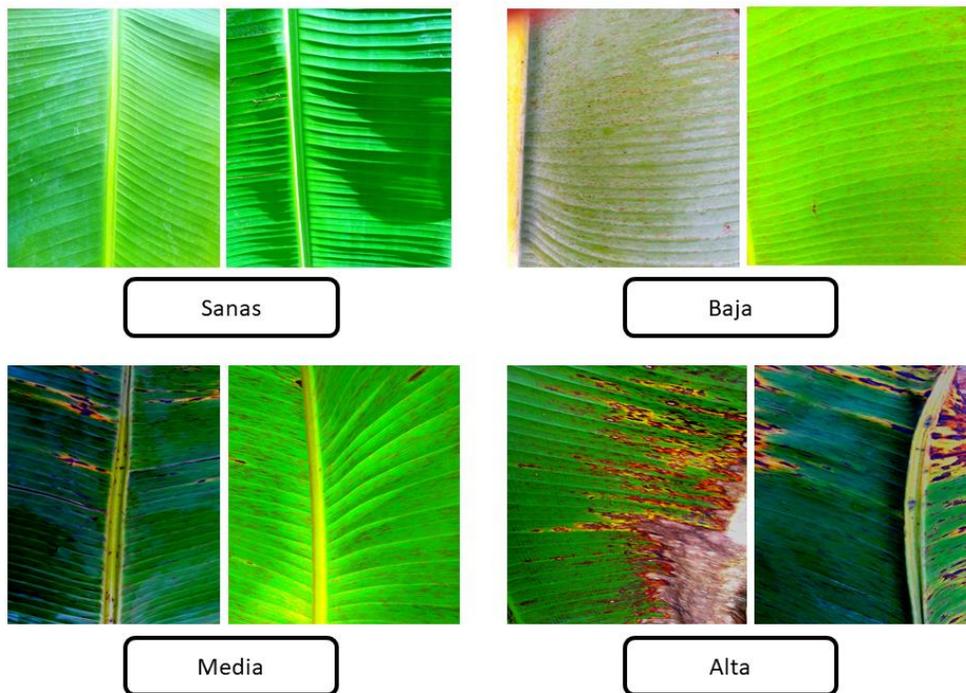
Para adquirir las imágenes de los diferentes cultivos, se seleccionó las plantas sanas y enfermas de tomate basado en la escala de severidad de la enfermedad *Phytophthora Infestans* del trabajo [32], se tomó las fotos con una cartulina negra de fondo para aislar la planta del resto de los cultivos, con el fin de mejorar el proceso de extracción de características; en los cultivos de plátano se tomaron las fotos sanas y para las enfermas se creó una escala de severidad de Baja, Media, Alta, en la Baja, se consultó el porcentaje de estadio del trabajo [33] y se combinó el porcentaje de estadio 1 y 2, en la media el estadio 3 y 4, en la Alta el estadio 5 y 6, basado en la escala de severidad de *Sigatoka Negra*; por último, en los cultivos de mora se basó en el trabajo [34] para distinguir la escala de severidad de la enfermedad *Antracnosis*, donde se creó la escala de severidad Baja, Media, Alta combinando la escala de severidad 1% y 5% para la escala Baja, en la Media se

combinó la del 10% y 25%, y en la escala Alta es la 50%, las fotos se tomaron igual que con los cultivos de tomate.

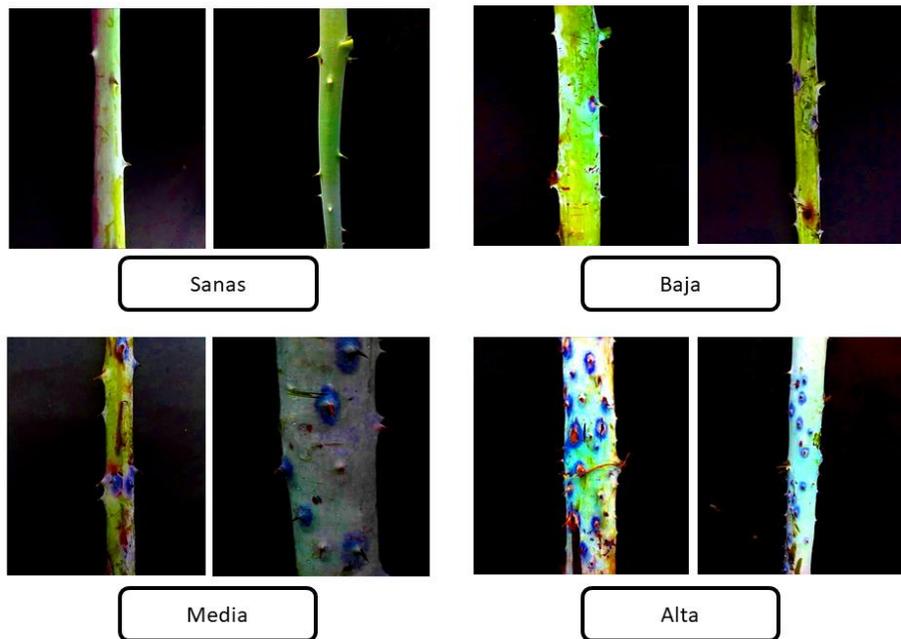
En las figuras 5, 6 y 7, se muestra las bases de datos de los cultivos con su propia clasificación.



**Figura 5. Base de datos anotadas de las plantas de tomate.**



**Figura 6. Base de datos anotadas de las hojas de plátano.**



**Figura 7. Base de datos anotadas de los tallos de mora.**

## 6.2. SEGMENTACIÓN

La segmentación solamente de las plantas de tomates se realizó con, el objetivo de separar un color fuerte como el verde o el amarillo de un color oscuro como el negro o el morado que es el color del fondo. Inicialmente se reescala la imagen a una resolución menor ver Figura 8, con el fin de procesar una imagen de menor tamaño, luego se convierte la imagen al espacio de color Lab, y se escoge el canal b que es la variación de los colores azul y amarillo para detectar el fondo, normalizando el canal b con respecto al valor máximo seleccionando todos los colores que son muy oscuros, para lo cual se estableció un umbral (0.35) como se observa en la siguiente función.

$$f(x) = \begin{cases} 1 & x > 0.35 \\ 0 & \text{otro caso} \end{cases} \quad (25)$$

Aplicando una operación morfológica de dilatación con un elemento estructurante cuadrado de 10x10 píxeles, con el fin de rellenar los píxeles vacíos que están cerca a los píxeles que hacen parte de la enfermedad. Para eliminar el fondo, se reemplaza el color de la imagen original en los píxeles que tienen el valor de 1 (blanco).

### **6.3. EXTRACCIÓN DE CARACTERÍSTICAS**

Para la extracción de características. Se utilizan los modelos de color propuesto mediante el uso de histogramas, que van a permitir la clasificación de los datos de cada imagen, utilizando descriptores de espacio-frecuencia (Wavelet, FFT) y de color (RGB, TSL, HSV, Lab).

#### **6.2.1 Descriptor RGB**

El descriptor RGB es una representación espacial de color en una imagen, para calcular el descriptor de color se utilizó un histograma, que mide la distribución de los niveles de intensidad de la imagen, se calculó un histograma por cada canal, luego se concatenó cada histograma en uno solo, para que el descriptor quede de la siguiente forma  $D_{RGB} = [D_R : D_G : D_B]$ .

$D_R, D_G$  y  $D_B$  son de tamaño  $1 \times n$ , donde  $n$  es la cantidad de bins. De manera experimental se eligió una cantidad de 5 a 20 bins para cada canal, buscando cual de esos bins tendría mejor desempeño.

#### **6.2.2. Descriptor TSL**

Como se mencionó en el capítulo anterior en el modelo de color TSL, la información que está contenida en el canal L, no es de mayor importancia para esta etapa de desarrollo, ya que contiene la variación de iluminación de la imagen. Teniendo en cuenta lo anterior, se analiza los canales T y S y se define el descriptor mediante histogramas, quedando de la siguiente manera:  $D_{TSL} = [D_T : D_S]$  de dimensiones  $1 \times n$  que corresponden a los histograma de cada uno, y la cantidad de bins por canal, va desde 5 hasta 15 bins, nuevamente se escoge el de mejor desempeño.

#### **6.2.3. Descriptor HSV**

En el descriptor HSV, la información de los canales de Tono, Saturación y valor, se analizan para hallar el descriptor mediante histogramas de la siguiente forma:  $D_{HSV} = [D_H : D_S : D_V]$  de dimensiones  $1 \times n$  y  $n$  es la cantidad de bins.

#### **6.2.4. Descriptor Lab**

En el descriptor Lab, las diferencias de color que se perciben corresponden a las distancias medidas. En el espacio a que se extiende desde el verde (-a) al rojo (+ a) y el eje b desde azul (-b) hasta amarillo (+ b). El brillo (L) aumenta de abajo hacia arriba en el modelo tridimensional. Por lo tanto, se define el descriptor mediante histogramas de la siguiente manera:  $D_{lab} = [H_l; H_a; H_b]$  donde  $H_l$ ,

Ha y Hb son de dimensiones  $1 \times n$  y  $n$  es la cantidad de bins, de nuevo se selecciona el mejor desempeño dependiendo de la cantidad de bins.

### 6.2.5. Descriptor FFT

Se propone el uso de este descriptor geométrico, que está relacionado con los picos más altos respecto al orden central de la transformada de Fourier, por tal motivo se realiza el cálculo de la transformada rápida de Fourier, que permite obtener un vector de características X. Después se calcula los modelos estadísticos utilizando las ecuaciones de la tabla 1 como, la media, desviación estándar, sesgo y kurtosis, para poder analizar las características principales de la imagen.

Parámetro	Ecuación
Media	$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{x_1 + x_2 + \dots + x_n}{n} \quad (11)$
Desviación Estándar	$s = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (12)$
Sesgo	$s_1 = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\left( \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \right)^3} \quad (13)$
Kurtosis	$k_1 = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{\left( \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \right)^2} \quad (14)$

Tabla 1. Modelos estadísticos para obtener el vector de características FFT.

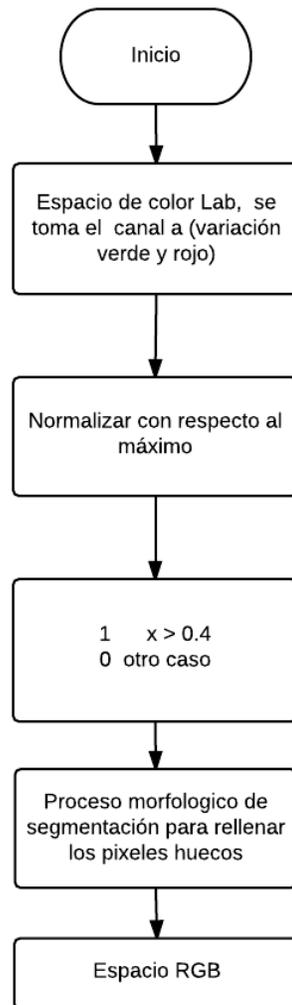
Donde  $x_i$  es cada una de las muestras obtenidas en el cálculo de X, de dimensiones  $4 \times 1$ .

### 6.2.6. Descriptor Wavelet

Este descriptor se utiliza para reconocer objetos según su forma de contorno, se calcula aplicando la transformada Wavelet y se sigue el mismo procedimiento del descriptor anterior, donde se

calcula los parámetros estadísticos de la tabla 1, obteniendo el vector de características  $W_a$  con dimensiones  $4 \times 1$ .

### 6.2.7. Método para eliminar el tallo en la planta de tomate



**Figura 8. Diagrama de Flujo para eliminar todo lo que no sea amarillo ni verde de la imagen.**

Como el tallo generalmente tiene un color más oscuro a la enfermedad, pero es muy parecido al color. Nuevamente se reemplaza el color RGB al HSV, y se toma el canal V, que es la variación de brillo, todos los valores mayores a 0.5 normalizados, toman el valor de 1, si no cumple esta condición toma el valor de 0 aplicando la función (25), esto con el fin de dejar los pixeles que tienen brillo en la imagen que es potencialmente la enfermedad, sin embargo, todavía quedan verdes con brillo, de nuevo se reemplaza el color original como se ve en la Figura 11.

Para quitar ese verde con brillo, se pasa al HSV y se escoge el canal H que son las variaciones de color rojo y amarillo, se aplica la función (26), donde todos los valores normalizados menores a 0.3 que son el rojo o el amarillo y mayores a 0.05 que no es totalmente negro, porque si es 0 tomaría los pixeles del fondo negro, luego se reemplaza al color original como se observa en la Figura 12.

$$f(x) = \begin{cases} 1 & 0.3 < x < 0.05 \\ 0 & \text{otro caso} \end{cases} \quad (26)$$

En el espacio RGB se toma el valor de los pixeles mayor a 130, para poder dejar el color amarillo y rojo que es el color característico de la enfermedad, sin embargo, todavía quedan partes de tallo y esto va generar ruido a la imagen. Por lo tanto, se utiliza una operación morfológica de forma, que consiste en eliminar todo lo que no sea de forma cuadrada, normalizando respecto a la distancia más grande, luego se restó el valor máximo y mínimo de la columna con el valor máximo y mínimo de la fila, si la resta da menor a 0.4 tiende a ser un cuadrado; como los tallos generalmente son de forma rectangular, con este proceso se elimina los tallos. Por último, queda la enfermedad segmentada, para determinar el porcentaje del área afectada en la imagen, es decir, se calcula cuantos pixeles hay en toda la imagen y luego se resta los pixeles del área afectada por la enfermedad, que será la característica fundamental para entrenar la SVM.

### **6.3. ENTRENAMIENTO Y VALIDACION**

En esta sección se pretende implementar el modelo de separación del modelo de aprendizaje y luego validar ese modelo, mediante los datos de los descriptores de color y de textura. Por lo cual se divide en dos etapas. La primera etapa es entrenar el modelo, para estimar los parámetros intrínsecos del modelo y la otra etapa consiste en validar dicho modelo con el método de validación cruzado de Montecarlo que encuentra la convergencia del desempeño del clasificador.

Para la etapa de clasificación se utilizó la Máquina de Soporte Vectorial Multiclase, utilizando la estrategia uno para todos (one-vs-all) con un kernel Gaussiano con radio adaptativo para separar los datos, además, se utilizó el método minimización *Sequential Minimal Optimization* (SMO) para calcular los vectores de soporte que ayudan a la estimación del modelo,

el algoritmo se implementó con la función *Fitcecoc* utilizando el toolbox de Matlab® *Statistics and machine learning*. Se debe tener en cuenta que se debe realizar una normalización gaussiana de los datos que se van entrenar como se observa en la ecuación 26.

$$z = \frac{x-\mu}{\sigma} \quad (26)$$

Donde  $\mu$  es el vector de medias de la matriz de entrenamiento y  $\sigma$  es vector de desviaciones estándar de esta matriz.

La estrategia de validación cruzada que se utilizó fue fraccionar de forma aleatoria la distribución uniforme de la base de datos, lo cual se seleccionó 70% para el entrenamiento y el 30% restante para validar en cada iteración.

El criterio de parada del algoritmo es  $\|diag(M_k) - diag(M_{k-1})\| < 0.002$ , donde  $diag(M_k)$  es el vector de la diagonal de la matriz de confusión y  $k$  es la iteración actual del método de Montecarlo; al realizar estos cálculos de forma adaptativa se garantiza la convergencia del experimento.

Para observar el porcentaje de aciertos que obtuvo el clasificador, se utilizó la matriz de confusión con los porcentajes y desviación de cada clase.

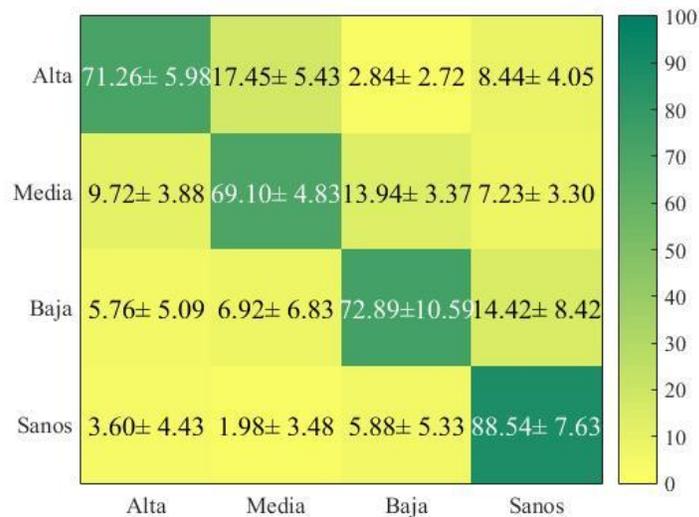
## 7. ANÁLISIS Y RESULTADOS

Una vez presentadas las técnicas y métodos fundamentales referentes a la visión por computador, que permitan detectar las enfermedades *Antracnosis* y *Phytophthora Infestans* de los cultivos de plátano, tomate y mora, es indispensable el análisis de los resultados obtenidos con dichos métodos, esto permite realizar un estudio cualitativo y cuantitativo, sobre la capacidad de descripción que tiene los descriptores y las transformadas de espacio-frecuencia. En este capítulo se realizará el proceso de entrenamiento y validación de la base de datos anotada, con el fin de analizar el desempeño de cada metodología de extracción de características que se propuso para el método SVM.

Inicialmente se presentan los resultados relativos a los diversos experimentos realizados con el Método de Montecarlo para cada cultivo y luego se realiza un análisis comparativo del desempeño de cada descriptor.

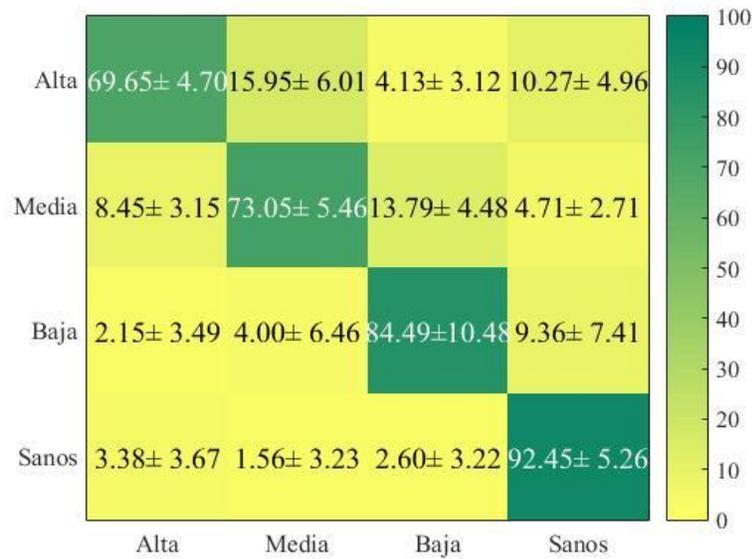
### 7.1. Cultivo de Plátano

La tabla 2 muestra la matriz de confusión para analizar el desempeño que presenta el clasificador (SVM) con el descriptor RGB con 5 bins. De esta tabla se observa un rendimiento medio para la detección de las hojas de plátano, presentando porcentajes de acierto mayores al 69% para todas sus clases. La clasificación de cada clase corresponde a la severidad de la enfermedad de *Sigatoka Negra* descrito en la sección de la base de datos anotada, por ejemplos la clase Baja corresponde a la escala Baja de esta enfermedad.



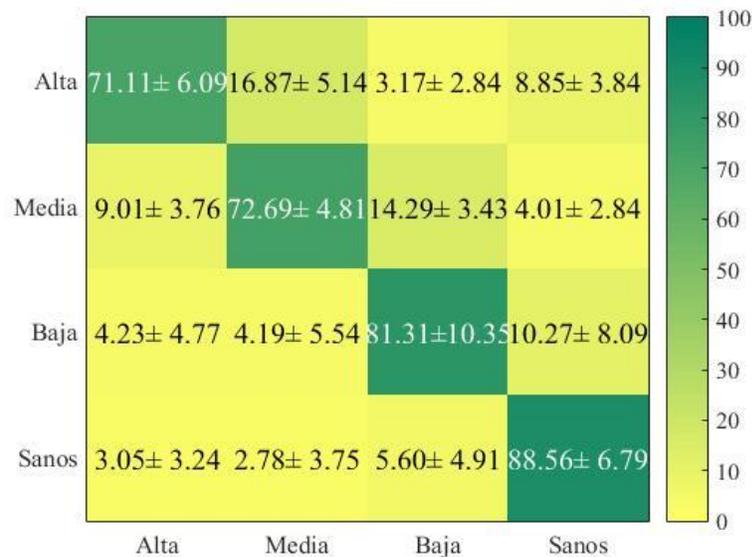
**Tabla 2. Matriz de confusión del plátano método RGB-SVM con 5 bins.**

La tabla 3 muestra un mejor rendimiento para la detección de las hojas de plátano, presentando porcentajes de acierto mayores al 73% para todas sus clases exceptuando la clase Alta que fue mayor al 69%, se evidencia una baja confiabilidad para detectar este tipo de variaciones. Tuvo 192 iteraciones de Montecarlo y se realizó igual que el experimento anterior solo que se con el descriptor RGB a 10 bins.



**Tabla 3. Matriz de confusión del plátano método RGB-SVM con 10 bins**

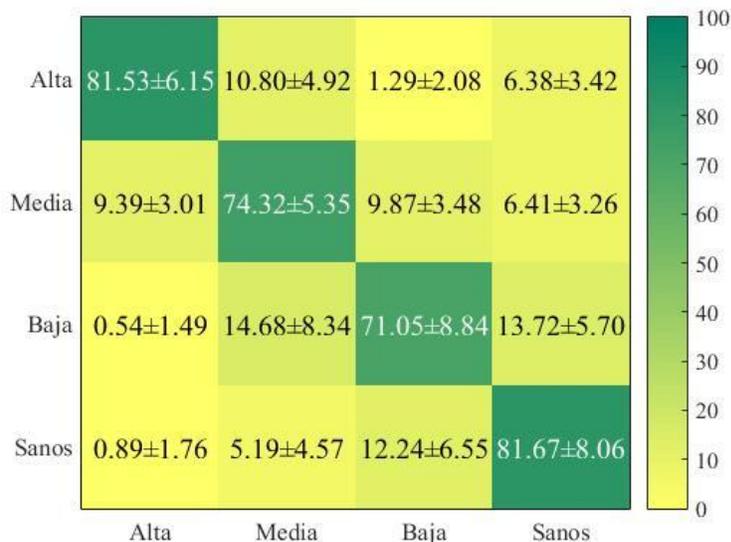
La tabla 4 muestra un bajo el rendimiento para la detección de las hojas de plátano, presentando porcentajes de acierto mayores al 71% para todas sus clases. Tuvo 204 iteraciones de Montecarlo y se realizó igual que el experimento anterior con el descriptor RGB a 20 bins.



**Tabla 4. Matriz de confusión del plátano método RGB-SVM con 20 bins.**

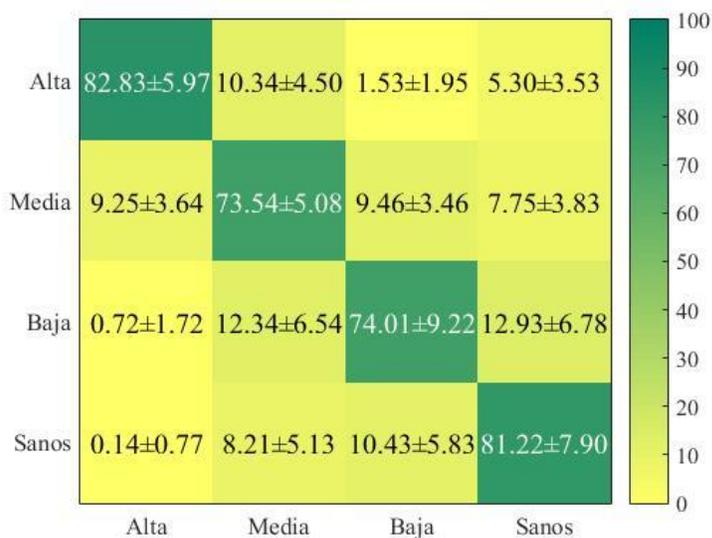
La tabla 5 muestra el desempeño de clasificación utilizando el método de caracterización del descriptor TSL con 10 bins y clasificación con SVM. Se observa un alto rendimiento para la

detección de las hojas de plátano, presentando porcentajes de acierto mayores al 81% en las clases Sanos y Altas. Sin embargo, se puede observar en el experimento que las clases Media y Baja presentan rendimientos en la escala del 71%.



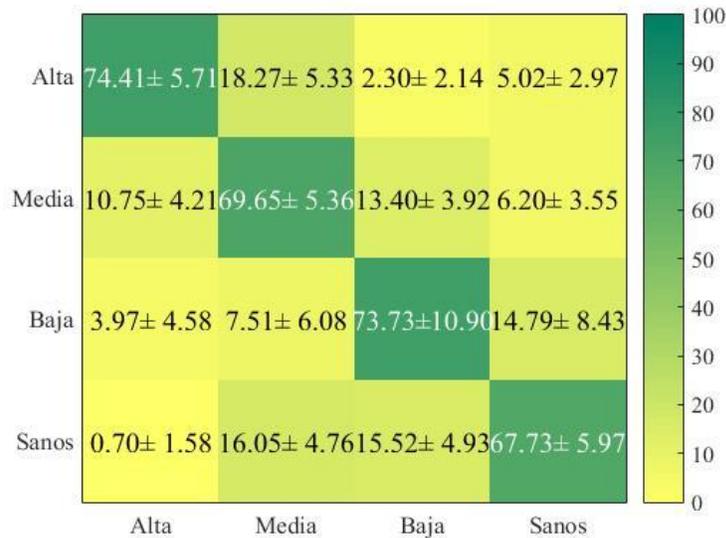
**Tabla 5. Matriz de confusión del plátano método TSL-SVM con 10 bins.**

La tabla 6 muestra el desempeño de clasificación similar al experimento anterior solo que se varió a 15 bins. Se observa que es mejor el rendimiento para la detección de las hojas de plátano, presentando porcentajes de acierto mayores al 73% en todas sus clases.



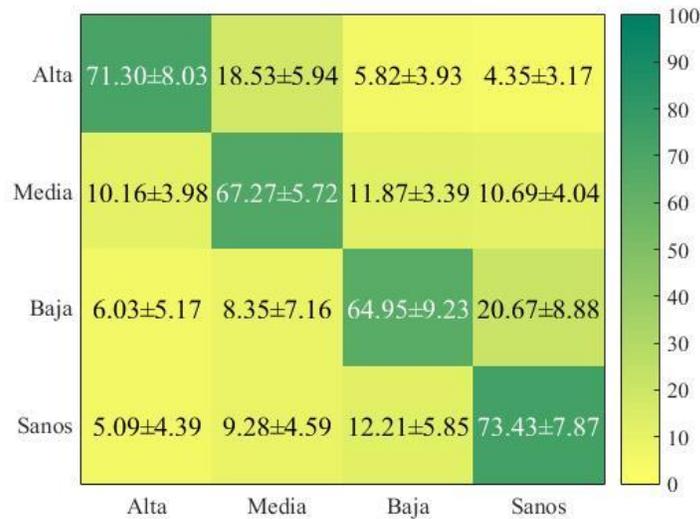
**Tabla 6. Matriz de confusión del plátano método TSL-SVM con 15 bins.**

La tabla 7 se observa la matriz de confusión utilizado el descriptor Lab con 15 bins y SVM. para la detección de las hojas de plátano, presentando porcentajes de acierto mayores al 73% en todas sus clases.



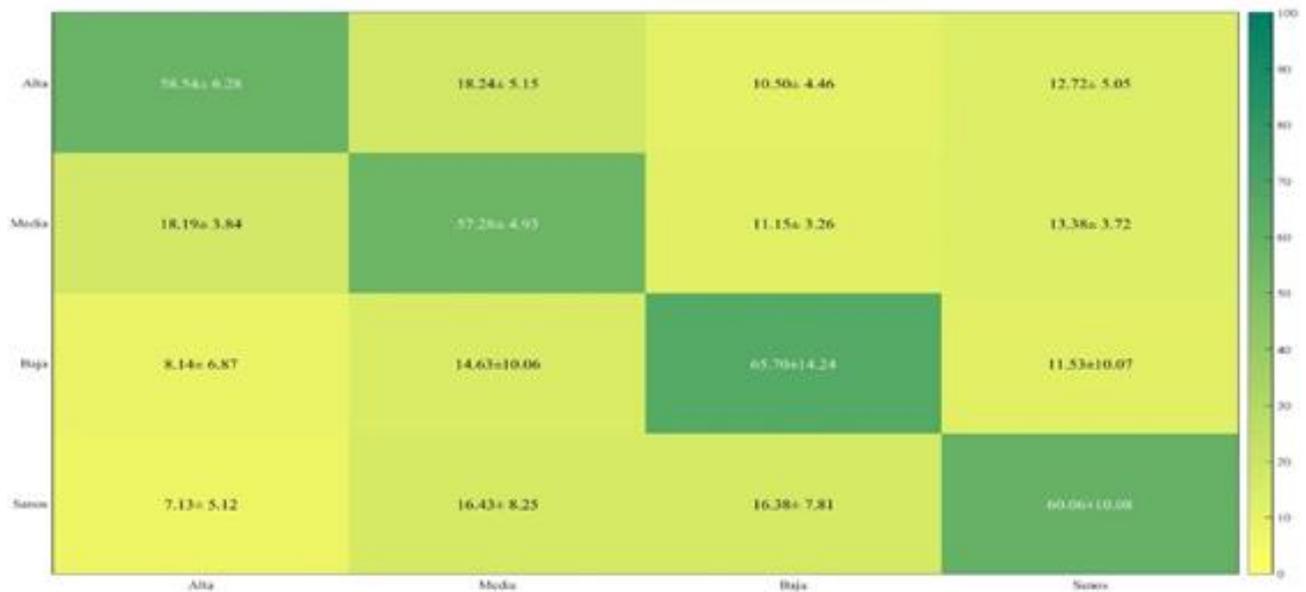
**Tabla 7. Matriz de confusión del plátano método Lab-SVM con 15 bins.**

En la tabla 8 se puede observar la matriz de confusión para un total de 302 iteraciones de MonteCarlo. En este experimento se aplicó el método de caracterización con el descriptor FFT y método de clasificación SVM. De esta tabla se observa un medio rendimiento para la detección de las hojas de plátano, presentando porcentajes de acierto mayores al 71% para las clases Altas y Sanos, pero para las clases Media y Baja fue del 67% y 64% respectivamente. Este experimento fue uno de los que más se demoró en mostrar sus resultados.



**Tabla 8. Matriz de confusión del plátano método fft-SVM.**

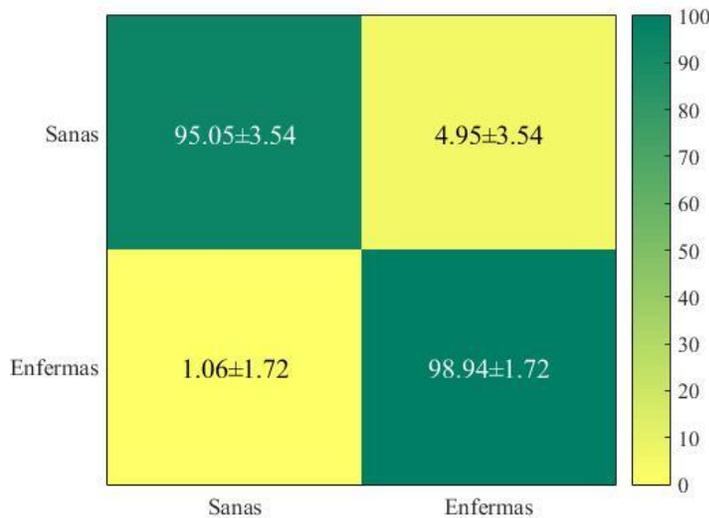
La tabla 9 muestra el desempeño del clasificador utilizando el método de caracterización Wavelet y clasificación con SVM. De esta tabla se observa un bajo rendimiento para la detección de las hojas de plátano, presentando porcentajes de acierto menores del 65% para las todas las clases que evidencia una baja confiabilidad para detectar este tipo de enfermedad.



**Tabla 9. Matriz de confusión del plátano método Wavelet-SVM.**

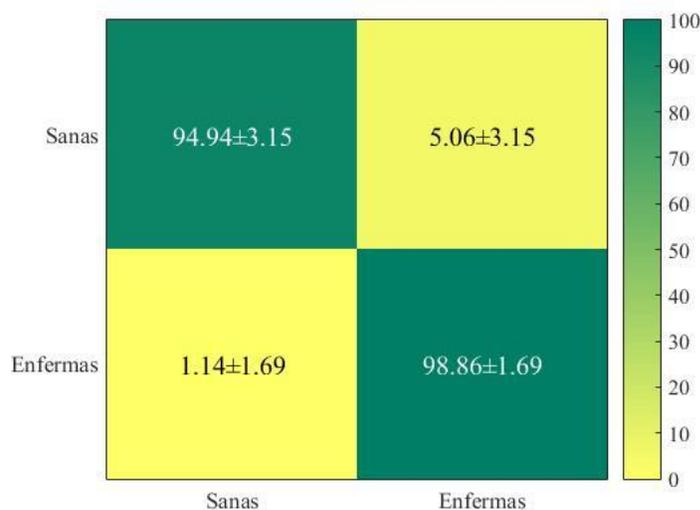
## 7.2. Cultivo de Tomate

La tabla 10 muestra la matriz de confusión obtenida, con el descriptor RGB a 5 bins y con SVM. De esta tabla se observa un alto rendimiento para la detección de las plantas de tomate, presentando porcentajes de acierto mayores al 95% para todas sus clases.



**Tabla 10. Matriz de confusión del tomate método RGB-SVM con 5 bins.**

La tabla 11 realizó el mismo experimento anterior se cambió los bins por una cantidad de 10 bins. Se observa en la tabla que para la clase Sanas bajo el porcentaje de acierto a 94% y para la clase Enfermas se mantuvo en 98%.



**Tabla 11. Matriz de confusión del tomate método RGB-SVM con 10 bins.**

La tabla 12 se observa el desempeño del clasificador utilizando el método de caracterización del descriptor TSL con 5 bins y la clasificación con SVM. Se muestra un alto rendimiento para la detección de las plantas de tomate, presentando porcentajes de acierto mayores al 94% en las dos clases. Tuvo un total de 60 iteraciones de Montecarlo.



**Tabla 12. Matriz de confusión del tomate método TSL-SVM con 5 bins.**

La tabla 13 se observa el desempeño de clasificación utilizando el método anterior pero ahora con 10 bins, se muestra un excelente rendimiento para la detección de las plantas de tomate, presentando porcentajes de acierto mayores al 100% en las clases Sanas y en las enfermas fue de 97%.



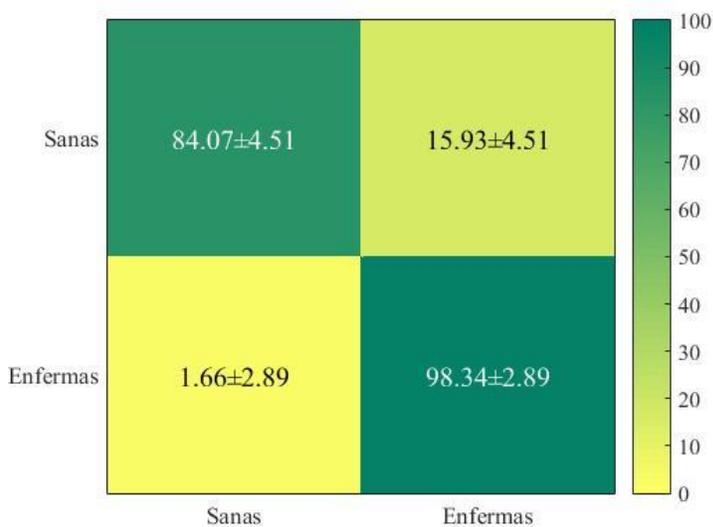
**Tabla 13. Matriz de confusión del tomate método TSL-SVM con 10 bins.**

En la tabla 14 se puede observar la matriz de confusión con el descriptor FFT y SVM. De esta tabla se observa un medio rendimiento para la detección de las plantas de tomate, presentando porcentajes de acierto del 60% para la clase Sanas y la clase Enferma de 62%.



**Tabla 14. Matriz de confusión del tomate método fft-SVM.**

La tabla 15 muestra el desempeño de clasificación utilizando el método de caracterización Wavelet y clasificación con SVM. De esta tabla se observa un alto rendimiento para la detección las plantas de tomate, presentando un porcentaje de acierto 84% para las clases Sanas y 98% para las enfermas.



**Tabla 15. Matriz de confusión del tomate método Wavelet-SVM.**

En las siguientes figuras se muestra el resultado de la metodología propuesta para la extracción de características del tomate, donde se muestra la eliminación del tallo de la planta..



**Figura 9. Planta de tomate imagen original.**

En la figura 9 se observa la segmentación de la planta, donde se eliminó el fondo que sería ruido para entrenar el modelo.



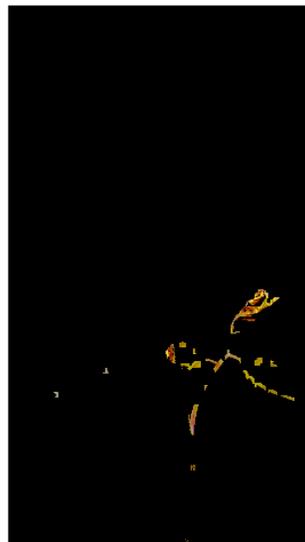
**Figura 10. Segmentación de la planta.**

En la figura 10 se segmentó el área donde se presenta la enfermedad, pero se observa que también quedan partes de tallo.



**Figura 11. Segmentación de la enfermedad.**

En la figura 11 se elimina el color oscuro del tallo dejando, el color verde que tiene brillo.



**Figura 12. Eliminación de las zonas oscuras del tallo.**

En la figura 12 se eliminan las zonas que quedan de verde con mucho brillo.



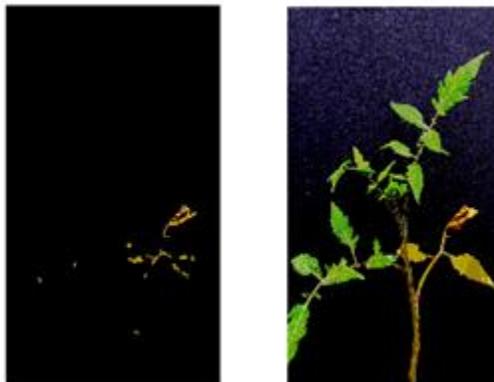
**Figura 13. Eliminación de las áreas restantes de verde.**

En la figura 13 se elimina un gran porcentaje de las zonas donde está el tallo utilizando una operación morfológica de forma, eliminando área donde está presente la enfermedad, pero un pequeño porcentaje.



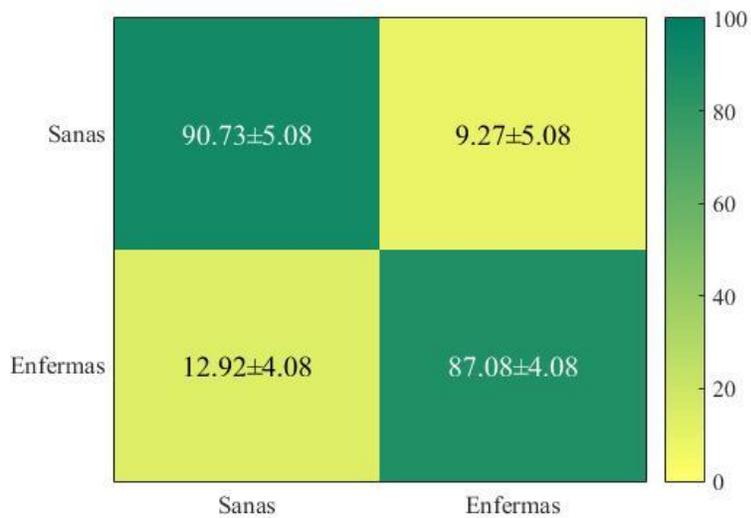
**Figura 14. Operación morfológica para quitar el resto zonas del tallo.**

En la figura 14 se observa el área afectada de la enfermedad, respecto a la imagen original.



**Figura 15. Porcentaje del área afectada de la enfermedad.**

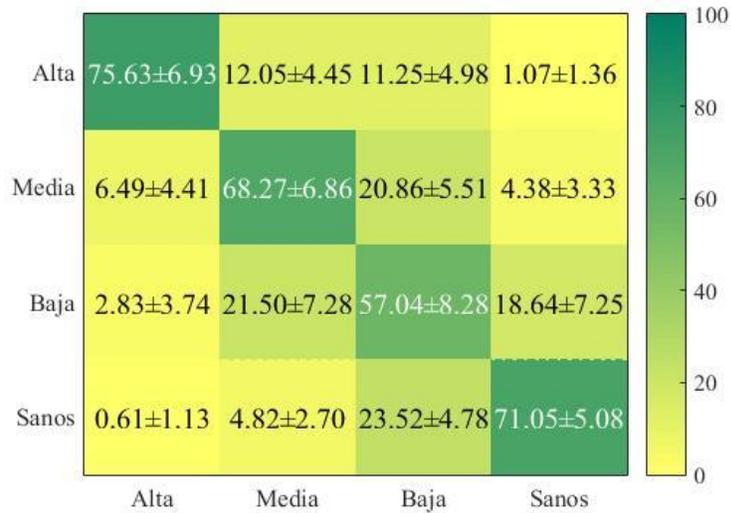
En la tabla 16 se puede observar la matriz de confusión del método propuesto para detectar la enfermedad, se tiene un alto rendimiento, presentando porcentajes de acierto 84% para la clase Sanas y Medias del 98%.



**Tabla 16. Matriz de confusión del tomate método para detectar *Phytophthora Infestans*.**

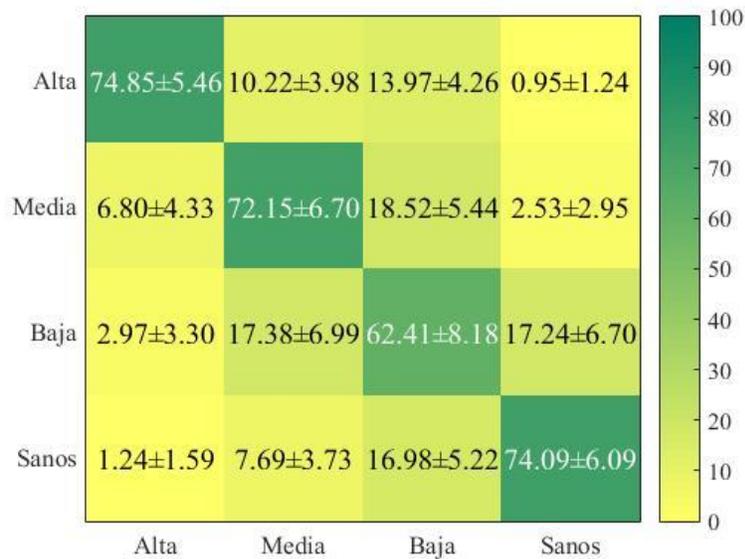
### 7.3. Cultivo de mora

En la tabla 17 se muestra la matriz de confusión obtenida, con el descriptor RGB con 5 bins y la clasificación con SVM. De esta tabla se observa un alto rendimiento para la detección de la enfermedad *Antracnosis* en las moras, presentando porcentajes de acierto mayores al 71% en las clases Alta y Sanos. Se hizo una clasificación similar de cada clase como en el cultivo de plátano.



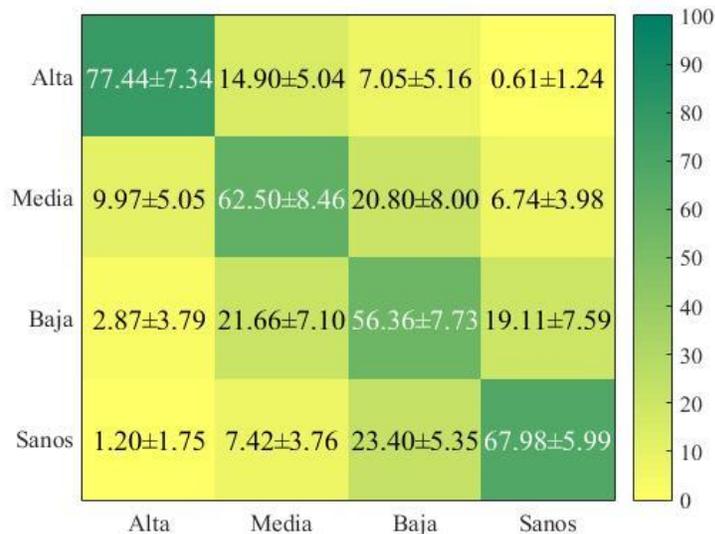
**Tabla 17. Matriz de confusión de mora método RGB-SVM con 5 bins.**

En la tabla 18 se realizó el mismo experimento anterior solo se varió los bins por 10 bins. De esta tabla se observa una mejora en la detección de la enfermedad *Antracnosis* en las moras, presentando porcentajes de acierto mayores al 72% en las clases Alta, Media y Sanos, sin embargo, la clase Baja tuvo un porcentaje de acierto de 62%.



**Tabla 18. Matriz de confusión de mora método RGB-SVM con 10 bins.**

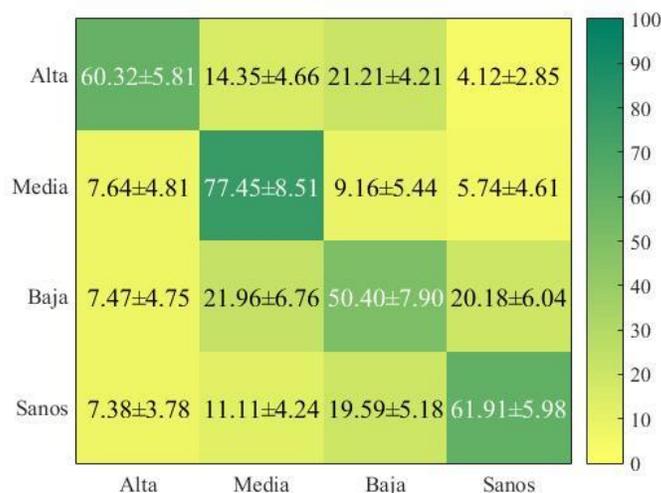
En la tabla 19 se puede observar la matriz de confusión obtenida, con el descriptor TSL con 10 bins y la clasificación con SVM. De esta tabla se observa un alto y medio rendimiento para la detección de la enfermedad *Antracnosis* en las moras, presentando porcentajes de acierto mayores al 67% en las clases Alta y Sanos y en las clases Media y Baja 62% y 56% respectivamente.



**Tabla 19. Matriz de confusión de mora método TSL-SVM con 10 bins.**

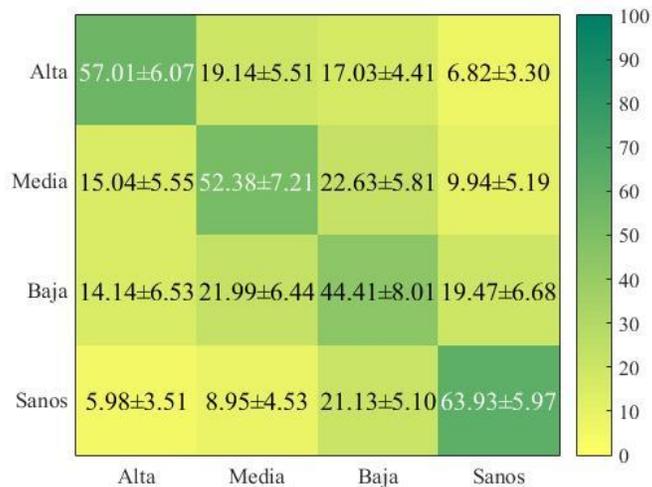
En la tabla 20 se muestra la matriz de confusión obtenida, con el descriptor Lab con 10 bins y la clasificación con SVM. De esta tabla se observa un alto y medio rendimiento para la detección de

la enfermedad *Antracnosis* en las moras, presentando porcentajes de acierto del 60.7% en las clases Media, en las clases Alta y Sanas de 60% y 61% respectivamente y la clase Baja tuvo bajo desempeño del 50%.



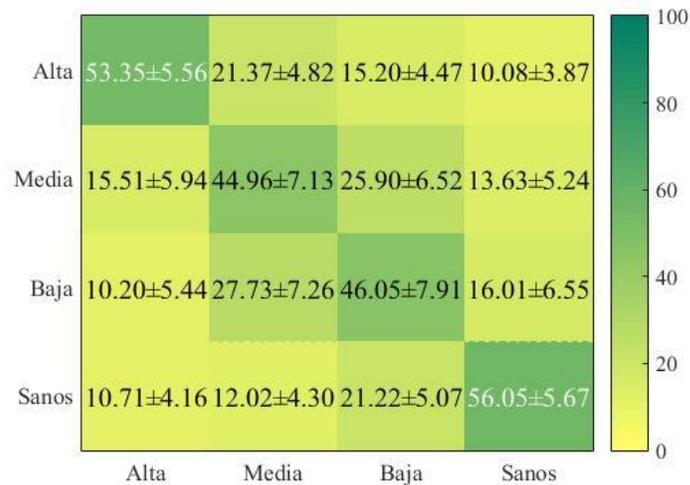
**Tabla 20. Matriz de confusión de mora método Lab-SVM con 10 bins.**

En la tabla 21 se puede observar la matriz de confusión con el descriptor FFT y método de clasificación SVM. De esta tabla se observa un medio y bajo rendimiento para la detección de la enfermedad *Antracnosis* en las moras, presentando porcentajes de acierto menores del 57% para la clase Alta, Media y Baja, la clase Sanas de 63%.



**Tabla 21. Matriz de confusión de mora método fft-SVM.**

La tabla 22 muestra el desempeño del clasificador utilizando el método de caracterización Wavelet y clasificación con SVM. De esta tabla se observa un bajo rendimiento para la detección de la enfermedad *Antracnosis* en las moras, presentando porcentajes de acierto menores 56% para las clases.



**Tabla 22. Matriz de confusión de mora método Wavelet-SVM.**

Con el objetivo de realizar un análisis comparativo entre las diferentes metodologías propuestas, se procede a calcular el desempeño de acierto promedio, este cálculo consiste en calcular el valor medio del vector resultante de la diagonal de la matriz de confusión. En las tablas 23, 24 y 25 se puede observar el desempeño promedio para cada una de las metodologías propuestas en este trabajo.

**Tabla 23. RESULTADOS DE TEST DE PLATÁNO**

Método	Porcentaje (%)
SVM-RGB con 5 bins	75.45±8.87
SVM-RGB con 10 bins	79.91±10.50
SVM-RGB con 20 bins	78.41±8.11
SVM-TSL con 10 bins	77.14±5.32
SVM-TSL con 15 bins	77.90±4.81
SVM-Lab con 15 bins	77.38±3.21
SVM-FFT	69.23±3.83
SVM-Wavelet	60.40±3.71

De la tabla 23 se puede observar que los métodos con mayor desempeño son los que utilizan el descriptor de color, logrando un desempeño alto del 79% para el método SVM-RGB con 10 bins de la base de datos del cultivo de plátano, aunque este desempeño tiene una desviación muy alta, por lo tanto no es muy confiable para caracterizar la enfermedad, aunque los otros dos descriptores de color presentan un desempeño cercano al método anterior del 77% y su desviación también es menor, lo cual son aceptables para caracterizar la enfermedad.

**Tabla 24. RESULTADOS DE TEST DE TOMATE**

Método	Porcentaje (%)
SVM-RGB con 5 bins	96.99±2.75
SVM-RGB con 10 bins	96.90±2.77
SVM-TSL con 5 bins	95.34±1.77
SVM-TSL con 10 bins	98.72±1.81
SVM-FFT	61.55±1.67
SVM-Wavelet	91.21±10.09
Método para detectar <i>Phytophthora Infestans</i>	88.91±2.58

De la tabla 24 se muestra que los métodos con mayor desempeño son los que utilizan el descriptor de color, logrando un desempeño ideal del 98% para el método SVM-TSL con 10 bins de la base de datos del cultivo de tomate, también se evidencia que el método Wavelet tuvo un desempeño

alto del 91%, pero su desviación es muy alta, lo cual no es confiable para caracterizar la enfermedad. Por último, se observa que el método propuesto para detectar la enfermedad es aceptable logrando un desempeño del 88% con una desviación pequeña.

**Tabla 25. RESULTADOS DE TEST DE MORA**

Método	Porcentaje (%)
SVM-RGB con 5 bins	67.99±7.91
SVM-RGB con 10 bins	70.88±5.76
SVM-TSL con 10 bins	66.07±8.94
SVM-Lab con 10 bins	62.52±11.18
SVM-FFT	54.43±8.19
SVM-Wavelet	50.10±5.44

De la tabla 25 se puede observar que los métodos lograron un desempeño menor del 70%, pero nuevamente los descriptores de color son los que tienen mejor desempeño para caracterizar la enfermedad, como el método SVM-RGB con 10 bins que tuvo un desempeño del 70% con una desviación pequeña. Por otra parte, los descriptores de espacio-frecuencia lograron un desempeño medio del 50%, lo cual no son confiables para caracterizar la enfermedad del cultivo de mora.

## 8. CONCLUSIONES

- Se permitió verificar el nivel de descripción de cada metodología propuesta en el trabajo para el cultivo de plátano, tomate y mora, tales como histogramas de color como RGB, TSL y Lab; en descriptores espacio-frecuencia como FFT, Wavelet y el método propuesto para segmentar la planta de tomate verificando el desempeño en la etapa de validación con MonteCarlo. Como se observa en la tabla 23 el rendimiento promedio de los métodos con un mejor desempeño son RGB con 10 bins con un  $79.91\% \pm 10.50\%$ , TSL con 15 bins con un  $77.90\% \pm 4.81\%$  y Lab con 15 bins con un  $77.38\% \pm 3.21\%$ . Para la tabla 24 se muestra que los mejores desempeños de los métodos son RGB con 5 bins  $96.99\% \pm 2.75\%$ , TSL con 10 bins con un  $98.72\% \pm 1.81\%$ , Wavelet con un  $91.21\% \pm 10.09\%$  y el método propuesto para detectar *Phytophthora Infestans* con un  $88.91\% \pm 2.58\%$ . por último, en la tabla 25 se puede observar que el mejor rendimiento promedio fue el RGB con 10 bins con un  $70.88\% \pm 5.76\%$  y el TSL con 10 bins con un  $66.07\% \pm 8.94\%$ .
- Se evaluó la metodología para detectar las enfermedades *Antracnosis* y *Phytophthora Infestans*, aplicando un método de aprendizaje supervisado como la SVM obteniendo desempeños promedio superiores al  $79.91\% \pm 10.50\%$  en el cultivo de plátano,  $98.72\% \pm 1.81\%$  para el cultivo de tomate y  $70.88\% \pm 5.76\%$  para el cultivo de mora de todos los métodos analizados.
- Como se logra observar en las tablas 23, 24 y 25 los descriptores de color tienen un mejor desempeño que los descriptores espacio-frecuencia para todos los cultivos permitiendo que los resultados de los métodos tengan un alto porcentaje de eficiencias.
- Se evidencia que el descriptor TSL tiene un buen desempeño similar al RGB, sin embargo, el modelo TSL fue creado para la detección de piel humana, pero se evidenció que en este tipo de aplicaciones su eficiencia promedio fue del  $77.90\% \pm 4.81\%$  para el cultivo de plátano,  $98.72\% \pm 1.81\%$  para el cultivo de tomate y  $66.07\% \pm 8.94\%$  para el de mora. por otro lado, se verifica que el canal L (luminancia), no aporta información relevante en la identificación de parámetros.
- Se analizó en la tabla 24 que el descriptor wavelet tuvo un buen desempeño con un porcentaje de acierto del  $91.21\% \pm 10.09\%$  debido a que este descriptor reconoce objetos por su forma de contorno.

- El método propuesto para detectar la enfermedad *Phytophthora Infestans*, tuvo un buen desempeño para la caracterización de la enfermedad con un  $88.91\% \pm 2.58\%$ , lo cual es viable implementar este método.

## 9. REFERENCIAS

- [1] Sosa-Moss, C. (1997). Manual de técnicas para el diagnóstico de las enfermedades de las plantas. [México]: IICA Agencia de Cooperación Técnica.
- [2] FLORIANO Q J, García Lozano J, Vera L Chamorro L y J, Dimas Segura. Enfermedades y plagas del cultivo del lulo (*Solanum quitoense*) en el departamento del Huila. En: Centro de Investigación Nataima, CORPOICA, 2007.
- [3] SILVA B, Jaramillo S y M, Martín. Caracterización genética de aislamientos de *Phytophthora Infestans* en las zonas productoras de papa de los departamentos de Antioquía, Boyacá, Cundinamarca y Norte de Santander (Colombia). En: Actualidades Biológicas, tomo 31, no 90, 2009.
- [4] GARCÍA, Alejandro Pérez. La interacción tomate-*Cladosporium fulvum*: Un modelo experimental para el estudio de interacciones patógeno-planta (I). Inf. téc., Departamento de Microbiología de la Universidad de Málaga, 2000.
- [5] LEDERSON GAÑÁN, Elizabeth Álvarez, Jairo Castaño Zapata. Identificación genética de aislamientos de *Colletotrichum* spp. causantes de antracnosis en frutos de aguacate, banano, mango y tomate de árbol. En: Revista de la Academia Colombiana de las Ciencias Exactas, Física y Naturales, 2015, pág. 9.
- [6] Price, T., Gross, R., Ho, W. and Osborne, C. (1993). A comparison of visual and digital image-processing methods in quantifying the severity of coffee leaf rust (*Hemileia vastatrix*). *Australian Journal of Experimental Agriculture*, 33(1), p.97.
- [7] Hetzroni, A., Miles, G., Engel, B., Hammer, P. and Latin, R. (1994). Machine vision monitoring of plant health. *Advances in Space Research*, 14(11), pp.203-212.
- [8] Tucker, C. and Chakraborty, S. (1997). *Quantitative Assessment of Lesion Characteristics and Disease Severity Using Digital Image Processing*. Volume 145, Issue 7, pp 273–278
- [9] Martín, D. and Rybicki, E. (1998). Microcomputer-Based Quantification of Maize Streak

- Virus Symptoms in *Zea mays*. *Phytopathology*, 88(5), pp.422-427.
- [10] Yang, C., Prasher, S., Landry, J., Ramaswamy, H. and DiTommaso, A. (2000). Application of artificial neural networks in image recognition and classification of crop and weeds. *AGRIS: International Information System for the Agricultural Science and Technology*. ISSN : 0045-432X
- [11] Sampallo, G. (2003). Reconocimiento de Tipos de Hojas. SSN 1137-3601, ISSN-e 1988-3064, Vol. 7, N°. 21, págs. 55-62
- [12] R. Pydipati, T. F. Burks and W. S. Lee (2005). Statistical and Neural Network classifiers for Citrus disease detection using Machine Vision. *Transactions of the ASAE*, 48(5), pp.2007-2014.
- [13] Sandoval Niño, Z. and Prieto Ortiz, F. (2007). Caracterización de café cereza empleando técnicas de visión artificial. vol.60, n.2, pp.4105-4127. ISSN 0304-2847.
- [14] Huang, K. (2007). Application of artificial neural network for detecting *Phalaenopsis* seedling diseases using color and texture features. *Computers and Electronics in Agriculture*, 57(1), pp.3-11.
- [15] Meunkaewjinda, A., Kumsawat, P., Attakitmongcol, K. and Srikaew, A. (2008). Grape leaf disease detection from color imagery using hybrid intelligent system. 2008 *5th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology*.
- [16] Wiwart, M., Fordoński, G., Żuk-Golaszewska, K. and Suchowilska, E. (2009). Early diagnostics of macronutrient deficiencies in three legume species by color image analysis. *Computers and Electronics in Agriculture*, 65(1), pp.125-132.
- [17] Bermudez, H. and Báez, J. (2010). Aplicación de Técnicas de vision artificial para el reconocimiento de naranjas maduras en el arbol. Trabajo de grado de Ingeniería Electrónica. Bucaramanga: Universidad Pontifica Bolivariana.
- [18] Xu, G., Zhang, F., Shah, S., Ye, Y. and Mao, H. (2011). Use of leaf color images to identify nitrogen and potassium deficient tomatoes. *Pattern Recognition Letters*, 32(11), pp.1584-1590.
- [19] Krishnan, M. and Sumithra, M. (2013). A novel algorithm for detecting bacterial leaf scorch (BLS) of shade trees using image processing. *2013 IEEE 11th Malaysia International Conference on Communications (MICC)*.

- [20] Ratnasari, E., Mentari, M., Dewi, R. and Ginardi, R. (2014). Sugarcane leaf disease detection and severity estimation based on segmented spots image. *Proceedings of International Conference on Information, Communication Technology and System (ICTS) 2014*.
- [21] Dandawate, Y. and Kokare, R. (2015). An automated approach for classification of plant diseases towards development of futuristic Decision Support System in Indian perspective. *2015 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*.
- [22] BELEÑO SAENZ, K. (2016). Clasificación de los frutos de café según su estado de maduración y detección de la broca mediante técnicas de procesamiento de imágenes. Vol. 14, No. 1, págs. 15-22
- [23] Gonzalez, R. and Woods, R. (2001). *Digital image processing*. New York, NY: Pearson.
- [24] Solomon, C. and Breckon, T. (2011). *Fundamentals of Digital Image Processing*. 1st ed. West Sussex, PO19 8SQ, UK: John Wiley & Sons, pp.11-14.
- [25] Sankur, B. (2004). Survey over image thresholding techniques and quantitative performance evaluation. *Journal of Electronic Imaging*, 13(1), p.146.
- [26] Sucar, L. and Gómez, G. (n.d.). *Visión Computacional*. pp.40-50.
- [27] Terrillon, Jean-Christophe; Akamatsu, Shigeru (1998). Automatic Detection of Human Faces in Natural Scene Images by Use of a Skin Color Model and of Invariant Moments. *Proc. Of the Third International Conference on Automatic Face and Gesture Recognition*. Nara, Japan. pp. 130–135.
- [28] Montenegro Bermúdez, A. and Parada Rojas, C. (2016). Diseño e implementación de un sistema de detección de malezas en cultivos Cundiboyacenses. [online] Hdl.handle.net. Available at: <http://hdl.handle.net/10983/3202> [Accessed 10 Jun. 2017].
- [29] Margulis, Dan (2006). *Photoshop Lab Color: The Canyon Conundrum and Other Adventures in the Most Powerful Colorspace*. Berkeley, Calif. : London: Peachpit ; Pearson Education. ISBN 0-321-35678-0.
- [30] Nixon, M. and Aguado, A. (2013). *Feature extraction & image processing for computer vision*. Amsterdam: Elsevier, Academic Press.
- [31] Gómez, H. (2012). *El uso de la transformada wavelet discreta en la reconstrucción de señales senosoidales*. Trabajo de grado de ingeniería Electrónica. Universidad Politecnica Salesiana.

- [32] BETANCOURT, G. (2005). LAS MÁQUINAS DE SOPORTE VECTORIAL (SVMs). [online] Available at: <http://dx.doi.org/10.22517/23447214.6895> [Accessed 18 jun. 2017].
- [33] Corrêa, F., Bueno Filho, J. and Carmo, M. (2009). Comparison of three diagrammatic keys for the quantification of late blight in tomato leaves. *Plant Pathology*, 58(6), pp.1128-1133.
- [34] Álvarez, E., Pantoja, A., Gañán, L. and Ceballos, G. (n.d.). La Sigatoka negra en plátano y banano. [online] Available at: <http://www.fao.org/docrep/019/as089s/as089s.pdf> [Accessed 19 Feb. 2017].
- [35] López, J., zapata, J., Marulanda, M. and López, A. (2012). Acta Agronómica. Caracterización de la resistencia a la antracnosis causada por *Glomerella cingulata* y productividad de cinco genotipos de mora (*Rubus glaucus* Benth.), 62(2323-0118), pp.174-185.