

UNIVERSIDAD AUTÓNOMA AGRARIA ANTONIO NARRO
SUBDIRECCIÓN DE POSTGRADO



ANÁLISIS MEDIANTE TÉCNICAS DE SEGMENTACIÓN DE IMÁGENES DE
HOJAS DE PEPINO (*Cucumis sativus*) INFESTADAS CON CENICILLA
(*Sphaerotheca fuliginea*).

Tesis

Que presenta RODRIGO MORALES GARCÍA

como requisito parcial para obtener el Grado de:
MAESTRO EN CIENCIAS EN HORTICULTURA

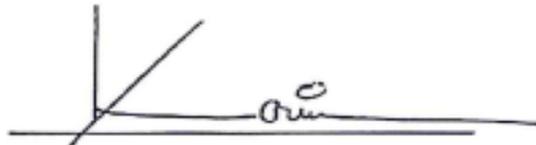
Saltillo, Coahuila.

Septiembre 2019

ANÁLISIS MEDIANTE TÉCNICAS DE SEGMENTACIÓN DE IMÁGENES DE
HOJAS DE PEPINO (*Cucumis sativus*) INFESTADAS CON CENICILLA
(*Sphaerotheca fuliginea*).

Tesis

Elaborada por RODRIGO MORALES GARCÍA como requisito parcial para
obtener el Grado de MAESTRO EN CIENCIAS EN HORTICULTURA con la
supervisión y aprobación del Comité de Asesoría



Dr. Karim de Alba Romenus

Asesor Principal



Dr. Antonio Juárez Maldonado

Asesor



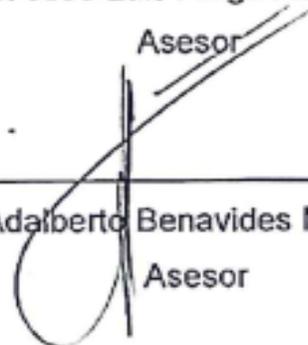
Dr. José Luis Fraga Almazán

Asesor



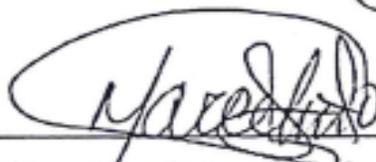
Dra. Susana González Morales

Asesor



Dr. Adalberto Benavides Mendoza

Asesor



Dr. Marcelino Cabrera De la Fuente

Subdirector de Postgrado UAAAN

AGRADECIMIENTO.

A mi **UNIVERSIDAD AUTÓNOMA AGRARIA ANTONIO NARRO** por ser mi casa de estudio y darme la oportunidad de formalizarme de manera profesional para poder ser alguien en la vida competente.

Al **Dr. Karim de Alba Romenus** por compartirme su conocimiento y profesionalismo durante el trabajo de investigación en el cual me permitió ser parte de él, por su comprensión y experiencia dedicado hacia mí.

Al **Dr. Antonio Juárez Maldonado** por la importancia que le dedico al proyecto de investigación y el conocimiento que me impartió durante toda esta etapa.

A la **Dra. Susana Gonzales Morales** por su importante y valiosa orientación y consejos que sirvieron para fortalecer este trabajo.

A la **Dr. Adalberto Benavides Mendoza** por su importante y valiosa orientación y consejos que sirvieron para fortalecer este trabajo.

A mis compañeros y amigos de la carrera de la generación CXXIII, por brindarme su amistad y compañerismo cada vez que lo necesitaba.

A mis amigos por estar siempre que los necesito ya que me ayudaron con el trabajo de investigación, los quiero mucho a todos.

DEDICATORIAS.

A mi familia:

Mis padres

A mi madre la Sra. **Jesús Emilia García Vega** por estar conmigo en los mejores y peores momentos, por siempre creer en mí y cuando no tenía a quien acudir, sabía que podía contar contigo, cuando todos los caminos se cerraban, tu puerta era la única siempre abierta y cuando todo se ponía difícil ahí estabas tú a mi lado diciéndome que todo saldría bien. Gracias Mamá por todo lo que hiciste y por todo lo que serias capaz de hacer si te lo hubiera pedido, sin ti no sería quien soy actualmente todo te lo debo a ti.

A mi padre el **Sr. Oscar Rene Morales Vargas** muchas gracias papá porque tus consejos me ayudan a tomar las decisiones correctas, porque tu esfuerzo ha hecho que no me falte nada y porque tu amor me ha enseñado a amar a los que me rodean.

Mis hermanos

Israel por estar en los momentos en los que te necesito y por confiar en mí, por ayudarme cada vez que te necesitaba y darme palabras de aliento al hablar contigo.

Juan de Dios por dedicarme tiempo en esas pláticas sobre los momentos que hemos vivido y la confianza que deposita en mí y por hacerme reír con sus tonterías.

Everardo por su apoyo, por estar ahí en todo momento y darme consejos cada vez que los necesitaba, los quiero muchos hermanos.

A mis abuelitas **Praxedis** y **Rosalinda**, a toda mi familia por creer en mi los quiero a todos.

ÍNDICE GENERAL

AGRADECIMIENTO	iii
DEDICATORIAS	iv
RESUMEN	x
ABSTRACT	xi
i	
INTRODUCCIÓN	1
OBJETIVOS	2
Objetivo general.	2
Objetivos específicos.	3
HIPÓTESIS	3
REVISIÓN DE LITERATURA	4
Representación digital de una imagen.	4
Definición de procesamiento y análisis digital de imágenes.....	5
Mejora de la imagen.....	6
Restauración de la imagen.....	8
Compresión de imágenes.....	9
Segmentación	11
Proceso de segmentación	12
Métodos de segmentación por la respuesta espectral	13
Índices de vegetación (Índices cromáticos).....	14
Umbralización.....	16
Segmentación basada en aprendizaje	16
Aplicaciones de la segmentación de imágenes digitales.....	18
Histogramas.	18
Propiedades del color.....	19

Modelos RGB	19
Modelo HSV.	21
Modelo de color ExG y ExR.	22
Modelo de color HSI	22
Modelo de color YUV	23
Modelo de color YD _B D _R	24
K-medias.	25
Uso de K-medias.....	26
Escala de grises.	26
Conversión de RGB a escalas de grises.....	27
Matrices convolucionales.	27
Procesamiento digital de imágenes.....	28
Aplicación de análisis de imágenes en agronomía.....	29
Importancia de la detección del hongo en el cultivo de pepino.	31
MATERIALES Y MÉTODOS.	32
Toma de fotografía.	32
Preprocesamiento manual de fotografías.....	32
Binarización en escala de grises.	33
Binarización en base al modelo de color RGB.	33
Filtrado mediante un filtro promedio.	34
Filtrado mediante una matriz de convolución.	35
Algoritmo k-medias.....	35
Definición del algoritmo K-medias.	36
Partición de datos.....	37
Detección de falsos positivos.	37

Procesamiento de fotografías en MatLab.....	37
Evaluación de la exactitud de las técnicas.....	38
RESULTADOS Y DISCUSIÓN.....	41
Evaluación de la exactitud de las técnicas.....	49
Falsos positivos.....	50
CONCLUSIONES.....	52
REFERENCIAS.....	54

LISTA DE CUADROS

Cuadro 1. Porcentaje de daño por cenicilla en hojas de pepino detectados por el método de binarización en escala de grises, modelo RGB y el algoritmo K-medias durante dos ciclos de cultivo.	45
Cuadro 2. Porcentajes mínimos y máximos de falsos positivos detectado por el método de binarización en escalas de grises, modelo RGB y el algoritmo K-medias en hojas sanas para ambos ciclos.	50

LISTA DE FIGURAS.

Figura 1. Representación digital de una imagen.	5
Figura 2. Mejora de la imagen.	8
Figura 3. Restauración de imagen con CLS.	9
Figura 4. Compresión de imagen utilizando el código Huffman.	11
Figura 5. Segmentación de imagen utilizando umbralización en escala de grises.	12
Figura 6. Etapas del procesamiento digital de una imagen.	13
Figura 7. Histograma de imagen en escala de grises.	18
Figura 8. Modelo de color RGB.	19
Figura 9. Ejemplo de la configuración del Modelo de color RGB.	20
Figura 10. Transformación del espacio de color RGB al HSV.	21
Figura 11. Modelo de color HSI. (a) Hue, (b) Saturation y (c) Intensity.	23
Figura 12. Modelo de color YUV.	24
Figura 13. Agrupamiento según K-medias.	25
Figura 14. Conversión de color a escalas de grises.	27
Figura 15. Matrices convolucionales más usadas en el análisis de imágenes digitales.	28
Figura 16. Esquema general de los algoritmos.	40
Figura 17. Binarización en escala de grises de hoja de pepino del ciclo marzo- junio. A) Hoja infectada con cenicienta con fondo rojo. B) Imagen en escala de gris. C, D) Postprocesamiento de imagen para eliminación de ruido.	42
Figura 18. K-medias en hojas de ciclo marzo-junio. A) Imagen original. B) Agrupamiento en capa Roja. C) Agrupamiento en capa Verde. D) Agrupamiento en capa Azul. E) Agrupamiento de las capas RGB.	44
Figura 19. Binarización en base al modelo de color RGB de hoja de pepino del ciclo junio-septiembre. A) Hoja infectada con cenicienta con fondo rojo. B) Después de seleccionar pixeles cenicienta. C) Después del fspecial-imfilter a color. D) Después de la matriz convolucional.	47
Figura 20. Registros de casos de cenicienta (marzo-junio).	48
Figura 21. Registros de casos de cenicienta (junio-septiembre).	48

RESUMEN

ANÁLISIS MEDIANTE TÉCNICAS DE SEGMENTACIÓN DE IMÁGENES DE
HOJAS DE PEPINO (*Cucumis sativus*) INFESTADAS CON CENICILLA
(*Sphaerotheca fuliginea*).

POR

RODRIGO MORALES GARCÍA

MAESTRÍA EN CIENCIAS EN HORTICULTURA
UNIVERSIDAD AUTÓNOMA AGRARIA ANTONIO NARRO

DR. KARIM DE ALBA ROMENUS – ASESOR-

SALTILLO, COAHUILA

SEPTIEMBRE 2019

En este documento, se propone el reconocimiento de cenicilla (*Sphaerotheca fuliginea*) en hojas de pepino (*Cucumis sativus*) basado en un método de procesamiento de imágenes y visión por computadora. A fin de investigar esta enfermedad es conveniente utilizar imágenes capturadas con dispositivos fotográficos por la abundancia y diversidad de dichos dispositivos. Para llevar a cabo el trabajo se establecieron dos ciclos de cultivo de pepino que se infestó con cenicilla. A medida que se desarrollaba la enfermedad se tomaron fotos para realizar el análisis. Se segmentaron las imágenes mediante las técnicas de binarización umbralizada utilizando tres métodos, binarización en escala de grises, binarización utilizando el método de color RGB y un algoritmo de k-medias con centroides inicialmente localizados para la detección de la enfermedad, se comparan los resultados entre los diversos métodos. La binarización analizada sobre la escala de grises permitió localizar la enfermedad en base a un porcentaje de los tonos más claros al igual que la binarización con el modelo de color RGB, aunque este último método analiza en cada una de sus capas previamente disociadas, el algoritmo k-medias identificó grupos con características similares que la imagen presentaba a partir de los centros proporcionados. También se realizó un análisis de detección de falsos positivos para todos los métodos con 25 fotografías previamente procesadas. Los resultados experimentales muestran que el método de binarización en escalas de grises propuesto programado en MatLab® presenta mejores resultados para el reconocimiento de la enfermedad que los demás métodos.

Palabras clave: Segmentación, Binarización, RGB, Gris, K-medias.

ABSTRACT

ANALYSIS BY MEANS OF SEGMENTATION OF IMAGES TECHNIQUES OF
CUCUMBER LEAVES (*Cucumis sativus*) INFECTED WITH POWDERY MILDEW
(*Sphaerotheca fuliginea*).

BY

RODRIGO MORALES GARCÍA

MASTER OF SCIENCE IN HORTICULTURE
UNIVERSIDAD AUTÓNOMA AGRARIA ANTONIO NARRO.

DR. KARIM DE ALBA ROMENUS – ASESOR-

SALTILLO, COAHUILA

SEPTIEMBRE 2019

In this document, we propose the recognition of powdery mildew (*Sphaerotheca fuliginea*) in cucumber leaves (*Cucumis sativus*) based on image processing and computer vision methods. In order to gain insight into this disease, it is convenient to use images captured with photographic devices due to the abundance and diversity of such devices. To carry out the work, two cucumber cycles were established and infested with powdery mildew. As the disease developed, photos were taken to perform the analysis. The images were segmented using three threshold binarization techniques: gray scale binarization, RGB binarization and K-means algorithm with initially located centroids. The results were compared between the different methods. The gray scale binarization as well as the RGB binarization allowed locating the disease based on a percentage of the lighter shades, although the latter method analyzes each one of the different color layers. The K-means algorithm identified groups with similar characteristics around provided centers. A false positive detection test was also performed for all methods with 25 previously processed photographs. The experimental results show that the proposed gray scale binarization method programmed in MatLab® presents better results for the recognition of the disease than the other methods.

Keywords: Segmentation, Binarization, RGB, Gray, K-means.

INTRODUCCIÓN

Cenicilla (*Sphaerotheca fuliginea*) es un hongo de importancia para el cultivo de pepino (*Cucumis sativus*) producido bajo invernadero y campo abierto por su fuerte efecto de patogenicidad ya que causa una gran pérdida de rendimiento (Fan *et al.*, 2014; Juárez *et al.*, 2012). Los hongos causan estrés biótico aumentando la producción de especies reactivas de oxígeno (ROSs) llevando a un estrés oxidativo (Horbach *et al.*, 2011). Dicho estrés conlleva a la muerte celular por peroxidación lipídica, daño al ARN y ADN, a enzimas clave o la oxidación de las proteínas (Jajic *et al.*, 2015; Shahid *et al.*, 2017). La cenicilla es un hongo no vascular que presenta crecimiento y proliferación de estructuras en el área inmediata donde se dispone la espora sobre la hoja (Kiss *et al.*, 2010). Por tal razón, los esfuerzos para el control del hongo se hacen directamente sobre el área infectada con aplicaciones foliares (Liu *et al.*, 2010; Pérez-Ángel *et al.*, 2010). Lo lamentable es que las alternativas de control resultan ser en ocasiones costosas y muy dañinas para el medio ambiente (Chen y Ying, 2015; Kim *et al.*, 2010).

La producción en invernaderos necesita de más equipos y maquinas especializadas y automatizadas para satisfacer necesidades de rendimiento y monitoreo de enfermedades (Comba *et al.*, 2010). Actualmente en la agronomía se trabaja con análisis de imágenes para la detección de enfermedades como un esfuerzo para la automatización de invernaderos (Lee *et al.*, 2017; Chad DeChant *et al.*, 2016; Pryzant *et al.*, 2017). Uno de los análisis utilizado es la segmentación la cual divide una imagen en regiones basándose en la clasificación de cada uno de sus píxeles componentes, por ejemplo el color (Angulo y Serra, 2005). La técnica de umbralización (T) es uno de los métodos más importantes de los que se auxilia a segmentación de imágenes (Kaur *et al.*, 2012). El umbral es una función que convierte una imagen con diferentes tonalidades en una imagen en blanco y negro (Al-amri *et al.*, 2010).

Por otra parte, utilizar el algoritmo K-medias a resultado adecuado para resolver problemas en la identificación de regiones de interés como la de localización de

enfermedades en cultivos (Al Bashish *et al.*, 2011; Dhanachandra *et al.*, 2015). Este algoritmo nos permite detectar áreas mediante a la agrupación de las características que la imagen presenta (Yong *et al.*, 2010). Utilizando grupos y centros adecuados para generar mejores resultados sin causar errores o identificaciones innecesarias (Celebi *et al.*, 2013). El algoritmo trabaja a partir de la identificación de centroides y posteriormente realiza un análisis de las características vecinales de los píxeles de la imagen con lo cual realiza la segmentación por grupos (Celebi *et al.*, 2013; Jain, 2010; Yong *et al.*, 2010).

El problema de la segmentación por binarización puede reducirse a encontrar un valor adecuado de umbral. En esta investigación se utilizaron dos técnicas de segmentación por binarización, uno segmentando en imágenes analizadas en escala de grises, otro segmentando con base a las capas que nos proporciona el modelo de color RGB y se utilizó el algoritmo K-medias con centroides localizados para la búsqueda de grupos de interés al problema. A fin de obtener un umbral adecuado se analizó el histograma de la imagen para detectar el valor más claro de la misma. La cenicilla como enfermedad es una especie de hongo que produce manchas de color gris y en forma de algodoncillo sobre la hoja, de tal manera que una forma de detectarla es a partir del color más claro y tomando como margen inferior un determinado porcentaje. Se detectaron áreas con afectación de cenicilla en hojas de pepino en 200 imágenes tomadas en dos ciclos de cultivos (marzo-junio y junio-septiembre, 2018) producidos bajo invernadero.

OBJETIVOS

Objetivo general.

Identificación de los daños ocasionados por Cenicilla (*Sphaerotheca fuliginea*) en hojas de pepino mediante la segmentación de imágenes digitales.

Objetivos específicos.

1. Elaborar un programa usando MATLAB® para la segmentación de imágenes digitales de hojas de pepino afectadas por cenicilla.
2. Determinar el valor del umbral para la segmentación con las técnicas de binarización en escala de grises, binarización en modelo de color RGB y con la técnica de K-medias.
3. Identificar hojas dañadas por presencia de cenicilla.
4. Obtener el área afectada por cenicilla en las hojas de pepino a fin de obtener el porcentaje de daño ocasionado por el hongo.

HIPÓTESIS.

Es posible detectar, mediante la segmentación de imágenes digitales y usando como umbral los colores más claros en las hojas de pepino afectadas por el hongo cenicilla y conocer el porcentaje de afectación de dicha enfermedad en la hoja determinada por las técnicas de binarización en escala de grises, binarización en modelo de color RGB y la técnica de K-medias.

REVISIÓN DE LITERATURA.

Representación digital de una imagen.

La discretización es el proceso que representa a una imagen analógica en forma aproximada por una serie de muestras igualmente espaciadas (Leijenaar *et al.*, 2015). Una imagen digital es la discretización tanto en coordenadas como en tonos de gris de una imagen analógica (Molina *et al.*, 2016). La imagen está definida por la función $f(x, y)$, donde el valor de f en (x, y) es conocido como intensidad o nivel de gris de la imagen en ese punto y los valores x y y son coordenadas espaciales (Balaguer *et al.*, 2010). Se habla de una imagen digital cuando x , y y los valores de f son cantidades finitas y discretas (Korobiichuk *et al.*, 2016). De tal manera que un número finito de elementos que tienen valor particular y posición definen totalmente a una imagen digital (Wang y Wang, 2014). Estos elementos son conocidos como pels, elementos de la imagen o píxeles (Pan, 2011).

El uso de coordenadas representan las posiciones de los píxeles de una imagen digital (Langerholc *et al.*, 2013). Por convención el origen de la imagen se encuentra en el extremo izquierdo superior, denotado por la coordenada $(x,y) = (0,0)$, que indica que se encuentra en el primer renglón y en la primera columna (Blaber *et al.*, 2015). La siguiente coordenada del primer renglón es $(x,y) = (0,1)$, así hasta llegar al píxel finito de la imagen, como se muestra en la Figura 1.

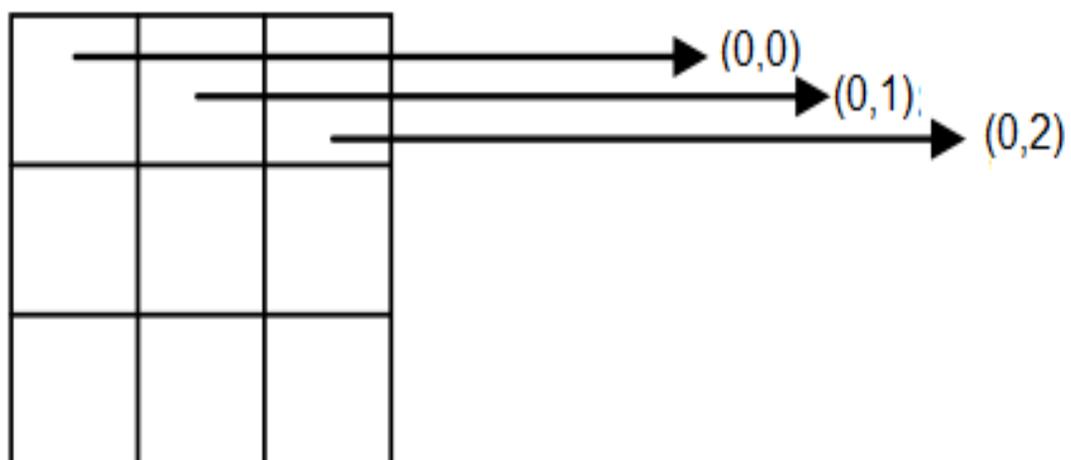


Figura 1. Representación digital de una imagen.

Definición de procesamiento y análisis digital de imágenes.

Al área de la ingeniería que se dedica al análisis y a la manipulación de la información por medio de un procesador que puede contener una imagen digital se le llama análisis y procesamiento digital de imágenes (Cheddad *et al.*, 2010). El análisis digital de imágenes se encarga de la extracción de mediciones, datos o información contenida en una imagen (Hall *et al.*, 2010). Su principal objetivo es facilitar la búsqueda e interpretación de información contenidas en las imágenes a través de diferentes técnicas de análisis digital (Cheddad *et al.*, 2010; Hall *et al.*, 2010).

Un sistema de análisis de imágenes se distingue debido a que tiene como parámetro de entrada una imagen y cuyo producto es comúnmente una salida numérica, en lugar de otra imagen (Samretwit y Wakahara, 2011). Esta salida es información, en la mayoría de los casos estadística, referente al contenido de la imagen de entrada (Kim y Kim, 2013).

Por otra parte, las técnicas que se aplican a las imágenes digitales con el principio de mejorar su calidad se le llama procesamiento de imágenes digitales (Fontana *et al.*, 2012). Engloba una serie de técnicas que comprenden operaciones donde el origen es una imagen y el resultado final es otra imagen ya procesada (Roman-Gonzalez *et al.*, 2012). El valor del píxel en la imagen de salida puede estar en función de los valores de sus vecinos, del valor de todos

los puntos de la imagen o del valor que tenía en la imagen de entrada (Palomino *et al.*, 2010).

El término específico es importante, porque establece que el valor del resultante este en función del problema que se trata. De esta manera, un método que es útil para realzar un determinado tipo de imágenes puede no serlo para otras (Méndez-Vázquez *et al.*, 2012).

El procesamiento y análisis de imágenes se ha desarrollado en respuesta a tres de los más grandes problemas concernientes a imágenes (Cuevas y Ortega, 2013):

1. Descripción y segmentación de imágenes para una etapa inicial de visión robótica.
2. Mejora y restauración de una imagen para interpretar más fácilmente su contenido sobre una superficie.
3. La digitalización y codificación de imágenes que facilite la transmisión, impresión y almacenamiento de las mismas.

La mayoría de las técnicas de procesamiento y análisis de imágenes entran dentro de la clasificación que se resume en (Maini y Aggarwal, 2010):

- Mejora de la imagen.
- Restauración de la imagen.
- Compresión de imágenes.
- Segmentación.

Mejora de la imagen

En el tratamiento de imágenes digitales la mejora de la imagen es el conjunto de técnicas más utilizadas y también más sencillas (Maini y Aggarwal, 2010). Durante el proceso, el objetivo principal es mejorar la calidad de la imagen con la finalidad de que el resultado sea más adecuado para una aplicación en específico, ayudando a destacar las características de interés de la imagen (Zhang *et al.*, 2013).

El resultado obtenido de una técnica empleada en la mejora de una imagen es evaluado mediante un criterio subjetivo; es decir, el encargado de determinar

cuánto una técnica ha mejorado cierto aspecto de una imagen es un experto en la materia mediante la inspección de los resultados (Barbedo, 2013). Las técnicas de mejora de la imagen son aquellos algoritmos de procesamiento de imágenes destinados a resaltar, agudizar y/o contrastar determinados aspectos de la imagen (Fridrich y Kodovsky, 2012). Por otra parte, ayudan a eliminar efectos no deseados sobre ellas, como toda clase de ruido (aditivo, sustractivo, multiplicativo, etc.), afinando sus características (Denemark, 2014).

Es importante destacar que al utilizar algoritmos de mejora de la imagen se deben considerar los siguientes aspectos (Alaghi, 2013; Denemark, 2014):

- Muchos de estos algoritmos suelen ser utilizados para formar parte de otros algoritmos de procesamiento de imágenes más complejos.
- La valoración de los resultados es subjetiva, debido a que no existe un criterio para saber que tanto se mejoró la imagen original, por lo regular se emplean varias pruebas sobre la imagen hasta obtener los resultados más adecuados.
- No se añade información nueva que no esté presente en la imagen. Tan solo se resalta la información existente, para que pueda ser apreciada de mejor manera por el ojo humano.

El conjunto de algoritmos de mejora de imagen comúnmente es dividido en dos grandes grupos (Alaghi, 2013; Denemark, 2014):

1. **Algoritmos en el dominio de la frecuencia.** Frecuentemente, estos métodos son aplicados sobre los crecientes resultantes de la Transformada de Fourier de una imagen.
2. **Algoritmos en el dominio espacial.** Se refiere a métodos que procesan una imagen pixel por pixel, y en ocasiones tomando en cuenta un conjunto de píxeles vecinos.

La Figura 2 muestra imágenes procesadas a través del software Image J 1.43u. Este software modifica las imágenes ya adquiridas agregando el ruido a partir de la desviación estándar para generar las imágenes simuladas a diferentes valores de mAs (Brooks y Miller, 2012).

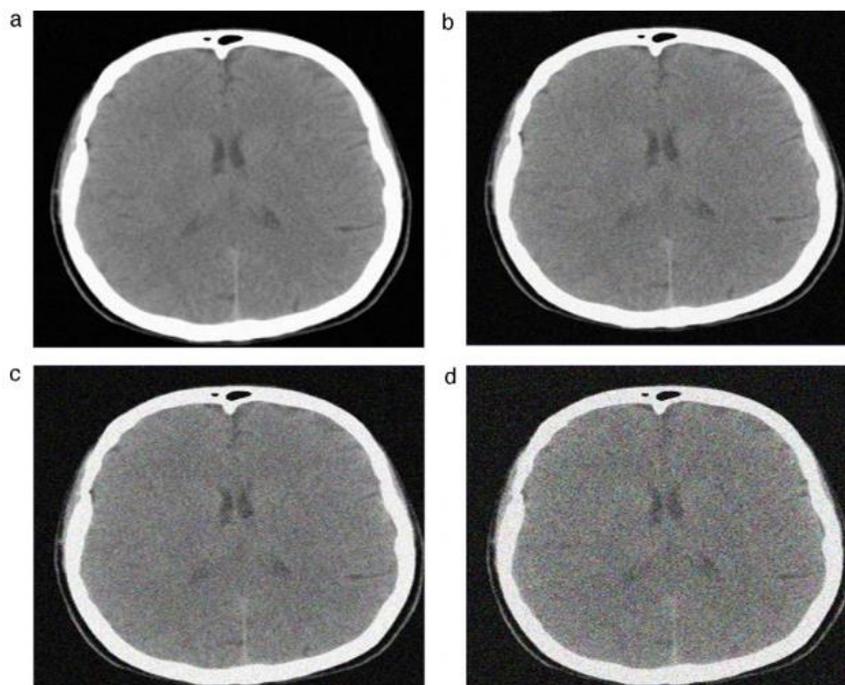


Figura 2. Mejora de la imagen.

Restauración de la imagen

Estas técnicas tienen por objetivo corregir la degradación sufrida por una imagen (Arbace *et al.*, 2013). Utilizar la restauración de la imagen es debido a que en algunas ocasiones estas suelen ser distorsionadas al desplazar la posición de los píxeles varias posiciones de su posición original o degradadas al alterar los niveles de gris de cada pixel (López-Rubio, 2010). En general, las imágenes pueden ser degradadas debido a las siguientes razones (Xiao *et al.*, 2011):

- Imperfección en el sistema de captura de la imagen.
- Degradaciones sobre la imagen generadas por movimientos relativos entre la cámara de captura y el objeto
- Degradación debida a condiciones atmosféricas.
- Imperfección en el canal de transmisión de la imagen.

Al igual que la mejora de la imagen, la restauración de la imagen incluye un conjunto de técnicas de procesamiento que busca obtener mejoras en las imágenes (Qian *et al.*, 2011). Aunque en la restauración de la imagen se requiere definir un criterio objetivo para valorar la calidad de la imagen

resultante comparado a las técnicas de mejora de la calidad, las cuales basan la evaluación de sus resultados en procedimientos heurísticos y criterios personales (Schmidt y Roth, 2014).

En la Figura 3, se ilustran como ejemplo los parámetros de regularización seleccionados para el método de reconstrucción con mínimos cuadrados restringidos (CLS) (Castillo *et al.*, 2014). En la sección de la derecha se puede observar una sección especial para configurar el modelo de mejoramiento/reconstrucción de la imagen óptica, la sección de la izquierda es la imagen degradada.

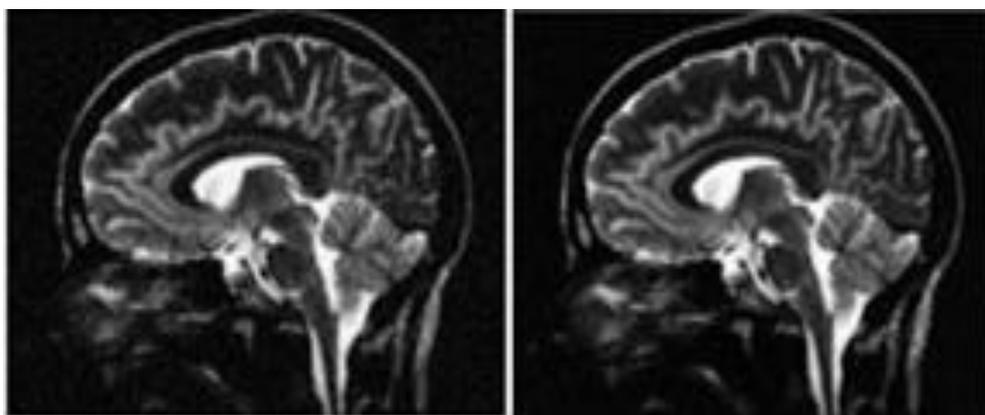


Figura 3. Restauración de imagen con CLS.

Compresión de imágenes

La compresión de una imagen tiene por objetivo reducir la cantidad de bits que ocupa dicha imagen en su representación (Kirchner y Fridrich, 2010). La forma más comúnmente utilizada para la compresión de imágenes es si después de la compresión existe pérdida de información o si la información se mantiene (Stamm y Liu, 2011). Diferenciando de esta manera los métodos de compresión en sus técnicas: métodos de compresión con pérdida de información y métodos de compresión sin pérdida de información (Chowdhury y Khatun, 2012).

El proceso es reversible cuando una imagen es comprimida usando el método de compresión sin pérdida de información pero utilizando esta técnica la relación de compresión alcanzada no es significativa (Heinz y Wiggins, 2010). Es posible recuperar la imagen original previa al proceso de compresión a partir de la representación de la imagen en forma compacta (Stamm *et al.*, 2010).

Por otra parte, un proceso irreversible es utilizado un método de compresión con pérdida de información, es decir, al aplicar el proceso inverso la imagen recuperada no representará idénticamente a la imagen original (Chen y Chuang, 2010). Estos métodos poseen la ventaja de permitir factores de compresión elevados y posiblemente las pérdidas que el ojo humano logre captar al ver ambas imágenes sean nulas (Lo y Hu, 2014). Para el procesamiento de imágenes y video, es recomendable utilizar los métodos de pérdida de información. La compresión de datos es el proceso de reducción del volumen de datos necesarios para representar una determinada cantidad de información eliminando la proporción de datos que contienen información sin relevancia (Kang *et al.*, 2011). Los datos con información sin relevancia, son conocidos como datos de redundancia (Nilesh *et al.*, 2013). La redundancia de datos es un término importante en la compresión digital de imágenes, donde se han identificado tres tipos de redundancias (Makbol y Khoo, 2013):

1. Redundancia de codificación.
2. Redundancia entre píxeles; también conocida como redundancia espacial, es la única que entra dentro del procesamiento y análisis de imágenes.
3. Redundancia psicovisual.

La compresión de datos se consigue cuando una o más de estas redundancias se reduce o elimina (Gupta y Choubey, 2015).

La Figura 4 es de tamaño 512×768 píxeles para un total de $512 \times 768 = 393,216$ píxeles o $393,216 \times 8 = 3,145,728$ bits se aplicó el código de Huffman para esta imagen pudiendo comprimir el tamaño de almacenamiento y utilizar 3,033,236 bits o aproximadamente 7,714bpp (Lezama, 2017). Lo que representa un pequeño ahorro en la cantidad de bits a guardar.



Figura 4. Compresión de imagen utilizando el código Huffman.

Segmentación

A la técnica matemática que consiste en dividir en un conjunto de datos, en este caso a la imagen, en subconjuntos llamados regiones o zonas que comparten alguna propiedad se le denomina segmentación (Martin Sotoca, 2017). La segmentación es un concepto usado en el tratamiento digital de una imagen. La segmentación de una imagen implica la detección, mediante procedimientos de etiquetado determinista o estocástico, construyendo un modelo con los valores digitales de la imagen en respuesta de la visión humana (Padrón-Pereira, 2013; Angulo y Serra, 2005).

Los elementos de una distribución digital de este tipo se denominan elementos de la imagen o más comúnmente píxeles (Palomino y Concha, 2009).

Las técnicas de segmentación pueden darse mediante agrupamiento de píxeles, en algún espacio de colores de acuerdo a una o más características, o usando el píxel como referencia para la segmentación de los algoritmos que usan agrupamiento difuso en los espacios de color (Angulo y Serra, 2005; Martin Sotoca, 2017). Éstas pueden ser basadas en el área, ya sea por crecimiento de regiones o por división y combinación de regiones, o bien, segmentación basada en orillas, la cual se divide en técnicas locales o globales (Palomino y Concha, 2009; Báez Rojas *et al.*, 2004).

En la Figura 5 se observa el proceso de segmentación por umbralización de niveles de grises, en la izquierda se muestra la imagen original Geostationary

Operational Environmental Satellites (GOES), en el centro la imagen en escala de grises y en la derecha la imagen segmentada (Gómez *et al.*, 2013).

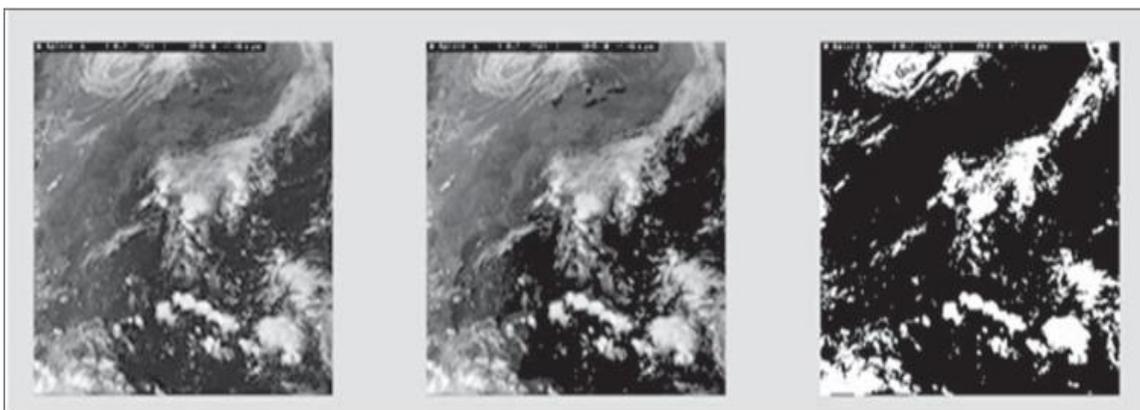


Figura 5. Segmentación de imagen utilizando umbralización en escala de grises.

Proceso de segmentación

Según Palomino y Concha (2009), el proceso de la segmentación consta de seis pasos requeridos para el proceso, la obtención de resultados y finalmente la toma de decisiones con los resultados obtenidos, estos pasos se describen a continuación.

1. Adquisición de la imagen.
2. Preprocesamiento, con la finalidad de: a) mejora de contraste, b) eliminación de ruido y la restauración.
3. La segmentación, dónde la imagen se divide en sus partes constituyentes u objetos.
4. Descripción o extracción de características.
5. Reconocimiento, que implica asignar significado a un conjunto de objetos reconocidos.
6. Base de conocimiento.

Las etapas del procesamiento digital de una imagen se muestran en la Figura 6 (Palomino y Concha, 2009).

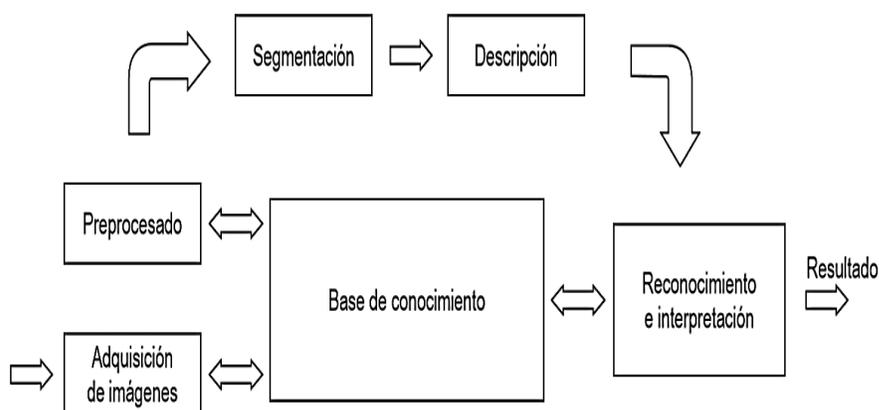


Figura 6. Etapas del procesamiento digital de una imagen.

Métodos de segmentación por la respuesta espectral

La segmentación de imágenes trata de descomponer una imagen en las partes que la constituyen, es decir, los objetos de interés y el fondo, esto se realiza a partir de unas características locales (Chakrabarti y Zickler, 2011). La mayoría de las imágenes están constituidas por regiones o zonas que tienen características homogéneas (Drăguț *et al.*, 2010). La umbralización es el método más simple para la segmentación de una imagen (Vala y Baxi, 2013). El objetivo de la segmentación es cambiar y/o simplificar la representación de la imagen de forma que la nueva imagen sea más significativa y resulte más fácil de analizar (Chakrabarti y Zickler, 2011; Vala y Baxi, 2013).

A partir de una imagen en escala de grises se puede utilizar la umbralización para crear imágenes binarias (Hu *et al.*, 2008). Gée *et al.* (2008) propusieron aplicar un umbral sencillo determinado a partir del valor medio proporcionado por el histograma de la imagen en niveles de gris, de tal manera que después del análisis el fondo de la imagen (lo que no es cultivo o hierba) aparece en color negro y las partes vegetales aparecen en color blanco.

Actualmente se está utilizando las imágenes satelitales o implementación de drones para obtener imágenes de grandes dimensiones de terreno en poco tiempo (Bhandari *et al.*, 2014).

Aunque se han implementado diversos métodos de segmentación de imágenes con diversas propiedades en diversas áreas, en la agronomía aún existe sesgo de error grande al poder identificar los problemas agrícolas (Fallah *et al.*, 2013). Con el objetivo de segmentar la capa vegetal al analizar las imágenes de los cultivos se han desarrollado diversas técnicas (Singh y Misra, 2017), las cuales se pueden clasificar en los siguientes grupos:

1. Basadas en índices cromáticos (relativos al espectro visible).
2. Basadas en una umbralización específica.
3. Basadas en aprendizaje.

Índices de vegetación (Índices cromáticos)

Los índices de vegetación (VI, vegetation index) son medidas empíricas obtenidas al cuantificar y combinar dos o más bandas del espectro electromagnético, normalmente el infrarrojo cercano y la luz visible, que reflejan la vegetación (Candiago *et al.*, 2015). Con los VI se trata de obtener datos con los que caracterizar el tipo, la cantidad, el estado y la situación de la vegetación en el escenario que se quiere analizar (Peña-Barragán *et al.*, 2011). Dentro de estos índices es posible hacer una diferenciación, por un lado, están los que emplean el espectro infrarrojo cercano (NIR) y por otro los que hacen uso únicamente del espectro visible (Bendig *et al.*, 2015).

No es muy frecuente que las cámaras tengan uno o varios canales destinados a medir alguna de las bandas del espectro que ocupa el NIR, aunque sin duda existen cámaras multiespectrales e hiperespectrales que utilizan el NIR con tal propósito (Jurado-Expósito *et al.*, 2003; Peña *et al.*, 2013; de Castro *et al.*, 2012). Normalmente, las cámaras digitales están equipadas con un filtro de corte de infrarrojos, aunque se ha llegado a proponer modificar físicamente la cámara para suprimirlo y equiparla con otros que dejan pasar una amplia gama de radiaciones a partir del rojo (Rabatel *et al.*, 2014).

Por lo general, los datos de los índices en los que se utiliza alguna banda del espectro infrarrojo suelen obtenerse a partir de datos capturados por plataformas remotas, en aplicaciones de teledetección, donde estas imágenes

tienen naturaleza multispectral o hiperespectral (Bhandari *et al.*, 2012). El ojo humano no es sensible a la región NIR por tal motivo sólo somos capaces de distinguir plantas a partir del verdor que estas representan dentro de las imágenes a color, así que NIR es menos intuitivo para el humano (Sankaran *et al.*, 2013).

El Índice de Vegetación de Diferencia Normalizada (NDVI), se utiliza habitualmente para determinar cubiertas vegetales, medir el crecimiento de las plantas y controlar la producción de biomasa (Bhandari *et al.*, 2012). Se define mediante la siguiente fórmula, $NDVI = (NIR - R) / (NIR + R)$, que utiliza la componente espectral R y el NIR. El NDVI ha sido utilizado en diversos trabajos (Zarco-Tejada *et al.*, 2012; Zhang *et al.*, 2006; Perry y Davenport, 2007; Hasegawa *et al.*, 2010) y se ha demostrado que está muy relacionado con el índice de área foliar y la fracción ocupada por la cobertura vegetal (Zarate-Valdez *et al.*, 2012). Torres-Sánchez *et al.* (2013) analizaron las diferencias espectrales entre cultivos, suelo y malezas con los índices de vegetación Diferencia Normalizada Verde-Rojo (NDGRI), Vegetación de Diferencia Normalizada (NDVI) y Exceso de Verde (ExG), obteniendo con el índice NDVI una mayor separabilidad espectral entre el suelo y la vegetación.

En la literatura se han definido otros muchos índices, algunos derivados del NDVI, que para detectar la vegetación o alguna de sus propiedades utilizan el NIR. Estos índices son:

- NG (Normalized Green), NR (Normalized Red), NNIR (Normalized Near Infrared), Green-Red NDVI (GRNDVI), Green Ratio Vegetation Index (GRVI, Sripada *et al.*, 2006).
- Green Difference Vegetation Index (GDVI, Sripada *et al.*, 2006).
- Green-Blue NDVI (GBNDVI, Wang *et al.*, 2007), entre otros.

El NIR además de detectar la vegetación, a veces se utiliza para diferenciar en la vegetación los distintos tipos de plantas, e incluso para clasificar las plantas en base a alguna deficiencia nutrimental o ataque por patógenos (Mahlein *et al.*, 2013). La vegetación si posee buenas cualidades de salud refleja la mayor parte de la luz infrarroja absorbiendo la mayor parte de la luz visible que le llega

(Fiorani *et al.*, 2012). Por el contrario, si está enferma la vegetación refleja menos infrarroja y más luz visible (Sankaran *et al.*, 2010).

Umbralización

La umbralización es una técnica de segmentación más utilizada que se preocupa en calcular y definir un umbral, con el objetivo de diferenciar los objetos de interés respecto del fondo (Vala y Baxi, 2013). A partir de la transformación de una imagen de color a escala de grises, se establece un umbral a partir del cual poder decidir si un píxel es considerado como cualquier otro material o como pixel que representa a la región de interés (Karasulu y Korukoglu, 2011). De esta forma podemos generar una matriz binaria donde los píxeles que identifican la región de interés se etiquetan con el color blanco y el resto con color negro (Zhang *et al.*, 2010). En general, estas técnicas suponen la solución de un problema de segmentación de dos clases (Wang y Zhang, 2012). Las técnicas basadas en la umbralización, también utilizan un método de implementación de umbral conocido como umbral dinámico (Tavares, 2010). Este tipo de umbral no solo actúa considerando la imagen al completo sino también las regiones de vecindad (Kamdi y Krishna, 2012).

Los algoritmos de umbralización obtienen el umbral a partir de una matriz binarizada en dos clases existentes que se aplican generalmente en imágenes que han sido escalados a niveles de grises (Su *et al.*, 2010). Gebhardt y Kühbauch (2007) para lograr segmentar una imagen a color necesitaron transformar dicha imagen en escala de grises a partir del modelo de color RGB logrando así la umbralización de las imágenes analizadas.

Segmentación basada en aprendizaje

Las distintas naturalezas de las texturas están dadas por los grupos que tienden a unirse a partir de las características que las imágenes a color proporcionan (Kavitha *et al.*, 2011).

La aplicación de fuzzy o también llamado métodos borrosos han logrado considerar la integración de los píxeles, aunque estén en diferentes clases

(Ciesielski *et al.*, 2012). Lo cual genera buenos resultados al combatir el problema de pérdida de identidad de los píxeles al soparlos en clases (Ghosh y Dubey, 2013). La pérdida de identidad sucede en las zonas de cambio de texturas, donde el cambio de una región a otra es gradual, desfavoreciendo a la agrupación de los píxeles (Ciesielski *et al.*, 2012; Ghosh y Dubey, 2013).

A esta categoría fuzzy pertenece el método de segmentación agrupamiento borroso o "Fuzzy Clustering" (Gosh *et al.*, 2011). Esta técnica consigue agrupaciones que ayudan a resolver los problemas existentes durante el método de optimización que se establece durante la fase de entrenamiento de la técnica (Naz *et al.*, 2010).

Al paso de los años se ha logrado identificar a partir de la similitud de los colores los grupos de píxeles que contienen las mismas características, aunque los cambios en las regiones son graduales (Wang *et al.*, 2017). Posteriormente se definió la función a partir del espacio de color RGB, identificando a fuzzy como método de carácter natural (Pajares y Cruz, 2007).

Otras técnicas de aprendizaje no supervisado actualmente se han estado implementando, con el mismo fin de segmentar regiones de interés en imágenes transformadas a escala de grises, obtenidas mediante los índices de vegetación ExR y ExG (Meyer *et al.*, 2004). Se propuso un algoritmo de clasificación que trabaja en dos fases, en un primer análisis se extraen e identifican los colores verdes para posteriormente utilizar Fuzzy Clustering para la segmentación (Romeo *et al.*, 2013). Utilizando la intensidad de las imágenes a partir de modelo de color HSI como origen, se logró segmentar la vegetación en las imágenes contrastada del fondo utilizando el algoritmo EASA (Ruiz-Ruiz *et al.*, 2009).

Tomando como principio que el problema de la segmentación del suelo o fondo con respecto a la vegetación se puede tratar como un problema que la umbralización puede resolver, se utilizó un algoritmo de desplazamiento de la media por Zheng *et al.* (2010), obteniendo buenos resultados en la separación.

Aplicaciones de la segmentación de imágenes digitales.

El trabajo en el campo de la industrialización de alimentos llevado a cabo por Padrón-Pereira (2013), muestra la metodología utilizada para la obtención de similitudes y diferencias en las imágenes segmentadas para crear un estándar entre los tonos de color de los alimentos procesados.

En el campo de la geodesia, Ortiz (2002) mejoró los métodos ya existentes utilizando ordenación vectorial, basado en la eliminación de brillo de las imágenes y la atenuación del ruido de las mismas, basándose en sistemas de color HGV y HSI.

Histogramas.

El histograma de una imagen con niveles de gris en el rango $[0, L-1]$, es una función discreta que representa el número de píxeles que posee cada nivel de gris en la imagen, o dicho en otras palabras, es la frecuencia relativa de ocurrencia de cada nivel de gris en la imagen (Liu *et al.*, 2010; Cheddad *et al.*, 2010; Liu y Yang, 2013):

$$h(rk) = nk \quad (1)$$

donde rk es el nivel de gris y nk es el número de píxeles en la imagen que contienen dicho nivel.

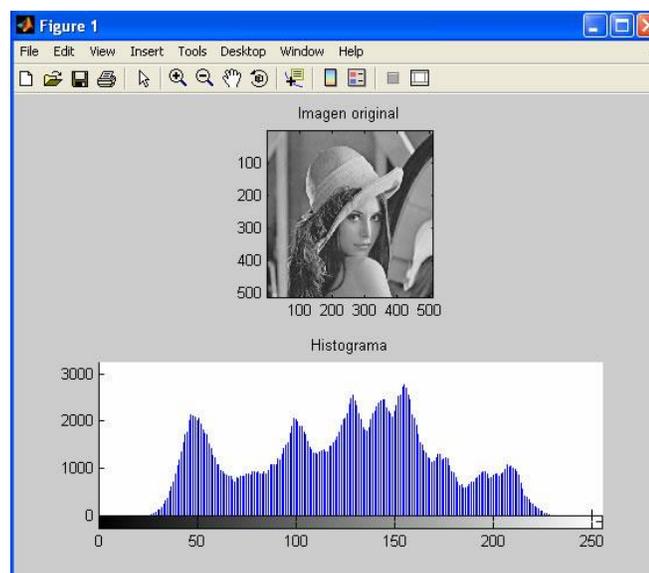


Figura 7. Histograma de imagen en escala de grises.

Propiedades del color

Un aspecto importante de la teoría del color es saber la diferencia entre el color luz (el que proviene de una fuente luminosa) y el color pigmento o color materia (óleo, témpera, lápices de color, etcétera) (Marchesotti *et al.*, 2011).

El color es definido como el fenómeno visual, que permite distinguir entre los elementos que se observan y clasifican, es la adición empleando puntos de color rojo, verde y azul, la suma de los tres colores es blanco y la ausencia de ellos es negro (los Santos, 2010; Verdú, 2001).

Modelos RGB

Tres son los valores que pueden representar un color con gran aproximación al analizar una imagen digital debido a la respuesta de tres diferentes sensores o fotorreceptores en la salida de una cámara digital (Cheddar *et al.*, 2010). Estos valores responden a una función de sensibilidad espectral y la distribución de la luz en el fotorreceptor (Ma *et al.*, 2012). Las respuestas originan curvas las cuales tienen picos en diferentes partes del espectro visible total, ya sea en las regiones de longitud de onda larga, mediana y corta (Verdú, 2001). Por lo tanto, la respuesta que observamos es lo que conocemos como rojo, verde y azul (modelo RGB) (Conde-Acevedo y Báez-Rojas, 2000). La relación de los colores primarios que conforman el modelo RGB se muestra en la Figura 8.

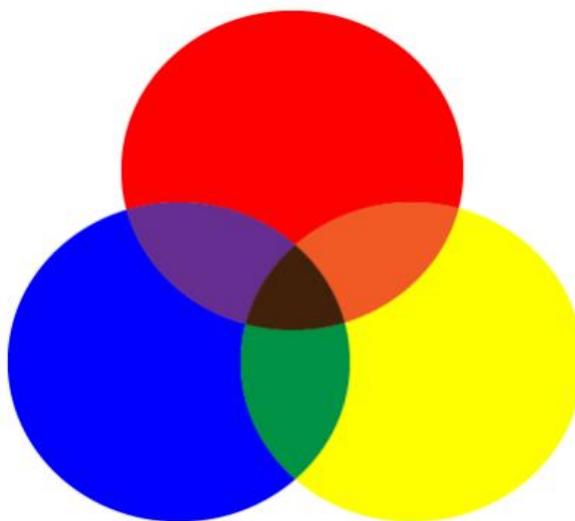


Figura 8. Modelo de color RGB.

Un modelo RGB está basado en un modelo triestímulo, en el cual, el color aparece especificado por cantidades positivas de rojo, verde y azul (Kaur *et al.*, 2010). El rango en cada coordenada o componente cromático RGB suele ser (0,1), aunque en multimedia, o sea, en imágenes digitales, se entiende en el intervalo (0,255) (Yang *et al.*, 2014). La Figura 9 muestra la configuración de rango de cada color con respecto al modelo RGB (Conde-Acevedo y Báez-Rojas, 2000).

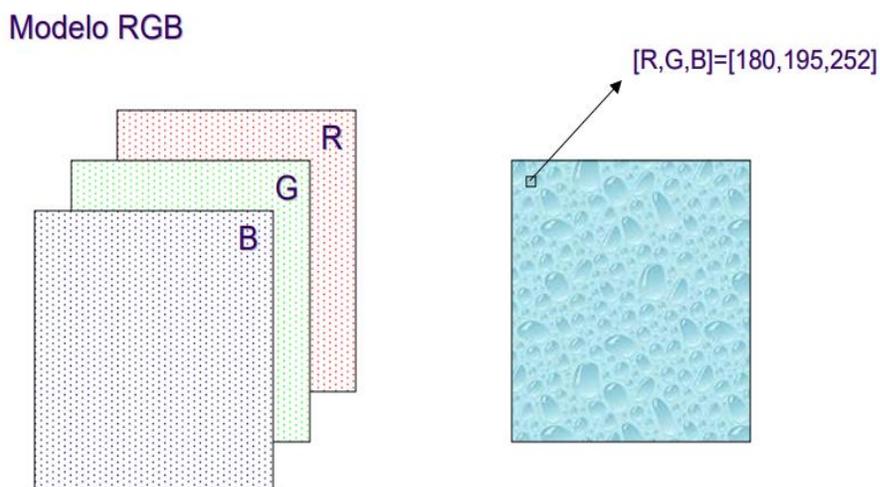


Figura 9. Ejemplo de la configuración del Modelo de color RGB.

La intensidad de cada componente se mide en una escala que va de 0 a 255. De esta manera, por ejemplo, el color rojo se obtiene con (255, 0, 0), el verde con (0, 255, 0) y el azul con (0, 0, 255) (Benito, 2005). Esto se sintetiza y muestra en la Figura 9.

Actualmente la mayoría de los equipos de captura de imágenes captan los colores principalmente por el modelo de color RGB, con tres canales incluidos, uno para cada componente del modelo (Pajares y Cruz, 2007; Gonzalez y Woods, 2007). Siendo una de las formas más sencillas de detectar la vegetación es analizando solamente los verdes presentes en la imagen sin necesidad de considerar los canales rojo y azul del espectro visible (Bendig *et al.*, 2014).

Modelo HSV.

Es un modelo basado en coordenadas polares y no cartesianas (Soleimanizadeh *et al.*, 2015). El espacio RGB tiene el inconveniente de ser un poco intuitivo para un usuario cuando tiene que especificar un color (Chernov *et al.*, 2015). Para solventar ese problema se inventó el espacio HSV, donde cada punto se corresponde a uno del espacio RGB (Basilio *et al.*, 2012), por tanto, es un espacio de color relativo a los primarios de un dispositivo (Báez Rojas *et al.*, 2004), al igual que el RGB, cada color del espacio está definido por un tono (Hue), una saturación (Saturation) y un brillo (Value) (los Santos, 2010).

Tono o matiz (H): Se corresponde con el tono de color (rojos, verdes, azules, etc.). Es un ángulo, en grados entre 0 y 360.

Saturación (S): indica el nivel de pureza del color, y varía entre 0 para todos los grises, (incluyendo al negro y blanco), y 1 para todos los colores cuyas componentes RGB tienen algún cero (máxima pureza).

Brillo (V): representa la luminosidad del color y varía entre 0 para el negro y 1 para todos los colores tales que alguna de sus componentes RGB es 1 (no pueden hacerse más brillantes).

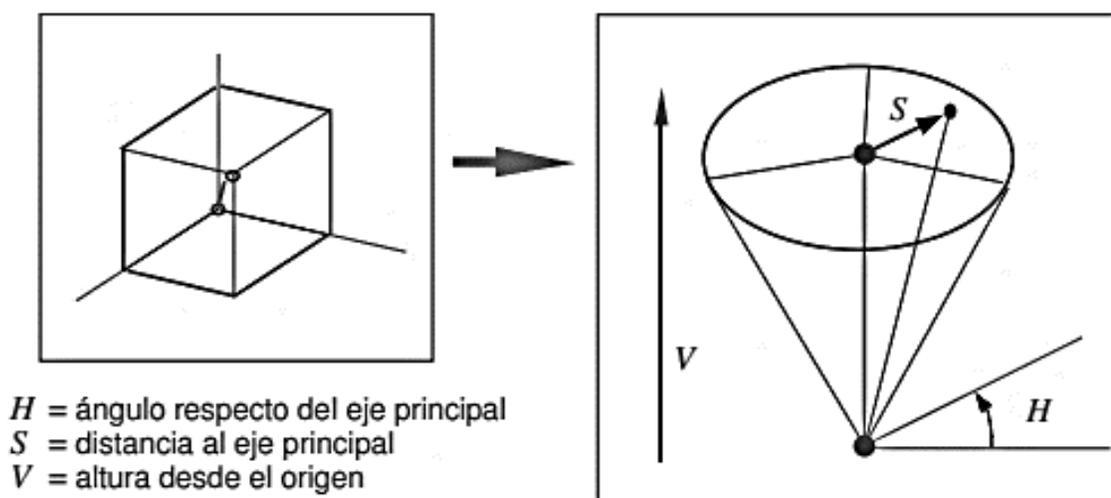


Figura 10. Transformación del espacio de color RGB al HSV.

Modelo de color ExG y ExR.

El exceso de verde es uno de los métodos más utilizados para la segmentación de plantas contrastándolas con el fondo o con alguna otra región de la imagen, debido a que el método resalta los colores verdes de la planta (Montalvo *et al.*, 2012; Ponti, 2012). Con este método se han tenido excelentes resultados como los que reporta Torres-Sánchez *et al.* (2014), donde le ayudo a discriminar el suelo de la vegetación que se encontraba dentro de la imagen. En otra investigación realizada por Soontranon *et al.* (2014) compararon ExG, NGRDI y ExG-ExR para la detección de los estadios de crecimiento de arroz donde el más sobresaliente fue ExG. El índice cromático se obtiene mediante una combinación lineal de los planos de color RGB con constantes $r = -1$, $g = 2$, $b = -1$, para este caso de resaltar el verde.

Aunque la segmentación basada en ExG a menudo proporciona resultados de segmentación pobres es aceptada generalmente como uno de los métodos más comunes y eficaces (Zhang *et al.*, 2011). Algunos trabajos de investigación han utilizado el modelo exceso de rojo ExR para el reconocimiento de falsos positivo en combinación don ExG (Guoxiang *et al.*, 2016). Como lo hicieron Shanmugam y Asokan (2015), utilizando ExG-ExR para separar las plantas del fondo debido a que en el fondo predominando colores con características rojas.

Modelo de color HSI

En el modelo HSI (Hue, Saturation, Intensity; Matiz, Saturación, Intensidad) los colores se distinguen unos de otros por su tono o matiz, saturación e intensidad (Chien y Tseng, 2011). El tono hace referencia al color dominante, la saturación es la cantidad de luz blanca mezclada con el color dominante, de modo que diferencia un color pálido de uno intenso, y en la intensidad se recoge la iluminación percibida (Shih y Liu, 2016). Este modelo se suele utilizar cuando la iluminación de la escena es determinante, y se necesita trabajar con la intensidad de la imagen (Fan *et al.*, 2016). Existe una relación de

transformación entre los modelos RGB y HSI y viceversa (Pajares y Cruz, 2007).

En la Figura 11 se observa las características del modelo de color HSI, donde:

- a) Presenta diferentes tonalidades (color dominante).
- b) Se encuentran distintas intensidades, que son representadas por esta escala de grises.
- c) Tiene variedades de saturación del color rojo.

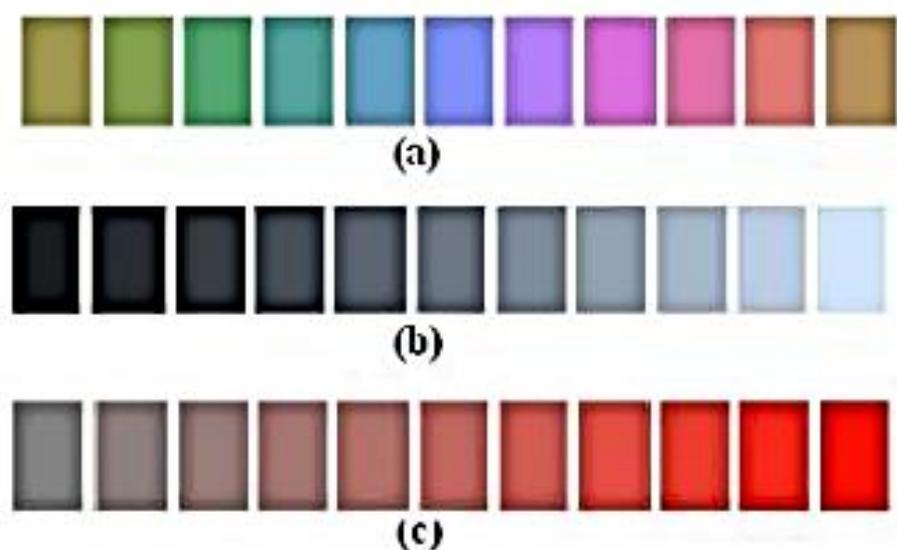


Figura 11. Modelo de color HSI. (a) Hue, (b) Saturation y (c) Intensity.

Modelo de color YUV

Este modelo es el usado por el hardware de gráficos por ordenador, se acerca más a la percepción humana del color que el estándar RGB (Hernández-Hernández *et al.*, 2016). Tiene en cuenta que la visión humana es más sensible a cambios en la intensidad de la luz que a los del color. El ojo humano no llega a apreciar el nivel razonable de error que admite (García-Lamont *et al.*, 2018). El parámetro Y representa la luminancia (información en blanco y negro), y los parámetros U y V representan la crominancia (información relacionada con el color) (Ganesan *et al.*, 2015). Permite enviar información de color independiente de la información de luminancia, este modelo se creó para garantizar el funcionamiento de los televisores en blanco y negro, cuando se codificaba la

transmisión de información de los televisores a color (Al-Tairi *et al.*, 2014). Dawson-Howe (2014) definió una relación de transformación, ya establecida de antemano, entre los modelos RGB y YUV y viceversa.

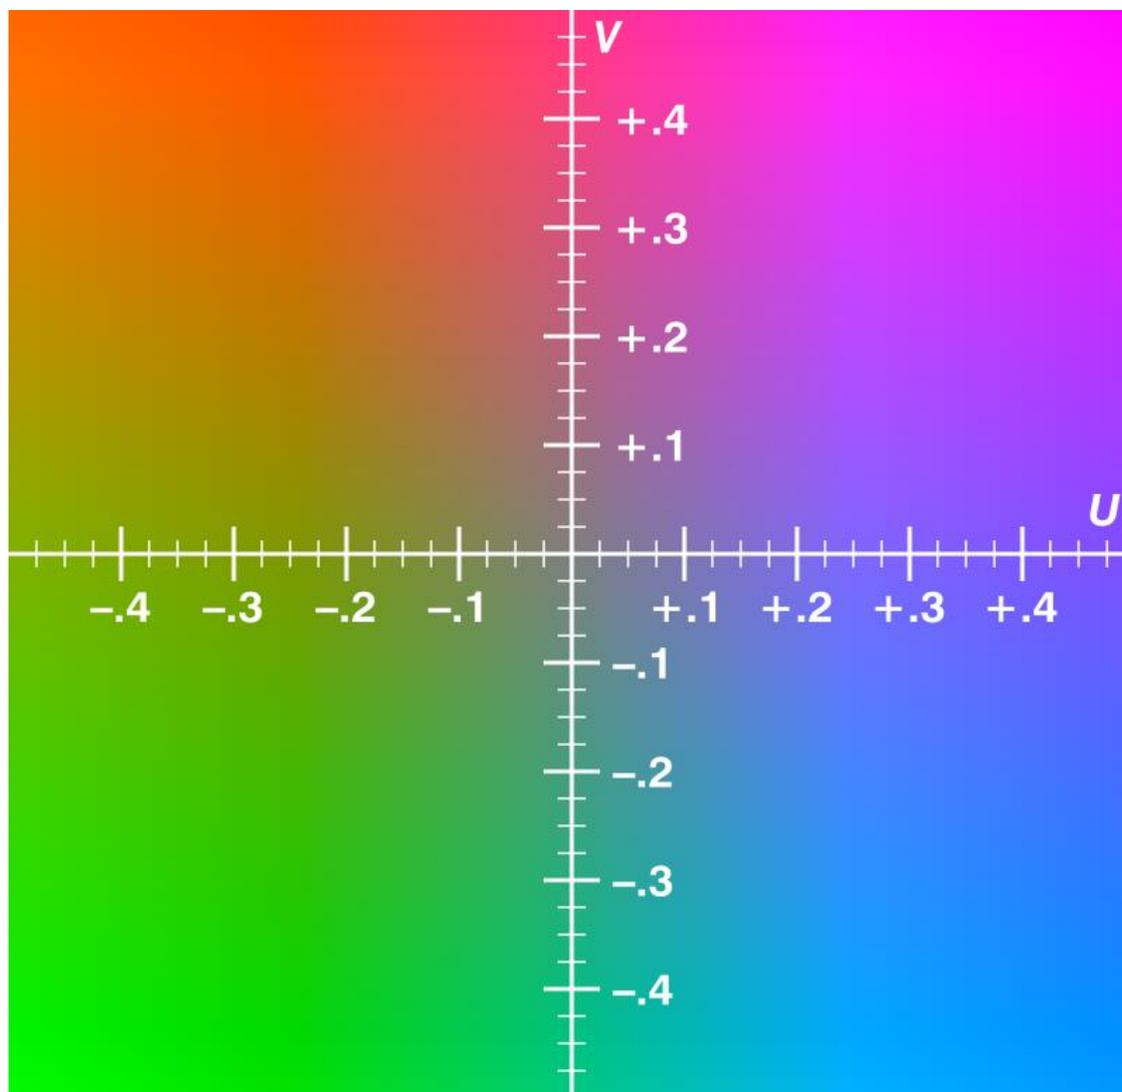


Figura 12. Modelo de color YUV.

Modelo de color $YD_B D_R$

Basado en el modelo YUV, es utilizado en el estándar de televisión en color SECAM (Al-Tairi *et al.*, 2014). Consta de una componente que representa la luminancia (Y) y dos que representan la crominancia (D_B y D_R) (Subban y Mishra, 2014). Es útil para diferenciar en una imagen los píxeles en los que domina la componente roja (Yadav *et al.*, 2013). Se relaciona con el modelo

RGB, los valores se suman para generar una señal simple de luminancia Y , y la señal D_B se obtiene restando Y de la señal azul del modelo RGB, y D_R restando Y de la señal roja, estando las dos multiplicadas por factores de escala diferentes (Chaves-González *et al.*, 2010; Sahdra y Kailey, 2012).

K-medias.

El agrupamiento de datos o simplemente clustering es considerado uno de los problemas más importantes en el aprendizaje no supervisado, como en todos los problemas de este tipo, lo que es relevante es encontrar grupos en un conjunto de datos (Jain, 2010; Na *et al.*, 2010). De manera más general puede definirse el agrupamiento de datos como el proceso de organización de objetos que son muy similares de alguna manera, la Figura 13 muestra el agrupamiento que realiza K-medias.

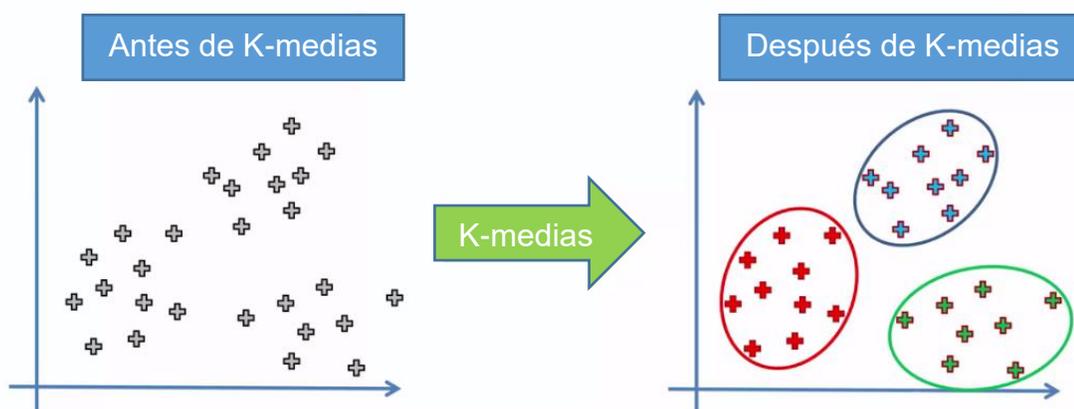


Figura 13. Agrupamiento según K-medias.

El problema de formar grupos es muy importante para el conocimiento del comportamiento de un conjunto de datos (Celebi *et al.*, 2013). La solución a estos problemas se realiza mediante la aplicación de algoritmos de agrupamiento, entre todos ellos existe el algoritmo K-medias utilizado para dicho propósito (descrito en parte de Métodos y Materiales).

Este algoritmo puede abordarse como un problema de optimización y desde un punto de vista geométrico que para fines de poner en contexto al lector se hace

énfasis en la parte geométrica del algoritmo (Celebi *et al.*, 2013; Jain, 2010; Na *et al.*, 2010; Dhanachandra *et al.*, 2015).

Uso de K-medias.

La segmentación con K-medias ha resultado tener buenos avances en cuestión sobre la identificación de problemas específicos como por ejemplo la identificación de enfermedades tanto en hojas como en frutos (Bhange y Hingoliwala, 2015), hablando del campo agronómico, ha identificado enfermedades en frutos de manzana, granada, mango, guayaba, entre otros (Dubey y Jalal, 2012), además de que también ha ayudado a la identificación de enfermedades en las hojas de los cultivos mencionados (Pagariya y Bartere, 2014).

Por otra parte, en la identificación de atributos de imágenes en general ha generado excelentes resultados ya que facilita el resalte de diversas áreas de interés de las imágenes a través de las diferentes características o atributos que las imágenes proporcionan (Dhanachandra *et al.*, 2015).

Escala de grises.

La escala de grises o la transformación de una imagen con un modelo de color tridimensional (RGB, HSL, HSV) o de más dimensiones (CMK) ha facilitado la lectura y análisis de problemas que implican videos o imágenes (Costa *et al.* 2012), ya la imagen se transforma a un plano donde solo existe una dimensión, el máximo valor representado por 255 generara el blanco absoluto y el valor 0 nos proporciona el color negro de la imagen transformada (David y Moreno, 2016).

Por tal manera, la lectura en las diversas concentraciones de los tonos de gris son los que se analizan en una imagen en escalas de grises (Liu y Ying, 2012), facilitando de esta manera la segmentación de las imágenes tanto utilizando métodos de umbralización (rangos) o utilizando agrupamientos gracias a las

diversas cantidades que el histograma generado en una imagen en blanco y negro proporciona (Zujovic *et al.*, 2013).

Conversión de RGB a escalas de grises.

La conversión de una imagen en color a escala de grises es el equivalente a la luminancia de la imagen (Güneş *et al.*, 2016). Se sabe que el ojo percibe distintas intensidades de luz en función del color que se observe, esto es debido a la respuesta del ojo al espectro visible la cual se puede observar en la Figura 14 (Sowmya *et al.*, 2017). Por esa razón el cálculo del equivalente blanco y negro (escala de grises o luminancia) de la imagen debe realizarse como una media ponderada de las distintas componentes de color de cada pixel (Jimmy y Cortés, 2011).

La ecuación de la luminancia muestra la expresión matemática de ese fenómeno y los factores de ponderación de cada componente de color nos indican la sensibilidad del ojo humano a las frecuencias del espectro cercanas al rojo, verde y azul (Saravanan, 2010).

$$Y = R * 0.3 + G * 0.59 + B * 0.11 \quad (2).$$

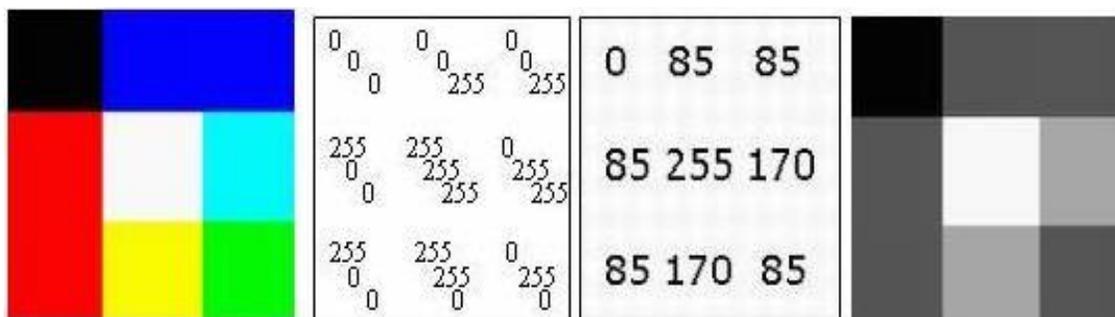


Figura 14. Conversión de color a escalas de grises.

Matrices convolucionales.

Las matrices convolucionales son herramientas que nos permiten la posibilidad de modificar las variables de entrada del modelo cuando se considere necesario de manera que se pueda analizar su influencia en los resultados finales (Depcik y Assanis, 2004).

Las matrices convolucionales permiten generar en escasos segundos el resultado de aplicar un filtro de convolución a partir de una máscara dada sea dada por bordes, enfocado, desenfocado, etc. (Almeida *et al.*, 2016). Estudiando con detalle las propiedades más importantes relacionadas con el filtrado de imágenes mediante la convolución, mostrándose muy útil desde el punto de vista didáctico para afianzar y ampliar los conocimientos sobre el tema (Giménez *et al.*, 2016) como se muestra en la Figura 15.

Enfoque	Desenfoque	Realce de bordes	Repujado
$\begin{bmatrix} 0 & -1 & 0 \\ -1 & 5 & -1 \\ 0 & -1 & 0 \end{bmatrix}$	$\begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$	$\begin{bmatrix} 0 & 0 & 0 \\ -1 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}$	$\begin{bmatrix} -2 & -1 & 0 \\ -1 & 1 & 1 \\ 0 & 1 & 2 \end{bmatrix}$
Detección de bordes	Filtro de tipo Sobel	Filtro de tipo Sharpen	
$\begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}$	$\begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}$	$\begin{bmatrix} 1 & -2 & 1 \\ -2 & 5 & -2 \\ 1 & -2 & 1 \end{bmatrix}$	
Filtro Norte	Filtro Este	Filtro de tipo Gauss	
$\begin{bmatrix} 1 & 1 & 1 \\ 1 & -2 & 1 \\ -1 & -1 & -1 \end{bmatrix}$	$\begin{bmatrix} -1 & 1 & 1 \\ -1 & -2 & 1 \\ -1 & 1 & 1 \end{bmatrix}$	$\begin{bmatrix} 1 & 2 & 3 & 1 & 1 \\ 2 & 7 & 11 & 7 & 2 \\ 3 & 11 & 17 & 11 & 3 \\ 2 & 7 & 11 & 7 & 1 \\ 1 & 2 & 3 & 2 & 1 \end{bmatrix}$	

Figura 15. Matrices convolucionales más usadas en el análisis de imágenes digitales.

Procesamiento digital de imágenes.

El procesamiento digital de imágenes es una herramienta ampliamente utilizada en la automatización de procesos industriales, debido a que presenta confiabilidad, eficacia y rapidez en el procesamiento. Flórez *et al.* (2015) mencionan que el procesamiento de imágenes con fines de reconocimiento de plagas y morfología de las plantas se ha discutido en diversos trabajos. Rastogi

et al. (2015) proponen un método para la detección de plagas y el suministro automatizado de plaguicidas en invernaderos.

Diversos son los estudios que muestran la importancia que puede tener el análisis en una imagen digital en el campo de la agricultura, ya sea en el fruto como lo mencionado por (Padrón-Pereira, 2013, Guzman *et al.*, 2004), o en las plagas y enfermedades presentes como lo menciona (Camacho *et al.*, 2014).

Aplicación de análisis de imágenes en agronomía.

El procesamiento digital de imágenes equivale a realizar operaciones sobre un conjunto de datos obtenidos de las mismas imágenes, esto con el fin de mejorar la imagen para una aplicación en particular o para extraer información útil (Choudhury *et al.*, 2016). Los trabajos más recientes sobre este tema están relacionados con la segmentación de imágenes a color, análisis de textura, morfología matemática, estandarización de imágenes a color y localización de objetos (Báez Rojas y Pérez, 2008).

La identificación automática de enfermedades en plantas por inspección visual puede ser de gran beneficio para aquellos usuarios que no conocen o tienen poca información sobre el cultivo que trabajan (Prince *et al.*, 2015). La importancia de poder conocer y controlar plagas en cultivos de interés agronómico radica en que se puedan aplicar tratamientos y protección temprana de estos cultivos si son detectadas las plagas y enfermedades en una etapa temprana, así como sus agentes causales (Velázquez-López *et al.*, 2011).

En la agricultura se han desarrollado muchas aplicaciones usando visión por computadora. Los sistemas de visión por computadora no sólo reconocen el tamaño, forma, color y textura de los objetos, sino que también proporcionan atributos numéricos de los objetos o escenarios para examinar (Velázquez-López *et al.*, 2011).

Unas de las ventajas del uso de la tecnología de detección por imágenes, es que puede ser bastante precisa, no destructiva y con resultados consistentes (Chen *et al.*, 2002). Por otra parte, los sistemas de visión artificial se utilizan

para desarrollar diversas aplicaciones agrícolas, de esta manera se conocen condiciones del suelo, cobertura de residuos, sanidad vegetal, identificación de especies, densidad de población y el tamaño de la planta (Velázquez-López *et al.*, 2011).

Por otro lado, Nandi *et al.* (2014) trabajaron con el procesamiento de las imágenes tomadas automáticamente a frutos de mango para clasificar estos de acuerdo con su grado de madurez. Concluyendo en la importancia de la automatización de la clasificación y detección detallada de la calidad del fruto. Un trabajo similar es el realizado por Padrón-Pereira (2013), en donde se mide el diámetro de los frutos de mandarina durante el desarrollo del árbol para construir curvas de crecimiento, relacionados a la nutrición y factores biológicos de desarrollo.

Por su parte, Guzman *et al.* (2004), utilizaron el programa MATLAB® para realizar un programa que analiza imágenes para medir la intensidad de la mancha de hierro en el café, la cual es provocada por *Cercospora coffeicola*, lo que permitió conocer con mayor precisión y rapidez el área foliar de las plantas y el área de afectación.

Kirk *et al.* (2009) aplicaron una combinación de verdes e intensidades derivadas de las bandas espectrales verde y roja, calculando un umbral automático para un problema biclase, vegetación y terreno, asumiendo dos funciones de densidad de probabilidad Gaussianas asociadas a cada una de las clases.

Los índices de vegetación ExG y NDI dado por la umbralización obtenido por el método Otsu, se compararon con el método ExGR, estableció como umbral el valor cero para la segmentación, los resultados mostraron mejor eficiencia en ExGR ya que el umbral establecido no dependió del método Otsu (Meyer y Camargo-Neto, 2008).

Burgos-Artizzu *et al.* (2011) proponen un método de segmentación automático, utilizando inicialmente los índices de color para crear una imagen de gris que luego binarizan fácilmente usando un método de ajuste de umbral automático, simple y rápido, considerando el valor medio estadístico de los niveles de intensidad de los píxeles, resultando ser un método de segmentación robusto.

En el trabajo de investigación desarrollado por Chumuang *et al.* (2016) se propuso el algoritmo de segmentación de imagen para clasificar sus elementos y calcular la superficie de la hoja con una técnica de segmentación de umbral para separar la superficie buena de la imagen de la hoja, utilizando un umbral constante en el modelo de color gris y calcular el grado de color verde en los modelos de valores de saturación de matices (HSV).

Para estimar el crecimiento de tomate se desarrolló un algoritmo llamado "Optimización de enjambre de Partículas" (PSO), el cual ha demostrado excelentes resultados como método de optimización a nivel mundial (Wei y Qiqiang, 2004).

Un método para estimar la medida del cambio en el diámetro en el fruto de mandarina se estableció en (Padrón-Pereira, 2013), generando un gran paso en la investigación fisiológica de árboles frutales el cual se puede incluir para el manejo del huerto o cultivo.

Importancia de la detección del hongo en el cultivo de pepino.

Cenicilla (*Sphaerotheca fuliginea*) es un hongo de importancia para el cultivo de pepino (*Cucumis sativus*) producido bajo invernadero y campo abierto por su fuerte efecto de patogenicidad ya que causa una gran pérdida de rendimiento (Fan *et al.*, 2014; Juárez *et al.*, 2012). Los hongos causan estrés biótico aumentando la producción de especies reactivas de oxígeno (ROSs) llevando a un estrés oxidativo (Horbach *et al.*, 2011). La implementación de sistemas y aparatos de manejo automática ayudan a la detección oportuna de esta y otras enfermedades (Al Bashish *et al.*, 2011). Lo cual permite a la toma de decisiones oportunas y adecuadas para mitigar o detener la diseminación del hongo en regiones sanas de la hoja de pepino (Zhang *et al.*, 2017). Además, los sistemas están integrados no solo para resolver un problema en particular, si no una gran variedad de problemas que comprometen el rendimiento del cultivo (Haug *et al.*, 2014).

MATERIALES Y MÉTODOS.

Toma de fotografía.

La toma de fotografías se realizó con una cámara de celular de 13 mega pixeles durante dos sesiones manteniendo un fondo color rojo de cartón para contrastar la hoja. La primera sesión correspondió a un ciclo de cultivo establecido durante los meses de marzo a junio y la segunda sesión a un ciclo establecido durante junio a septiembre. Ambas sesiones fueron realizadas durante la tarde cuando la luz solar era muy deficiente, esto con el fin de reducir la luminosidad. Las fotografías contenían áreas de la hoja enfermas y áreas que estaban sanas, además de contener áreas de fondo. La enfermedad se identificó por su micelio veloso de color grisáceo, dicha característica de color se utilizó para el proceso de segmentación. Se capturaron un total de 3,000 fotografías de las cuales 100 fotografías por cada ciclo de cultivo se seleccionaron con evidente presencia de la enfermedad. Las fotografías, en formato JPG, fueron enumeradas para su posterior manejo en MatLab® v.2018.

Preprocesamiento manual de fotografías.

Para diferenciar las hojas del fondo en las fotografías la segmentación de las imágenes se puede tratar en dos procedimientos excluyentes: detección de cenicilla en hojas diferenciadas del fondo y separación de hojas del fondo. En este trabajo se ataca el primero de esos dos problemas, la detección de la cenicilla. A fin de detectar inicialmente la enfermedad, se separaron las hojas del fondo mediante un proceso manual, eliminando el fondo con auxilio del software GIMP® v.2.10.8. Dicho proceso de eliminación consistió en colocar un fondo color rojo para mejor separación del verde de la hoja, ya que el color rojo se encuentra en el lado opuesto al verde en la escala de color. De tal manera que se generaron una copia de todas las fotografías que se analizaron en esta investigación. Posteriormente las copias ya procesadas manualmente sirvieron para llevar los análisis con los programas de reconocimiento.

Binarización en escala de grises.

Para procesar mediante binarización en escalas de grises, el programa permitió leer las imágenes a color la cual la convierte inmediatamente a escalas de grises en el mismo programa. Posteriormente se determinó el tamaño de la imagen en píxeles realizando un conteo tanto en forma vertical como horizontal. Se descartó el fondo mediante discriminación por color donde el programa contabilizó los píxeles que mostraron el color rojo que previamente se había adicionado fin de obtener exclusivamente el área de interés, en este caso, la hoja. Se transformó la imagen a escala de grises y se analiza el histograma de frecuencia a fin de detectar los tonos más claros de dicha imagen. El umbral se calculó a partir de un promedio de 100 imágenes donde se seleccionó los colores de las regiones que mostraban cenicilla, dando un promedio de 178 el cual se dividió entre 255, valor máximo de color rojo, resultando un umbral igual o mayor al 70% del color que se detectó en el histograma en escala de grises a fin de que las regiones más claras funcionaran como el indicador para la segmentación de la cenicilla. Posteriormente se utilizó un filtro para eliminar ruido de la imagen, el cual fue de vital importancia ya que elimina regiones que se observan no correspondía a la enfermedad. Finalmente se realizó el conteo de los píxeles seleccionados en la segmentación para obtener el porcentaje total de afectación de la cenicilla en la hoja de pepino, el cual a partir del total de píxeles de la imagen que se encuentra en blanco y negro selecciona los píxeles blancos como el indicador de identificación de cenicilla.

Binarización en base al modelo de color RGB.

Para procesar mediante binarización en base al modelo de color RGB, se leyeron las imágenes en RGB posteriormente el programa disocia la imagen en sus tres componentes en base al modelo de color. Posteriormente se determina el tamaño de la imagen en píxeles realizando el mismo conteo de forma vertical y horizontal. Se realizó una primera segmentación en cada una de las capas

obteniendo regiones seleccionadas por el programa en base al umbral mayor o igual a 170/255 para el color rojo, esto ayudó para la eliminación del fondo rojo establecido en el procesamiento manual y para la segmentación de verde y azul, el umbral seleccionado fue multiplicando el valor del color rojo por 0.97 y 1.03 para cada una de las capas, estos umbrales permitieron eliminar el fondo color rojo y segmentar la cenicilla de la hoja. El valor para la segunda segmentación fue calculado a partir de la desviación estándar con respecto al color rojo de 20 fotos las cuales se extrajo el color que representaban las áreas con cenicilla, a estos valores se le calculo el promedio el cual fue de 170, esta desviación nos permitía dejar un rango entre el umbral calculado tomando en cuenta que dicho umbral fue el promedio de los pixeles seleccionados. De tal manera se amplió el rango de detección utilizando la desviación estándar. Se aplicó un primer filtro el cual ayudo a la eliminación de ruido el cual se confundía con enfermedad aplicando una matriz de (3,3). Posteriormente, se aplicó un filtro convolucional con el fin de que las regiones segmentadas sobresaliera en las imágenes analizadas, el filtro fue de 1 (3,3). Finalmente se realizó el conteo de los pixeles seleccionados en la segmentación para obtener el porcentaje total de afectación de la cenicilla en la hoja de pepino, esto es realizado en la última imagen generada después de la aplicación de la matriz convolucional.

Filtrado mediante un filtro promedio.

Denotamos mediante $g_{i,j}$, el resultado final del valor del mismo píxel después de haber aplicado el filtro. Sea $f_{i,j}$, para $i, j=1, \dots, n$, los valores de cada píxel de una imagen Un filtro lineal de tamaño $(2m+1) \times (2m+1)$, con pesos especificados por $w_{k,l}$ para $k, l = -m, \dots, m$, arroja un valor de $g_{i,j}$ igual a:

$$g_{ij} = \sum_{k=-m}^m \sum_{l=-m}^m w_{k,l} f_{i+k,j+l} \quad \text{para } i, j = (m+1), \dots, (n-m) \quad (3)$$

Filtrado mediante una matriz de convolución.

Utilizamos para el tratamiento de las imágenes una matriz de convolución. Este filtro ayudó a definir de forma más completa las áreas que se detectan como enfermedad. Dada una matriz $A_{m \times n}$ y una matriz $C_{(2N+1) \times (2N+1)}$ donde $2N+1 < m, n$, definimos la convolución de las matrices A y C como una nueva matriz $D = A * C$ definida a partir de la siguiente expresión:

$$d_{ij} = \frac{1}{v} \sum_{r=1}^{2N+1} \sum_{s=1}^{2N+1} a_{i-N-r+1, j-N-r+1} c_{r,s} \quad \text{para } i, j = (m+1), \dots, (n-m) \quad (4)$$

$$v = \sum_{i,j=1}^{2N+1} c_{i,j} \quad (5)$$

Si $v=0$, entonces se tomó $v=1$. A la matriz C se denominó núcleo o kernel de la convolución.

Algoritmo k-medias.

El algoritmo de k-medias leyó una imagen a color la cual posteriormente, tal como se hace con los de binarización, se determinó el tamaño de la imagen contabilizando en forma vertical y horizontal los pixeles de la imagen. Se utilizaron cuatro grupos a partir del histograma de frecuencia de la imagen convertida a tonos de gris para realizar el agrupamiento. Se detectó el pixel máximo de la imagen utilizando los centros para cada uno de los grupos encontrados en una imagen convertida a escalas de grises realizado por el mismo algoritmo. La imagen se disocio en los tres componentes que conforman el modelo RGB y el cual cada capa representa un grupo, obteniendo con ello tres de los cuatro establecidos. Al realizar la identificación de las regiones de interés en cada una de las capas la imagen se asoció nuevamente formando el último

grupo. La segmentación de las áreas que el programa identificó como cenicilla en cada una de las capas RGB son descartadas, y las que coinciden entre sí fueron marcadas como área de enfermedad por cenicilla en hojas de pepino. Finalmente se realizó el conteo de los pixeles seleccionados por la segmentación en el último grupo, es decir, el asociado en las tres capas para obtener el porcentaje de daño identificado por el algoritmo k-medias en las imágenes.

Definición del algoritmo K-medias.

Según Gan *et al.* (2007) dado un conjunto de datos $D = \{x_1, x_2, \dots, x_n\}$ y k número de agrupamientos a formar, entonces:

1. Se selecciona un conjunto arbitrario o aleatorio de centroides iniciales de los k agrupamientos: c_1, c_2, \dots, c_k .
2. Para cada $x_j \in D$, se encuentra el centroide c_j más cercano a x_i y se asigna x_j al agrupamiento:

$$C_j = \min_{1 \leq j \leq k} \|x_i - c_j\| \quad (6)$$

3. Para cada uno de los grupos se recalculo su centroide basado en los elementos que están contenidos en el agrupamiento.
4. Repetir los pasos 2 y 3 hasta que:

$$q_j = \sum_{v \in \pi_j} \|a_v - m_j\|_2^2 \quad (7)$$

$$\min_{\Pi} Q(\Pi) = \sum_{j=1}^k q_j = \sum_{j=1}^k \sum_{v \in \pi_j} \|a_v - m_j\|_2^2 \quad (8)$$

Partición de datos.

Según Eldén (2007) dado un conjunto de datos D con n objetos, una partición Π de D en k grupos es una familia de conjuntos $\{\pi_1, \pi_2, \dots, \pi_k\}$ que cumple con las propiedades siguientes:

$$\pi_i \neq \emptyset \quad i = 1, \dots, k \quad (9)$$

$$\bigcup_{i=1}^k \pi_i = D \quad (10)$$

$$\pi_i \cap \pi_j = \emptyset \quad i \neq j \quad (11)$$

Detección de falsos positivos.

Para la detección de falsos positivos se utilizaron 25 imágenes pre procesadas de cada ciclo de cultivo donde se le realizó la eliminación de la cenicilla con el programa GIMP. Se copiaron los pixeles sanos de cada una de las imágenes y se establecieron donde se encuentra la cenicilla identificada de forma visual por un experto. Se guardó una copia de dichas imágenes y estas se analizaron con los tres métodos mencionados en este trabajo. Los resultados son reportados con los valores mínimos y máximos encontrados con los métodos.

Procesamiento de fotografías en MatLab.

Para obtener los porcentajes de daño por cenicilla en las hojas de pepino mediante MATLAB®, al total de pixeles de la imagen se le resta la contabilización de pixeles del fondo para obtener el total de pixeles que forman la hoja. Estos pixeles se definen como área total de la hoja. Después de obtener en número de pixeles considerados como área total de la hoja, se obtuvo el número de pixeles que se segmentaron de acuerdo con los métodos utilizados. Finalmente se obtuvo la relación entre el total de pixeles clasificados como cenicilla divididos entre los pixeles de la imagen menos los pixeles rojos

correspondientes al fondo. Se multiplica por cien para obtener el porcentaje de daño por cenicilla en la hoja (Ecuación 12).

$$\text{Porcentaje de cenicilla} = \frac{\text{Píxeles segmentados}}{\text{Píxeles totales} - \text{Píxeles rojos}} \times 100 \quad (12)$$

Evaluación de la exactitud de las técnicas.

Una medida de rendimiento (λ) que compara el fondo (B) y el primer plano (F) entre la imagen real e imagen resultante después de un procedimiento de reconocimiento puede ser definida como:

$$\lambda = 100 \times \frac{|B_O \cap B_T| + |F_O \cap F_T|}{|B_O| + |F_O|} \quad (13)$$

donde B_0 y F_0 representan el fondo y el objeto de la imagen real, B_T y F_T son el fondo y el objeto de la imagen resultante, y el símbolo $|\cdot|$ denota la cardinalidad de cada uno de los diferentes conjuntos que componen la ecuación (Xiao *et al.*, 2011).

En el caso de este trabajo se considerará únicamente el problema de la hoja y la enfermedad, ya identificadas y separadas del fondo. Esto debido a que el problema de reconocimiento de la hoja es un problema complejo que va más allá del propósito original de este trabajo, pero que deja abierta la posibilidad para una futura investigación.

La calidad de la segmentación fue definida por el Grupo de Trabajo de Reconocimiento Automático de Objetivos (ATRWG, por sus siglas en inglés) con el fin de evaluar el rendimiento de la segmentación de los diferentes métodos. Esta medida se puede escribir como:

$$Q_{seg} = \frac{|A \cap B|}{|A \cup B|}$$

donde A es el conjunto de píxeles del objeto que se desea identificar y B es el conjunto de píxeles del objeto resultante de la segmentación, y $|\cdot|$ denota la cardinalidad de cada uno de los diferentes conjuntos que componen la ecuación (Meyer y Neto, 2008). En el caso de este trabajo, A representa los píxeles detectados manualmente e identificados como enfermedad. Por otra parte, el conjunto B identifica los píxeles que el algoritmo separa mediante el uso de los algoritmos propuestos e identifica como enfermedad.

La precisión de la segmentación se utiliza en el VOC (Everingham *et al.*, 2015) y es similar a la calidad de la segmentación. Se puede escribir como:

En el presente trabajo se optó por aplicar la medición de la calidad de la segmentación para comparar la exactitud del índice de color y los enfoques basados en el aprendizaje, ya que actualmente es una medición de referencia en el estado de la técnica para la segmentación de cultivos. Para este experimento se seleccionó manualmente las regiones con apariencia de la enfermedad dentro de las imágenes, se analizaron 500 imágenes comparadas con las fotografías originales para calcular el porcentaje de exactitud a partir de la ecuación de Q_{seg} .

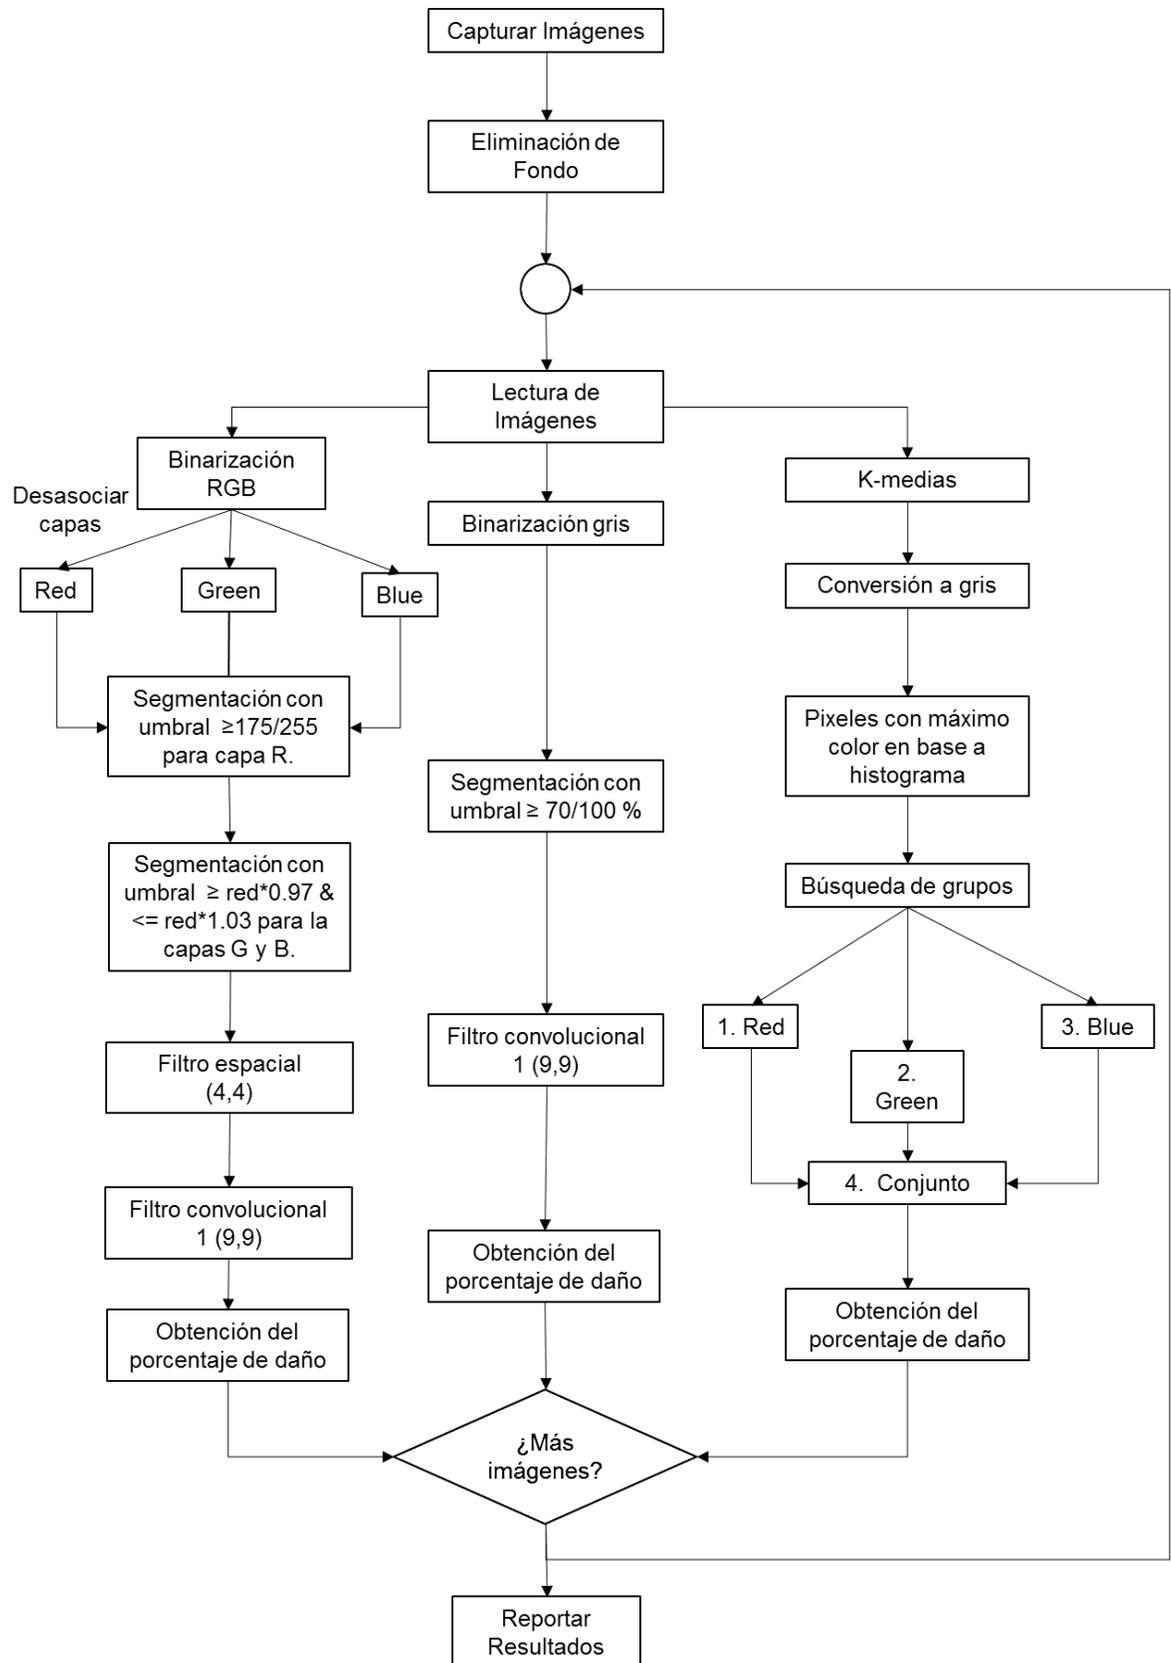


Figura 16. Esquema general de los algoritmos.

RESULTADOS Y DISCUSIÓN.

En la Figura 17 se muestran las imágenes analizadas de una hoja de pepino infestada. La imagen 17A muestra la imagen original, la imagen 17B muestra la misma imagen en tonos de gris, la imagen 17C muestra la imagen procesada mediante el método de binarización y, finalmente, la imagen 17D muestra la imagen filtrada para eliminar ruido que pudiera confundirse con la enfermedad. La Figura 17D fue usada en todas las imágenes para estimar el porcentaje de daño por la enfermedad en hojas de pepino. Ya que en esta figura se logró eliminar parte del ruido en la imagen gracias al filtro convolucional adherido en el proceso de segmentación, permitiendo generar resultados más certeros.

En algunos trabajos el algoritmo Otsu ayudó a diferenciar la hoja de la imagen para posteriormente binarizarla en las capas R y B teniendo un 90% de efectividad en identificar plagas y enfermedades (Wang *et al.*, 2013). Abdullah *et al.* (2016) utilizaron el método de Otsu, entropía y uno de Brink logrando la segmentación en escalas de grises utilizando histogramas tanto en 1D y 2D. Sus resultados fueron mejores al utilizar histogramas en 2D que 1D, al igual que Forero *et al.* (2016). Concluyendo que el histograma en 2D y en escala de grises mostraron mejor segmentación con la transformada de Radon por encima del método Otsu y SRG.

De igual manera las técnicas de segmentación fueron de gran utilidad en la clasificación de tizón (*Alternaria helianthi*) y roya de la hoja en avena (*Puccinia coronata* f.sp. *avenae*), separando la enfermedad de las regiones sanas de las hojas (Tucker y Chakraborty, 1997). Igualmente, se pudo lograr la separación de la planta de orquídea del fondo mediante la segmentación utilizando el algoritmo J48 con un 84% de precisión (Sanjaya *et al.*, 2015). Al utilizar dos o más umbrales en características de grises por binarización se puede obtener mejores resultados que solo utilizando un umbral. Además, utilizando el umbral más cercano a las regiones más claras del histograma muestra mejores resultados que marcando el umbral que predicho (Dubey y Jalal, 2012; Mora y Capulín, 2018). Lo anterior justifica el uso de la segmentación a partir de umbrales detectados en los colores más claros de los histogramas generados

de las imágenes en escala de grises y algún modelo de color como RGB mostrando que es una técnica adecuada para lograr la identificación características distintivas, entre ellas de enfermedades, en cultivos hortícolas.

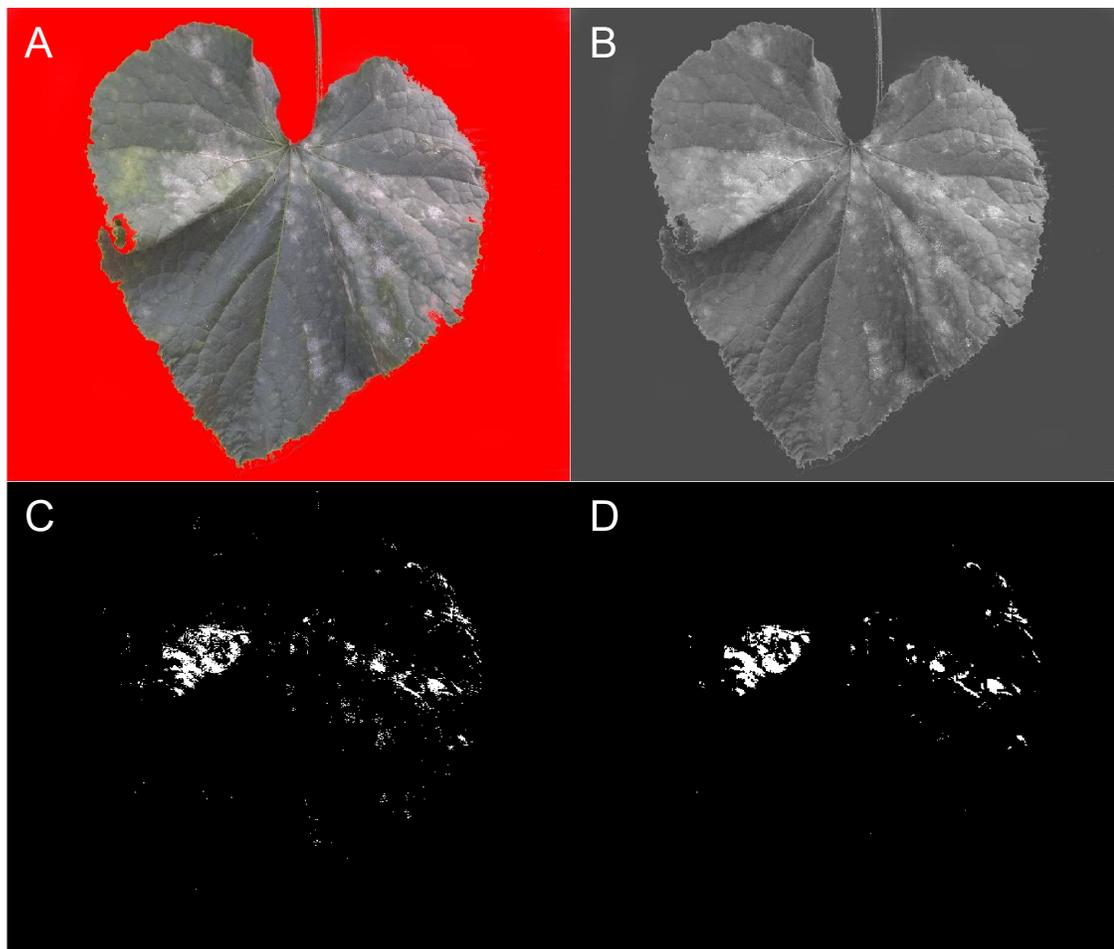


Figura 17. Binarización en escala de grises de hoja de pepino del ciclo marzo-junio. A) Hoja infectada con cenicilla con fondo rojo. B) Imagen en escala de gris. C, D) Postprocesamiento de imagen para eliminación de ruido.

En Abdullah *et al.* (2016) y Sanyal y Patel (2008) la textura les permitió diferenciar el fondo de la hoja dentro de la imagen. En Es-saady *et al.* (2016) y Sethupathy y Veni (2016) se utilizó el método k-medias el cual entregó resultados de agrupamiento, pero al ser aleatorios los puntos iniciales de los centroides, se tienen diferentes resultados cada vez que se ejecuta el proceso. Por lo que se debe iniciar con una búsqueda o localización de centroides adecuados al problema que se trata como se realizó en esta investigación. En este proceso el agrupamiento incluyó áreas de las hojas con luminosidad y las

clasificó como cenicilla, por lo que identificó regiones con enfermedad donde se observa que son regiones sanas como lo muestra la Figura 18.

La Tabla 1 muestra los resultados obtenidos por el análisis de frecuencias de los porcentajes de afectación de cenicilla generado por el análisis de imágenes por los métodos de binarización tanto en escala de grises como con el modelo de color RGB y el algoritmo k-medias. Se consideraron 12 clases establecidas arbitrariamente con lo que se generaron rangos de daño producido por la enfermedad en las hojas, tomando en cuenta que existieron imágenes que mostraban porcentajes de afectación muy altos. Se muestra que el daño más frecuente fue para la primera clase con un total de 97 casos en un rango de 0 a 5% de afectación para el primer ciclo. 67 casos en el mismo rango para el segundo ciclo utilizando el programa de binarización en escala de grises. Para la binarización con el modelo de color RGB en el primer ciclo los 100 casos fueron identificados y segmentados en la primera clase. Para el segundo ciclo la primera clase también fue la más sobresaliente con 93 del total de los casos. También, se muestra que el daño detectado por k-medias se encuentra entre el 20 y 45% durante el primer ciclo y entre 25 y 50% de daño para el ciclo de junio–septiembre, estos datos son poco confiables ya que realizando una comparación visual se detectan áreas sanas como enfermas como ya se mencionó.

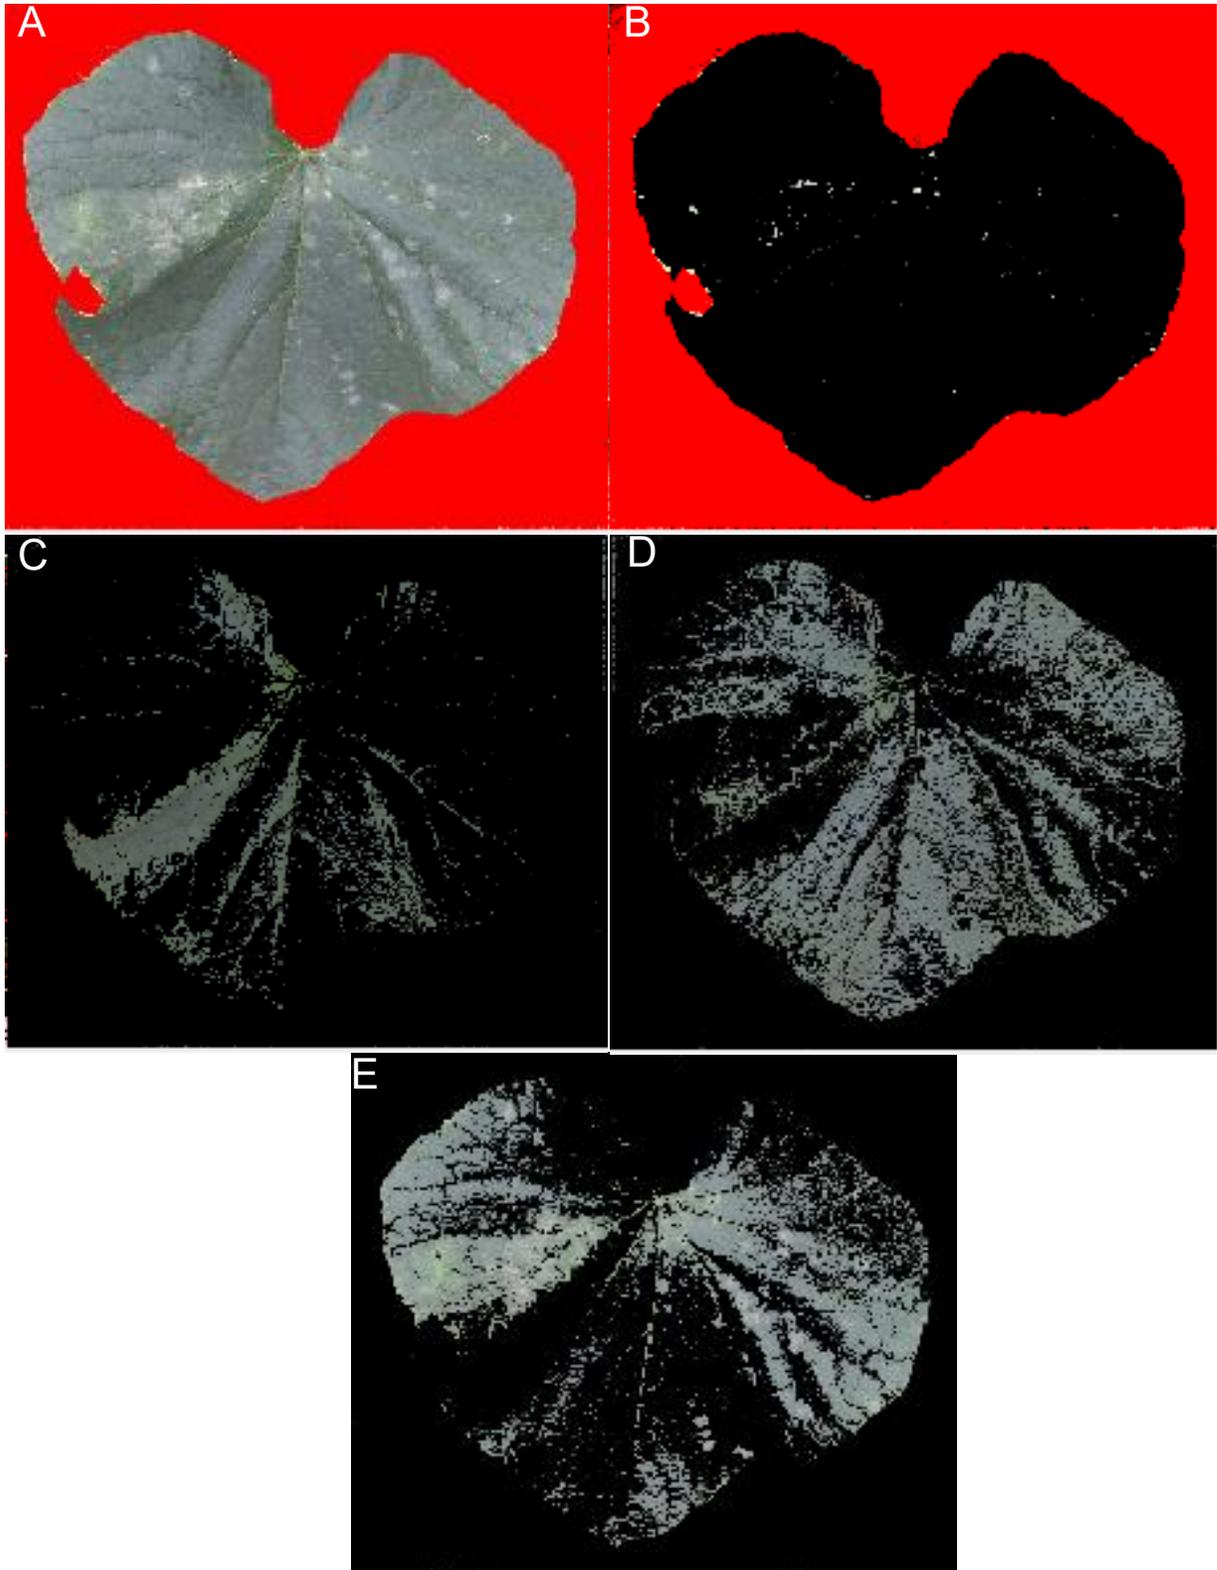


Figura 18. K-medias en hojas de ciclo marzo-junio. A) Imagen original. B) Agrupamiento en capa Roja. C) Agrupamiento en capa Verde. D) Agrupamiento en capa Azul. E) Agrupamiento de las capas RGB.

Tabla 1. Porcentaje de daño por cenicilla en hojas de pepino detectados por el método de binarización en escala de grises, modelo RGB y el algoritmo K-medias durante dos ciclos de cultivo.

Porcentaje de daño.	Marzo – Junio.			Junio – Septiembre.		
	Bin. gris.	K-medias.	Bin. RGB.	Bin. gris.	K-medias.	Bin. RGB.
0 – 5	97	14	100	67	8	93
5 – 10	2	1	0	18	4	3
10 – 15	1	3	0	6	4	1
15 – 20	0	6	0	6	5	2
20 – 25	0	12	0	3	7	1
25 – 30	0	13	0	0	10	0
30 – 35	0	15	0	0	17	0
35 – 40	0	9	0	0	9	0
40 – 45	0	12	0	0	10	0
45 – 50	0	4	0	0	19	0
50 – 55	0	7	0	0	4	0
55 – 60	0	4	0	0	2	0

De acuerdo con los resultados obtenidos el método de binarización en escalas de grises es más exacto para identificar la cenicilla en este caso en particular (Tabla 2). En la Tabla 1 se muestra que la afectación máxima se encuentra en la clase 1 la cual muestra el daño por cenicilla en porcentaje que oscila entre el 1 y 5% de afectación en la hoja en relación con el tamaño de la fotografía para ambos ciclos. Muchas de las fotos analizadas no contenían cenicilla por encima del 15% en el primer ciclo ni por encima del 25% en el segundo ciclo detectado por el método de binarización y corroborado por la detección visual de las imágenes. Por otro lado, mediante el algoritmo k-medias se detectan algunas fotografías con afectación entre el 55 y 60% lo cual rebasa la afectación real en la fotografía procesada. Esto se puede deber a que el color de la cenicilla es fácilmente confundido con partes iluminadas de la hoja o bien ruido que no se logró eliminar en su totalidad durante el análisis de segmentación. En *Atmaja et al.* (2016) binarizaron en RGB convirtiendo a gris, encontrando umbrales a través de la desviación estándar y aplicaban filtrados para exponer con mayor claridad las regiones sementadas por binarización, como en este estudio. En nuestro caso, el método de binarización en base al modelo de color RGB identificó menor porcentaje de cenicilla en las imágenes analizadas, pero esta

información al igual que el método de k-medias es poco confiable ya que al aplicar los filtros convolucionales estos hacían que la cenicilla se confundiera con regiones que no son daño, por lo cual el porcentaje mostrado al final del proceso fue muy poco significativo, pero utilizando otras técnicas en conjunto con k-medias podría generar resultados más concisos, como lo hicieron Rastogi *et al.* (2015) al transformar de RGB a L*a*b para detectar características y posteriormente utilizar una red neuronal artificial para segmentar enfermedades en hojas de hortensia.

En la Figura 19 se muestra el proceso que realiza el método de binarización en RGB y reafirma lo antes mencionado. Youlian *et al.* (2015) utilizaron el modelo de color RGB con el cual lograron la binarización a partir del histograma en la detección de rostros de personas, otorgando el 0 a lo que no es rostro y 1 a lo que se sí considera. Además, la segmentación pudo eliminar ruido y fondo en las imágenes analizadas. Flórez *et al.* (2015) mencionan que transformando las imágenes de RGB original a otro tipo de modelo de color como HSL o L*a*b ayuda a segmentar con mayor veracidad regiones de interés en las imágenes, ya que dichos modelos proporcionan características con las cuales la segmentación es más certera. Una de estas características, que estos modelos de color utilizan, es la luminosidad.

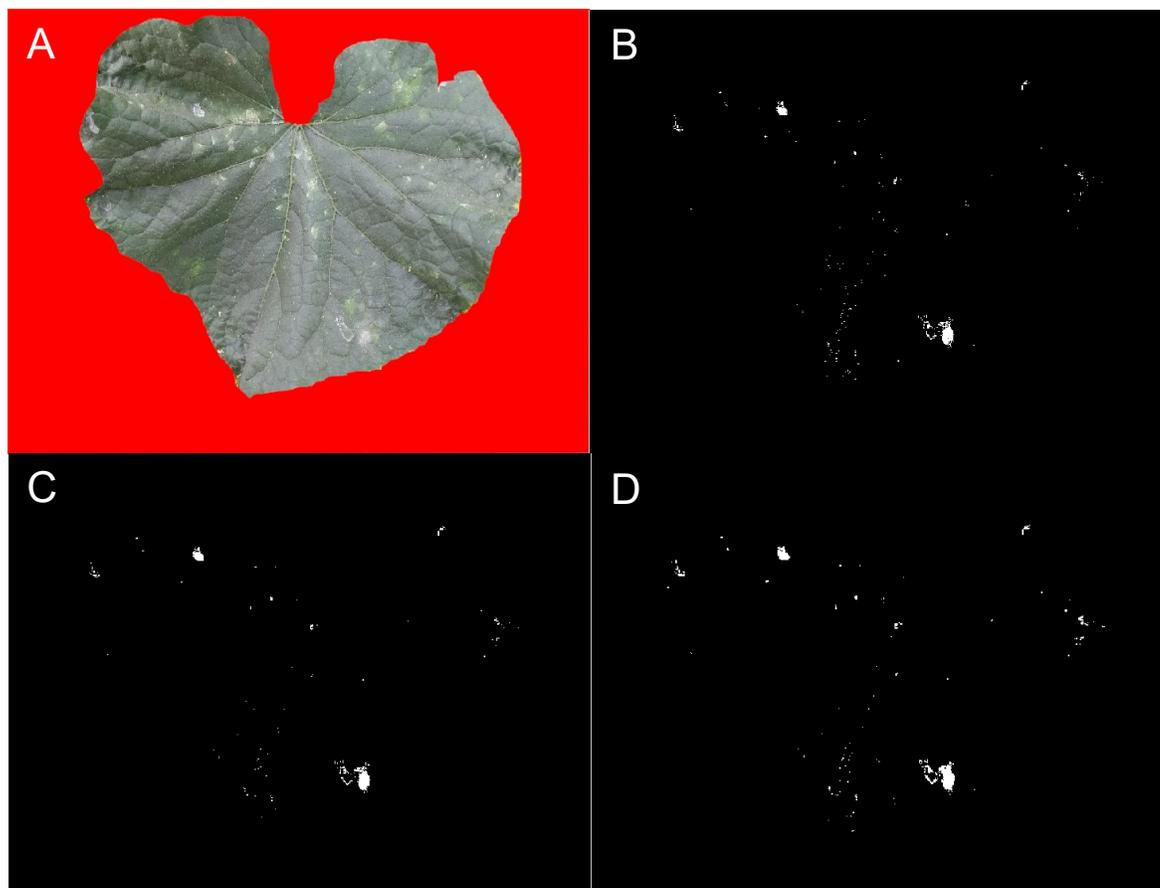


Figura 19. Binarización en base al modelo de color RGB de hoja de pepino del ciclo junio-septiembre. A) Hoja infectada con cenicilla con fondo rojo. B) Después de seleccionar pixeles cenicilla. C) Después del fspecial-imfiler a color. D) Después de la matriz convolucional.

La Figura 20 y 21 muestran los daños obtenidos en el análisis de fotografías del ciclo marzo–junio y junio–septiembre respectivamente. En estas figuras se muestra el contraste de los resultados obtenidos por los métodos de identificación de cenicilla el cual es evidente que k-medias y binarización en base a RGB detectan enfermedad en porcentajes muy elevados de acuerdo con el agrupamiento que realiza k-medias y después del filtro que aplica binarización RGB, los datos son poco confiable ya que los resultados no reflejan adecuadamente la realidad. Se muestra mayor porcentaje de afectación durante el segundo ciclo alcanzando hasta 25% de daño en la detección por binarización en base a los métodos de segmentación en escala de grises y el modelo de color RGB y mayor número de casos en porcentajes de 50% de

afectación con el método de k-medias, porcentaje mayor que el ciclo anterior debido a que las condiciones climáticas durante los meses de junio a septiembre favorecieron el crecimiento del hogo en las hojas de pepino.

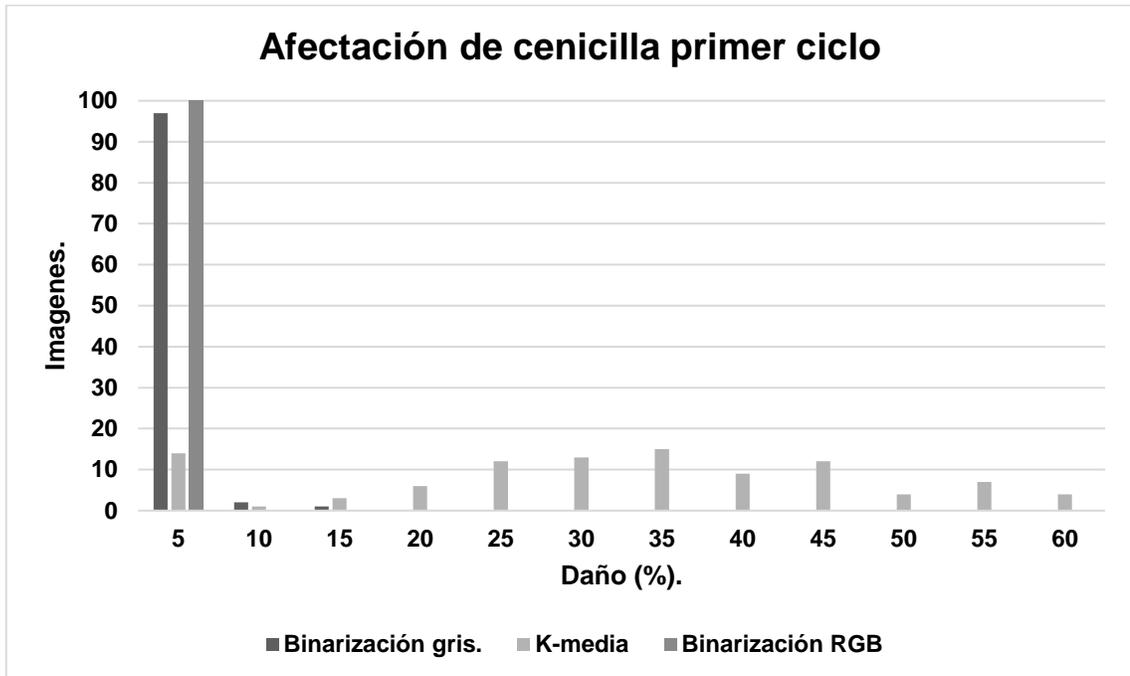


Figura 20. Registros de casos de cenicilla (marzo-junio).

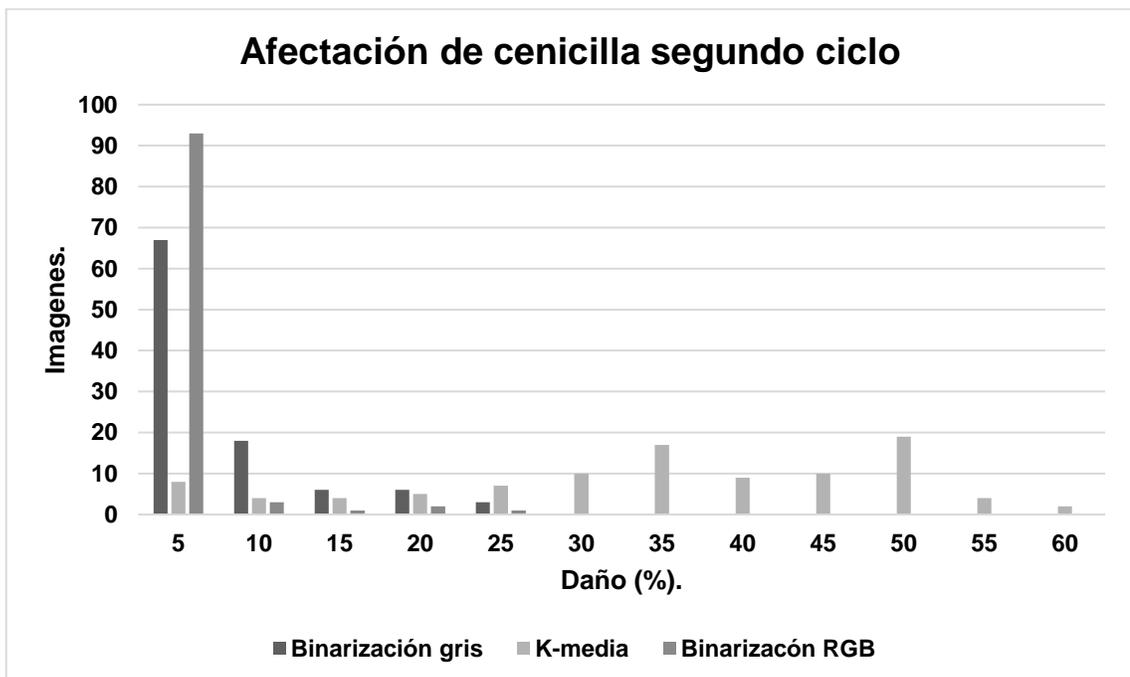


Figura 21. Registros de casos de cenicilla (junio-septiembre).

Es importante mencionar que la umbralización a través de niveles de grises nos facilita la segmentación de zonas con áreas enfermas por la diferenciación de las características del color que la imagen en escala de grises nos otorga, como el caso de Pujari *et al.* (2013) que utilizaron la matriz de coexistencia de nivel de grises (GLCM) y la matriz de longitud de ejecución del nivel de grises (GLRM) obteniendo precisión en 91.37% y 86.7% respectivamente. También se puede implementar la conversión de imágenes con escalas de grises y posteriormente binarizar como se realizó en este trabajo tal como Hlaing y Khaing (2014) lo llevaron a cabo diferenciando las plantas y el fondo de las imágenes analizadas utilizando nuevamente umbrales, en este caso calculando valores de verde menos rojo y verde menos azul, estableciendo el umbral igual a 20 ($T=20$) que probó ser una clasificación efectiva y precisa, similar a este proyecto de investigación.

Evaluación de la exactitud de las técnicas.

Los resultados de las pruebas de eficacia de las técnicas mostraron que la mejor detección se obtiene con el método de binarización en escala de grises con un 32% de exactitud, esto se puede atribuir principalmente a que cuando se lee una imagen que está convertida en escala de grises facilita su análisis ya que pasa de una matriz de tres dimensiones a una de una sola dimensión. Tal motivo hace que los datos se simplifiquen por estar en una sola escala. El método de binarización en el modelo de RGB obtuvo un 21.2% de exactitud y finalmente el menos exacto fue K-medias con un 14.9%.

Tabla 2. Exactitud de las técnicas (%).

Técnica	Binarización Gris	Binarización RGB	K-medias
Qseg	32	21.2	14.9

Según Rico-Fernández *et al.* (2019) la segmentación a través del modelo RGB tiene un porcentaje de exactitud de hasta en un 61%. Dicho porcentaje aumenta hasta el 86% cuando se utiliza el método 2G-R-B, lo que nos dice que se debe realizar una buena afinación a los métodos de segmentación presentados en

este trabajo, ya que los porcentajes presentados son muy inferiores, de tal manera el porcentaje de exactitud aumentara dando más confianza al utilizar las técnicas mencionadas y los resultados generados.

Falsos positivos.

Los resultados mostraron que todos los métodos detectan puntos de enfermedad en las 25 fotografías analizadas, las cuales son áreas sanas o que clasificadas como ruido (áreas que simulan enfermedad). Sin embargo, por el método de binarización en RGB la detección de falsos positivos es mucho menor que el reportado por los otros dos métodos, por lo que se debe revisar más a fondo ya que el filtro que se integra en el método de binarización en RGB elimina áreas que en realidad son cenicilla, es por esto que la identificación es menor con este método. Por otra parte, algunas áreas evidentemente sanas son clasificadas como enfermedad por el K-medias.

Tabla 3. Porcentajes mínimos y máximos de falsos positivos detectado por el método de binarización en escalas de grises, modelo RGB y el algoritmo K-medias en hojas sanas para ambos ciclos.

Valor de daño.		Mínimo	Máximo
Marzo – Junio. (Porcentaje de daño).	Binarización gris.	0.002	2.3344
	K-medias.	0.1261	54.4230
	Binarización RGB.	0.0017	0.1180
Junio – Septiembre. (Porcentaje de daño).	Binarización gris.	0.0055	19.6866
	K-medias.	0.1285	67.4917
	Binarización RGB.	0	11.6655

Esto se debe principalmente a que este algoritmo segmenta por grupos y la luminosidad de las imágenes puede simular el tono de la enfermedad. El método de binarización en escala de grises muestra resultados más semejantes a los de la realidad, resultados que se pueden corroborar según los datos

mostrados en la Tabla 2, este método es el más exacto para la segmentación. La Tabla 3 muestra los resultados mínimos y máximos de daño en porcentaje detectado para cada método, donde se observa que el mejor método es binarización en RGB con el mínimo de falsos detectados, seguido por binarización en escala de grises y finalmente el algoritmo k-medias, aunque la Tabla 3 nos muestra una jerarquía diferente de exactitud, siendo la binarización en escala de grises el método más exacto, siguiendo la binarización con el modelo de color RGB y finalmente el método menos eficiente es K-medias.

El algoritmo K-medias detecto por encima del 50 como máximo de daño en hojas que están totalmente sanas, esto se debe a la luminosidad que las fotografías presentaban. Para el caso específico de análisis de imágenes completas el necesario buscar métodos alternativos para la localización de centros a fin de obtener mejores resultados mediante el algoritmo K-medias.

CONCLUSIONES

En este trabajo se presentó un análisis de imágenes de hojas de pepino producido en invernadero en el que se generaron gráficas de frecuencia para conocer el porcentaje de afectación de la enfermedad de cenicilla (*Sphaerotheca fuliginea*) en las hojas del cultivo, así como la detección de falsos positivos en hojas sanas. También se logró detectar la enfermedad de cenicilla (*Sphaerotheca fuliginea*) con el análisis de segmentación de tipo binarización utilizando como umbral un porcentaje del valor más claro en el histograma de frecuencia de los tonos de gris de la imagen.

La escala de grises es un modelo de color más sencillo para la extracción de características durante el proceso de segmentación. Al igual que utilizar filtros que ayuden a resaltar las regiones segmentadas.

Utilizar los colores más claros de los histogramas generados para las imágenes convertidas a escala de grises en vez de utilizar alguna otra característica del histograma como los valles o los picos, ayudó sustancialmente a la correcta segmentación de la enfermedad en las hojas de pepino que contenían las imágenes analizadas

Para el algoritmo k-medias se recomienda trabajar más en la parte de localización de centroides para obtener mejores resultados o bien en el preprocesamiento de las imágenes para evidenciar el color real, o bien, eliminar luminosidad antes de ser analizadas por este algoritmo.

La prueba de exactitud mostro que el método de binarización en escala de grises es más adecuado para la segmentación, para este problema en particular.

Los métodos de segmentación identificaron falsos positivos por afectación por cenicilla (*Sphaerotheca fuliginea*) en las imágenes, sin embargo, los métodos de binarización detectó menor afectación comparado con el algoritmo k-medias y entre los métodos de binarización el que lo hace en escalas de grises fue el mejor.

Estos métodos de segmentación representan aplicaciones prácticas que se pueden integrar al manejo del cultivo de pepino y otros procesos agrícolas, que ayuden a reducir el uso de mano de obra y los costos de producción.

Se recomienda seguir sobre esta línea de investigación la cual ayuda a generar una gran base de datos los cuales fomentan la automatización en el sector agrícola.

La emergencia de nuevas tecnologías son factor importante en el manejo integral no solo del cultivo de pepino y en la detección de cenicilla (*Sphaerotheca fuliginea*), si no en gran variedad de cultivos y de los problemas nutrimentales, fitopatógenos o ambientales que se suscitan.

REFERENCIAS

- Abdullah, S. N. H. S., Abdullah, S., Petrou, M., Abdullah, S., Fitriyanshah, A., y Razalan, M. H. A. (2016). A portable rice disease diagnosis tool based on bi-level color image thresholding. *Applied Engineering in Agriculture*, 32(4), 295-310.
- Akram, T., Naqvi, S. R., Haider, S. A., y Kamran, M. (2017). Towards real-time crops surveillance for disease classification: exploiting parallelism in computer vision. *Computers & Electrical Engineering*, 59, 15-26.
- Al Bashish, D., Braik, M., y Bani-Ahmad, S. (2011). Detection and classification of leaf diseases using K-means-based segmentation and. *Information Technology Journal*, 10(2), 267-275.
- Alaghi, A., Li, C., y Hayes, J. P. (2013). Stochastic circuits for real-time image-processing applications. In *2013 50th ACM/EDAC/IEEE Design Automation Conference (DAC)*, 1-6. IEEE.
- Al-Amri, S. S., & Kalyankar, N. V. (2010). Image segmentation by using threshold techniques. *JOURNAL OF COMPUTING* 2(5): 83–86.
- Alchanatis, V., y Cohen, Y. (2016). Spectral and spatial methods of hyperspectral image analysis for estimation of biophysical and biochemical properties of agricultural crops. In *Hyperspectral remote sensing of vegetation*, 324-343.
- Almeida, P. J., Napp, D., y Pinto, R. (2016). Superregular matrices and applications to convolutional codes. *Linear Algebra and its Applications*, 499, 1-25.
- Al-Tairi, Z. H., Rahmat, R. W. O., Saripan, M. I., y Sulaiman, P. S. (2014). Skin Segmentation Using YUV and RGB Color Spaces. *JIPS*, 10(2), 283-299.
- Alvarado, J. D., & Fernández, J. (2012). Análisis de textura en imágenes a escala de grises, utilizando patrones locales binarios (LBP). *ENGI Revista Electrónica de La Facultad de Ingeniería*, 1(1).
- Angulo, J., & Serra, J. (2005). Segmentación de imágenes en color utilizando histogramas bi-variables en espacios color polares luminancia/saturación/matiz. *Computación y Sistemas*, 8(4), 303-316.
- Arbace, L., Sonnino, E., Callieri, M., Dellepiane, M., Fabbri, M., Idelson, A. I., y Scopigno, R. (2013). Innovative uses of 3D digital technologies to assist the restoration of a fragmented terracotta statue. *Journal of Cultural Heritage*, 14(4), 332-345.
- Arribas, J. I., Sánchez-Ferrero, G. V., Ruiz-Ruiz, G., y Gómez-Gil, J. (2011). Leaf classification in sunflower crops by computer vision and neural networks. *Computers and Electronics in Agriculture*, 78(1), 9-18.
- Atmaja, R. D., Murti, M. A., Halomoan, J., & Suratman, F. Y. (2016). An image processing method to convert RGB image into binary. *Indonesian Journal of Electrical Engineering and Computer Science*, 3(2), 377-382.

- Báez Rojas, J. J., & Pérez, A. (2008). Uso del sistema HSI para asignar falso color a objetos en imágenes digitales. *Revista mexicana de física E*, 54(2), 186-192.
- Báez Rojas, J. J., Guerrero, M. L., Conde Acevedo, J., Padilla Vivanco, A., & Urcid Serrano, G. (2004). Segmentación de imágenes de color. *Revista mexicana de física*, 50(6), 579-587.
- Bai, X. D., Cao, Z. G., Wang, Y., Yu, Z. H., Zhang, X. F., y Li, C. N. (2013). Crop segmentation from images by morphology modeling in the CIE L* a* b* color space. *Computers and electronics in agriculture*, 99, 21-34.
- Balaguer, A., Ruiz, L. A., Hermosilla, T., y Recio, J. A. (2010). Definition of a comprehensive set of texture semivariogram features and their evaluation for object-oriented image classification. *Computers & Geosciences*, 36(2), 231-240.
- Barbedo, J. G. A. (2013). Digital image processing techniques for detecting, quantifying and classifying plant diseases. *SpringerPlus*, 2(1), 660.
- Basilio, J. A. M., Torres, G. A., Pérez, G. S., Medina, K. T., & Meana, H. M. P. (2012). Novedosa técnica para la detección de imágenes pornográficas empleando modelos de color HSV y YCbCr. *Revista Facultad de Ingeniería*, (64), 79-90.
- Bendig, J., Bolten, A., Bennertz, S., Broscheit, J., Eichfuss, S., y Bareth, G. (2014). Estimating biomass of barley using crop surface models (CSMs) derived from UAV-based RGB imaging. *Remote sensing*, 6(11), 10395-10412.
- Bendig, J., Yu, K., Aasen, H., Bolten, A., Bennertz, S., Broscheit, J., ... y Bareth, G. (2015). Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. *International Journal of Applied Earth Observation and Geoinformation*, 39, 79-87.
- Bhandari, A. K., Kumar, A., y Singh, G. K. (2012). Feature extraction using Normalized Difference Vegetation Index (NDVI): A case study of Jabalpur city. *Procedia technology*, 6, 612-621.
- Bhandari, A. K., Singh, V. K., Kumar, A., y Singh, G. K. (2014). Cuckoo search algorithm and wind driven optimization based study of satellite image segmentation for multilevel thresholding using Kapur's entropy. *Expert Systems with Applications*, 41(7), 3538-3560.
- Bhange, M. A., & Hingoliwala, H. A. (2015). A review of image processing for pomegranate disease detection. *International Journal of Computer Science and Information Technologies*, 6(1), 92-94.
- Blaber, J., Adair, B., y Antoniou, A. (2015). Ncorr: open-source 2D digital image correlation matlab software. *Experimental Mechanics*, 55(6), 1105-1122.
- Brooks, D. A., y Miller-Clemente, R. (2012). Análisis de la calidad diagnóstica de imágenes de tomografía computarizada procesadas con un filtro bilateral. *Imagen Diagnóstica*, 3(2), 50-55.

- Burgos-Artizzu, X. P., Ribeiro, A., Guijarro, M., y Pajares, G. (2011). Real-time image processing for crop/weed discrimination in maize fields. *Computers and Electronics in Agriculture*, 75(2), 337-346.
- Camacho, J. K. C., Peña, N. E. C., & Guzmán, N. G. (2014). Determinación del color del exocarpio como indicador de desarrollo fisiológico y madurez en la guayaba pera (*Psidium guajava* cv. Guayaba pera), utilizando técnicas de procesamiento digital de imágenes (exocarp color determination as indicator of physiolog. *Revista EIA*, 10(19), 79-89.
- Candiago, S., Remondino, F., De Giglio, M., Dubbini, M., y Gattelli, M. (2015). Evaluating multispectral images and vegetation indices for precision farming applications from UAV images. *Remote sensing*, 7(4), 4026-4047.
- Castillo, A., Ortegon, J., Vazquez, J., y Rivera, J. (2014). Virtual laboratory for digital image processing. *IEEE Latin America Transactions*, 12(6), 1176-1181.
- Celebi, M. E., Kingravi, H. A., & Vela, P. A. (2013). A comparative study of efficient initialization methods for the k-means clustering algorithm. *Expert systems with applications*, 40(1), 200-210.
- Chakrabarti, A., y Zickler, T. (2011). Statistics of real-world hyperspectral images. In *CVPR 2011*, 193-200. IEEE.
- Chaves-González, J. M., Vega-Rodríguez, M. A., Gómez-Pulido, J. A., y Sánchez-Pérez, J. M. (2010). Detecting skin in face recognition systems: A colour spaces study. *Digital Signal Processing*, 20(3), 806-823.
- Cheddad, A., Condell, J., Curran, K., y Mc Kevitt, P. (2010). Digital image steganography: Survey and analysis of current methods. *Signal processing*, 90(3), 727-752.
- Chen, T. J., y Chuang, K. S. (2010). A pseudo lossless image compression method. In *2010 3rd International Congress on Image and Signal Processing* (2), 610-615. IEEE.
- Chen, Y. R., Chao, K., & Kim, M. S. (2002). Machine vision technology for agricultural applications. *Computers and electronics in Agriculture*, 36(2-3), 173-191.
- Chernov, V., Alander, J., y Bochko, V. (2015). Integer-based accurate conversion between RGB and HSV color spaces. *Computers & Electrical Engineering*, 46, 328-337.
- Chien, C. L., y Tseng, D. C. (2011). Color image enhancement with exact HSI color model. *International journal of innovative computing, information and control*, 7(12), 6691-6710.
- Choudhury, S. D., Stoerger, V., Samal, A., Schnable, J. C., Liang, Z., y Yu, J. G. (2016). Automated vegetative stage phenotyping analysis of maize plants using visible light images. In *KDD workshop on data science for food, energy and water, San Francisco, California, USA*.

- Chowdhury, M. M. H., y Khatun, A. (2012). Image compression using discrete wavelet transform. *International Journal of Computer Science Issues (IJCSI)*, 9(4), 327.
- Chumuang, N., Thaiparnit, S., y Ketcham, M. (2016). Algorithm Design in Leaf Surface Separation by Degree in HSV Color Model and Estimation of Leaf Area by Linear Regression. In *2016 12th International Conference on Signal-Image Technology & Internet-Based Systems (SITIS)*, 628-631. IEEE.
- Ciesielski, K. C., Udupa, J. K., Falcao, A. X., y Miranda, P. A. (2012). Fuzzy connectedness image segmentation in graph cut formulation: A linear-time algorithm and a comparative analysis. *Journal of Mathematical Imaging and Vision*, 44(3), 375-398.
- Comba, L., Gay, P., Piccarolo, P., & Ricauda Aimonino, D. (2010, September). Robotics and automation for crop management: trends and perspective. In *Int Conf on Work Safety and Risk Prevention in Agro-Food and Forest Systems: September*. pp(pp. 471-478).
- Conde-Acevedo, J. C., & Báez-Rojas, J. J. (2000). Conversión de un conjunto de imágenes multiespectrales a un sistema RGB. *Revista Mexicana de Física*, 46(1), 45-51.
- Costa, A. F., Humpire-Mamani, G., & Traina, A. J. M. (2012, August). An efficient algorithm for fractal analysis of textures. In *2012 25th SIBGRAPI Conference on Graphics, Patterns and Images* (pp. 39-46). IEEE.
- Cuevas, E., y Ortega-Sánchez, N. (2013). El algoritmo de búsqueda armónica y sus usos en el procesamiento digital de imágenes. *Computación y sistemas*, 17(4), 543-560.
- Cuevas, E., y Sossa, H. (2013). A comparison of nature inspired algorithms for multi-threshold image segmentation. *Expert Systems with Applications*, 40(4), 1213-1219.
- Dawson-Howe, K. (2014). *A practical introduction to computer vision with opencv*. John Wiley & Sons.
- de Castro, A. I., Jurado-Expósito, M., Peña-Barragán, J. M., y López-Granados, F. (2012). Airborne multi-spectral imagery for mapping cruciferous weeds in cereal and legume crops. *Precision Agriculture*, 13(3), 302-321.
- De los Santos, A. (2010). Fundamentos Visuales II. Teoría del Color. *IDAT Diseño Gráfico*, 11.
- de Miguel Benito, D. (2005). Detección automática del color de la piel en imágenes bidimensionales basado en el análisis de regiones. *Universidad Rey Juan Carlos, España*.
- DeChant, C., Wiesner-Hanks, T., Chen, S., Stewart, E. L., Yosinski, J., Gore, M. A., ... & Lipson, H. (2017). Automated identification of northern leaf blight-infected maize plants from field imagery using deep learning. *Phytopathology*, 107(11),

1426-1432.

- Denemark, T., Sedighi, V., Holub, V., Cogranne, R., y Fridrich, J. (2014). Selection-channel-aware rich model for steganalysis of digital images. In *2014 IEEE International Workshop on Information Forensics and Security (WIFS)* (pp. 48-53). IEEE.
- Depcik, C., & Assanis, D. N. (2005). Graphical user interfaces in an engineering educational environment. *Computer Applications in Engineering Education*, 13(1), 48-59.
- Dhanachandra, N., Manglem, K., & Chanu, Y. J. (2015). Image segmentation using K-means clustering algorithm and subtractive clustering algorithm. *Procedia Computer Science*, 54, 764-771.
- Drăguț, L., Tiede, D., y Levick, S. R. (2010). ESP: a tool to estimate scale parameter for multiresolution image segmentation of remotely sensed data. *International Journal of Geographical Information Science*, 24(6), 859-871.
- Dubey, S. R., & Jalal, A. S. (2012). Detection and classification of apple fruit diseases using complete local binary patterns. In *2012 Third International Conference on Computer and Communication Technology* (pp. 346-351). IEEE.
- Dubey, S. R., & Jalal, A. S. (2016). Apple disease classification using color, texture and shape features from images. *Signal, Image and Video Processing*, 10(5), 819-826.
- Eldén, L. (2007). *Matrix methods in data mining and pattern recognition* (Vol. 4). SIAM.
- Es-saady, Y., El Massi, I., El Yassa, M., Mammass, D., & Benazoun, A. (2016, May). Automatic recognition of plant leaves diseases based on serial combination of two SVM classifiers. In *2016 International Conference on Electrical and Information Technologies (ICEIT)* (pp. 561-566). IEEE.
- Everingham, M., Eslami, S. A., Van Gool, L., Williams, C. K., Winn, J., y Zisserman, A. (2015). The pascal visual object classes challenge: A retrospective. *International journal of computer vision*, 111(1), 98-136.
- Fallah Shamsi, S. R., Zare, S., y Abtahi, S. A. (2013). Soil salinity characteristics using moderate resolution imaging spectroradiometer (MODIS) images and statistical analysis. *Archives of Agronomy and Soil Science*, 59(4), 471-489.
- Fan, H., Ren, L., Meng, X., Song, T., Meng, K., y Yu, Y. (2014). Proteome-level investigation of Cucumis sativus-derived resistance to *Sphaerotheca fuliginea*. *Acta physiologiae plantarum*, 36(7), 1781-1791.
- Fan, F., Ma, Y., Li, C., Mei, X., Huang, J., y Ma, J. (2017). Hyperspectral image denoising with superpixel segmentation and low-rank representation. *Information Sciences*, 397, 48-68.
- Fiorani, F., Rascher, U., Jahnke, S., y Schurr, U. (2012). Imaging plants dynamics in

heterogenic environments. *Current opinion in biotechnology*, 23(2), 227-235.

- Flórez, C. A. C., Sandoval, O. L. R., & Hurtado, D. A. (2015). Procesamiento de imágenes para reconocimiento de daños causados por plagas en el cultivo de *Begonia semperflorans* (flor de azúcar). *Acta Agronómica*, 64(3), 273-279.
- Fontana, A. B., Lerda, N., Delannoy, M. M., Alessi, A. C., y Riquelme, B. D. (2012). Técnica de cuantificación de la agregación eritrocitaria por análisis digital de imágenes. *Acta bioquímica clínica latinoamericana*, 46(1).
- Forero, M. G., Merchan, M. C., & Ruiz, C. A. M. (2016). Análisis de técnicas de binarización basadas en histogramas 2d. *Ingeniería: Ciencia, Tecnología e Innovación*, 3(2), 24-34.
- Fridrich, J., y Kodovsky, J. (2012). Rich models for steganalysis of digital images. *IEEE Transactions on Information Forensics and Security*, 7(3), 868-882.
- Gan, G., Ma, C., & Wu, J. (2007). *Data clustering: theory, algorithms, and applications* (Vol. 20). Siam.
- Ganesan, P., Rajini, V., Sathish, B. S., Kalist, V., y Basha, S. K. (2015). Satellite image segmentation based on YCbCr color space. *Indian Journal of Science and Technology*, 8(1), 35.
- Garcia-Lamont, F., Cervantes, J., López, A., y Rodríguez, L. (2018). Segmentation of images by color features: A survey. *Neurocomputing*, 292, 1-27.
- Gebhardt, S., y Kühbauch, W. (2007). A new algorithm for automatic *Rumex obtusifolius* detection in digital images using colour and texture features and the influence of image resolution. *Precision Agriculture*, 8(1-2), 1-13.
- Gée, C., Bossu, J., Jones, G., y Truchetet, F. (2008). Crop/weed discrimination in perspective agronomic images. *Computers and Electronics in Agriculture*, 60(1), 49-59.
- Ghosh, A., Mishra, N. S., y Ghosh, S. (2011). Fuzzy clustering algorithms for unsupervised change detection in remote sensing images. *Information Sciences*, 181(4), 699-715.
- Ghosh, S., y Dubey, S. K. (2013). Comparative analysis of k-means and fuzzy c-means algorithms. *International Journal of Advanced Computer Science and Applications*, 4(4).
- Gómez Vargas, E., Obregón Neira, N., y Rocha Arango, D. F. (2013). Cloud segmentation methods applied to satellite images. *Tecnura*, 17(36), 96-110.
- Güneş, A., Kalkan, H., y Durmuş, E. (2016). Optimizing the color-to-grayscale conversion for image classification. *Signal, Image and Video Processing*, 10(5), 853-860.
- Guoxiang, S., Yongbo, L., Xiaochan, W., Guyue, H., Xuan, W., y Yu, Z. (2016). Image segmentation algorithm for greenhouse cucumber canopy under various

natural lighting conditions. *International Journal of Agricultural and Biological Engineering*, 9(3), 130-138.

Gupta, D., y Choubey, S. (2015). Discrete wavelet transform for image processing. *International Journal of Emerging Technology and Advanced Engineering*, 4(3), 598-602.

Guzman, O. A., Gómez, E. O., RIVILLAS, C., & OLIVEROS, C. (2004). Utilización del procesamiento de imágenes para determinar la severidad de la mancha de hierro en hojas de café. *Cenicafé* 54(3): 258–65.

Hall, S. A., Bornert, M., Desrues, J., Pannier, Y., Lenoir, N., Viggiani, G., y Bésuelle, P. (2010). Discrete and continuum analysis of localised deformation in sand using X-ray μ CT and volumetric digital image correlation. *Géotechnique*, 60(5), 315.

Hasegawa, K., Matsuyama, H., Tsuzuki, H., y Sweda, T. (2010). Improving the estimation of leaf area index by using remotely sensed NDVI with BRDF signatures. *Remote Sensing of Environment*, 114(3), 514-519.

Haug, S., Michaels, A., Biber, P., y Ostermann, J. (2014). Plant classification system for crop/weed discrimination without segmentation. In *IEEE winter conference on applications of computer vision* (pp. 1142-1149). IEEE.

Heinz, S. R., y Wiggins, J. S. (2010). Uniaxial compression analysis of glassy polymer networks using digital image correlation. *Polymer Testing*, 29(8), 925-932.

Hernández-Hernández, J. L., García-Mateos, G., González-Esquivá, J. M., Escarabajal-Henarejos, D., Ruiz-Canales, A., y Molina-Martínez, J. M. (2016). Optimal color space selection method for plant/soil segmentation in agriculture. *Computers and Electronics in Agriculture*, 122, 124-132.

Hlaing, S. H., & Khaing, A. S. (2014). Weed and crop segmentation and classification using area thresholding. *IJRET*, 3, 375-382.

Horbach, R., Navarro-Quesada, A. R., Knogge, W., & Deising, H. B. (2011). When and how to kill a plant cell: infection strategies of plant pathogenic fungi. *Journal of plant physiology*, 168(1), 51-62.

Hu, Q., Luo, S., Qiao, Y., y Qian, G. (2008). Supervised grayscale thresholding based on transition regions. *Image and vision computing*, 26(12), 1677-1684.

Jain, A. K. (2010). Data clustering: 50 years beyond K-means. *Pattern recognition letters*, 31(8), 651-666.

Jeon, H. Y., Tian, L. F., y Zhu, H. (2011). Robust crop and weed segmentation under uncontrolled outdoor illumination. *Sensors*, 11(6), 6270-6283.

Jiménez, A. V. P., Rojas, C. A. P., & Guzman, L. E. S. (2016). Procesamiento de imágenes para la identificación de plagas en los cultivos de espinaca. In *2016 IEEE Colombian Conference on Robotics and Automation (CCRA)* (pp. 1-7).

IEEE.

- Juárez, M. G. Y., de la Rocha, J. F. L., Angulo, T. P. G., Luque, R. G., Meza, M. L., Ortega, J. E. C., y Díaz, L. C. Alternativas para el control de la cenicilla (*Oidium* sp.) en pepino (*Cucumis sativus* L.)* Alternatives for the control of powdery mildew (*Oidium* sp.) in cucumbers (*Cucumis sativus* L.).
- Jurado-Expósito, M., López-Granados, F., Atenciano, S., Garcia-Torres, L., y González-Andújar, J. L. (2003). Discrimination of weed seedlings, wheat (*Triticum aestivum*) stubble and sunflower (*Helianthus annuus*) by near-infrared reflectance spectroscopy (NIRS). *Crop Protection*, 22(10), 1177-1180.
- Kamdi, S., y Krishna, R. K. (2012). Image segmentation and region growing algorithm. *International Journal of Computer Technology and Electronics Engineering (IJCTEE)*, 2(1), 53-57.
- Kang, B. J., Kim, H. S., Park, C. S., Choi, J. J., Lee, J. H., y Choi, B. G. (2011). Acceptable compression ratio of full-field digital mammography using JPEG 2000. *Clinical radiology*, 66(7), 609-613.
- Karasulu, B., y Korukoglu, S. (2011). A simulated annealing-based optimal threshold determining method in edge-based segmentation of grayscale images. *Applied Soft Computing*, 11(2), 2246-2259.
- Kaur, J., Agrawal, S., & Vig, R. (2012). A comparative analysis of thresholding and edge detection segmentation techniques. *International Journal of computer applications*, 39(15), 29-34.
- Kaur, M., Gupta, S., Sandhu, P. S., y Kaur, J. (2010). A dynamic RGB intensity based steganography scheme. *World Academy of Science, Engineering and Technology*, 67, 833-838.
- Kavitha, C., Rao, B. P., y Govardhan, A. (2011). Image retrieval based on color and texture features of the image sub-blocks. *International Journal of Computer Applications*, 15(7), 33-37.
- Kim, S. W., y Kim, N. S. (2013). Dynamic characteristics of suspension bridge hanger cables using digital image processing. *NDT & E International*, 59, 25-33.
- Kirchner, M., y Fridrich, J. (2010). On detection of median filtering in digital images. In *Media forensics and security II* (Vol. 7541, p. 754110). International Society for Optics and Photonics.
- Kirk, K., Andersen, H. J., Thomsen, A. G., Jørgensen, J. R., & Jørgensen, R. N. (2009). Estimation of leaf area index in cereal crops using red-green images. *Biosystems Engineering*, 104(3), 308-317.
- Korobiichuk, V., Shamrai, V., Iziyova, O., Tolkach, O., y Sobolevskiy, R. (2016). Definition of hue of different types of pokostivskiy granodiorite using digital image processing. *Восточно-Европейский журнал передовых технологий*, 4(5), 52-57.

- Langerholc, M., Slavič, J., y Boltežar, M. (2013). Absolute nodal coordinates in digital image correlation. *Experimental Mechanics*, 53(5), 807-818.
- Lee, S. H., Chang, Y. L., & Chan, C. S. (2017). LifeClef 2017 Plant Identification Challenge: Classifying Plants using Generic-Organ Correlation Features. *CEUR Workshop Proceedings* 1866(1): 1–9.
- Leijenaar, R. T., Nalbantov, G., Carvalho, S., Van Elmpt, W. J., Troost, E. G., Boellaard, R., y Lambin, P. (2015). The effect of SUV discretization in quantitative FDG-PET Radiomics: the need for standardized methodology in tumor texture analysis. *Scientific reports*, 5, 11075.
- Lezama, J. (2017). Compresión de imágenes-Codificación de Huffman. *Revista de educación matemática*, 32(1).
- Liu, G. H., y Yang, J. Y. (2013). Content-based image retrieval using color difference histogram. *Pattern recognition*, 46(1), 188-198.
- Liu, G. H., Zhang, L., Hou, Y. K., Li, Z. Y., y Yang, J. Y. (2010). Image retrieval based on multi-texton histogram. *Pattern Recognition*, 43(7), 2380-2389.
- Liu, Q., & Ying, J. (2012, June). Grayscale image digital watermarking technology based on wavelet analysis. In *2012 IEEE Symposium on Electrical & Electronics Engineering (EEESYM)* (pp. 618-621). IEEE.
- Lo, C. C., y Hu, Y. C. (2014). A novel reversible image authentication scheme for digital images. *Signal processing*, 98, 174-185.
- López-Rubio, E. (2010). Restoration of images corrupted by Gaussian and uniform impulsive noise. *Pattern Recognition*, 43(5), 1835-1846.
- Ma, S., Pang, J., y Ma, Q. (2012). The systematic error in digital image correlation induced by self-heating of a digital camera. *Measurement Science and Technology*, 23(2), 025403.
- Mahlein, A. K., Rumpf, T., Welke, P., Dehne, H. W., Plümer, L., Steiner, U., y Oerke, E. C. (2013). Development of spectral indices for detecting and identifying plant diseases. *Remote Sensing of Environment*, 128, 21-30.
- Maini, R., y Aggarwal, H. (2010). A comprehensive review of image enhancement techniques. *Journal of Computing* 2(3), 8-13..
- Makbol, N. M., y Khoo, B. E. (2013). Robust blind image watermarking scheme based on redundant discrete wavelet transform and singular value decomposition. *AEU-International Journal of Electronics and Communications*, 67(2), 102-112.
- Marchesotti, L., Perronnin, F., Larlus, D., y Csurka, G. (2011). Assessing the aesthetic quality of photographs using generic image descriptors. In *2011 International Conference on Computer Vision*, 1784-1791. IEEE.
- Martín Sotoca, J. J. (2017). *Método de segmentación basado en la estructura fractal del mapa de singularidades: aplicación a imágenes de uso agrícola* (Doctoral

dissertation, Agronomica).

- Martínez Verdú, F. M. (2001). *Diseño de un colorímetro triestímulo a partir de una cámara CCD-RGB*. Universitat Politècnica de Catalunya.
- Méndez-Vázquez, H., Chang, L., Rizo-Rodríguez, D., y Morales-González, A. (2012). Evaluación de la calidad de las imágenes de rostros utilizadas para la identificación de las personas. *Computación y Sistemas*, 16(2), 147-165.
- Meyer, G. E., Neto, J. C., Jones, D. D., y Hindman, T. W. (2004). Intensified fuzzy clusters for classifying plant, soil, and residue regions of interest from color images. *Computers and electronics in agriculture*, 42(3), 161-180.
- Meyer, G. E., y Neto, J. C. (2008). Verification of color vegetation indices for automated crop imaging applications. *Computers and electronics in agriculture*, 63(2), 282-293.
- Molina, D., Pérez-Beteta, J., Martínez-González, A., Martino, J., Velásquez, C., Arana, E., y Pérez-García, V. M. (2016). Influence of gray level and space discretization on brain tumor heterogeneity measures obtained from magnetic resonance images. *Computers in biology and medicine*, 78, 49-57.
- Montalvo, M., Pajares, G., Guerrero, J. M., Romeo, J., Guijarro, M., Ribeiro, A., ... y Cruz, J. M. (2012). Automatic detection of crop rows in maize fields with high weeds pressure. *Expert Systems with Applications*, 39(15), 11889-11897.
- Mora, A. J. R., & Capulín, C. H. G. (2018). Plataforma de desarrollo de procesamiento de imágenes en dispositivos móviles. *Jóvenes en la Ciencia*, 4(1), 2410-2414.
- Morales, R. R. (2016). Importance of the use of the parametric logarithm in a non-supervised strategy for the image binarization. *IEEE Latin America Transactions*, 14(3), 1434-1439.
- Na, S., Xumin, L., & Yong, G. (2010). Research on k-means clustering algorithm: An improved k-means clustering algorithm. In *2010 Third International Symposium on intelligent information technology and security informatics* (pp. 63-67). IEEE.
- Nandi, C. S., Tudu, B., & Koley, C. (2014). Machine vision based techniques for automatic mango fruit sorting and grading based on maturity level and size. In *Sensing Technology: Current Status and Future Trends II* (pp. 27-46). Springer, Cham.
- Naz, S., Majeed, H., y Irshad, H. (2010). Image segmentation using fuzzy clustering: A survey. In *2010 6th international conference on emerging technologies (ICET)* (pp. 181-186). IEEE.
- Nilesh, B., Sachin, S., Pradip, N., y Rane, D. B. (2013). Image compression using discrete wavelet transform. *International Journal of Computer Technology and Electronics Engineering (IJCTEE) Volume*, 3.
- Ortiz Zamora, F. G. (2002). *Procesamiento morfológico de imágenes en color:*

aplicación a la reconstrucción geodésica.

- Padrón-Pereira, C. A. (2013). Utilización de imágenes digitales para medición del diámetro de frutos de mandarina (*Citrus reticulata*) en crecimiento. *Ciencia y Tecnología*, 6(1), 1-9.
- Pagariya, R., & Bartere, M. (2014). Review Paper on Identification of Plant Diseases Using Image Processing Technique. *International Journal of Advanced Research in Computer Engineering & Technology (IJARCET)*, 3(11).
- Pajares, G., y Cruz, J. M. (2007). Visión por Computador: Imágenes digitales y aplicaciones, RA-MA. Madrid, Spain.
- Palomares, F. G., Serrá, J. A. M., & Martínez, E. A. (2016). Aplicación de la convolución de matrices al filtrado de imágenes. *Modelling in Science Education and Learning*, 9(1), 97-108.
- Palomino, N. L. S., & Concha, U. N. R. (2009). Técnicas de segmentación en procesamiento digital de imágenes. *Revista de investigación de Sistemas e Informática*, 6(2), 9-16.
- Palomino, N. L. S., Flores, W. C., y Rivera, M. R. (2010). Procesamiento Digital de textura: Técnicas utilizadas en aplicaciones actuales de CBIR. *Revista de investigación de Sistemas e Informática*, 7(1), 57-64.
- Pan, B. (2011). Recent progress in digital image correlation. *Experimental Mechanics*, 51(7), 1223-1235.
- Peña, J. M., Torres-Sánchez, J., de Castro, A. I., Kelly, M., y López-Granados, F. (2013). Weed mapping in early-season maize fields using object-based analysis of unmanned aerial vehicle (UAV) images. *PloS one*, 8(10), e77151.
- Peña-Barragán, J. M., Ngugi, M. K., Plant, R. E., y Six, J. (2011). Object-based crop identification using multiple vegetation indices, textural features and crop phenology. *Remote Sensing of Environment*, 115(6), 1301-1316.
- Perry, E. M., y Davenport, J. R. (2007). Spectral and spatial differences in response of vegetation indices to nitrogen treatments on apple. *Computers and Electronics in Agriculture*, 59(1-2), 56-65.
- Ponti, M. P. (2012). Segmentation of low-cost remote sensing images combining vegetation indices and mean shift. *IEEE Geoscience and Remote Sensing Letters*, 10(1), 67-70.
- Prince, G., Clarkson, J. P., y Rajpoot, N. M. (2015). Automatic detection of diseased tomato plants using thermal and stereo visible light images. *PloS one*, 10(4), e0123262.
- Pryzant, R., Ermon, S., & Lobell, D. (2017). Monitoring ethiopian wheat fungus with satellite imagery and deep feature learning. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops* (pp. 39-47).

- Pujari, J. D., Yakkundimath, R. S., & Byadgi, A. S. (2013). Statistical methods for quantitatively detecting fungal disease from fruits' images. *International Journal of Intelligent Systems and Applications in Engineering*, 1(4), 60-67.
- Qian, Z., Feng, G., Zhang, X., y Wang, S. (2011). Image self-embedding with high-quality restoration capability. *Digital Signal Processing*, 21(2), 278-286.
- Rabatel, G., Gorretta, N., y Labbe, S. (2014). Getting simultaneous red and near-infrared band data from a single digital camera for plant monitoring applications: Theoretical and practical study. *Biosystems Engineering*, 117, 2-14.
- Rastogi, A., Arora, R., & Sharma, S. (2015). Leaf disease detection and grading using computer vision technology & fuzzy logic. In *2015 2nd international conference on signal processing and integrated networks (SPIN)* (pp. 500-505). IEEE.
- Rico-Fernández, M. P., Rios-Cabrera, R., Castelán, M., Guerrero-Reyes, H. I., & Juarez-Maldonado, A. (2019). A contextualized approach for segmentation of foliage in different crop species. *Computers and electronics in agriculture*, 156, 378-386.
- Roman-Gonzalez, A. (2012). Digital Images Analysis. *Revista ECIPeru*, 9(1), 61-68.
- Romeo, J., Guerrero, J., Montalvo, M., Emmi, L., Guijarro, M., Gonzalez-de-Santos, P., y Pajares, G. (2013). Camera sensor arrangement for crop/weed detection accuracy in agronomic images. *Sensors*, 13(4), 4348-4366.
- Ruiz-Ruiz, G., Gómez-Gil, J., y Navas-Gracia, L. M. (2009). Testing different color spaces based on hue for the environmentally adaptive segmentation algorithm (EASA). *Computers and Electronics in Agriculture*, 68(1), 88-96.
- Sáenz, K. D. J. B. (2016). Clasificación de los frutos de café según su estado de maduración y detección de la broca mediante técnicas de procesamiento de imágenes. *Revista Prospectiva*, 14(1), 15-22.
- Sahdra, G. S., y Kailey, K. S. (2012). Detection of Contaminants in Cotton by using YDbDr color space. *Int. J. Computer Technology & Applications*, 3(3), 1118-1124.
- Samretwit, D., y Wakahara, T. (2011). Measurement of reading characteristics of multiplexed image in QR code. In *2011 Third International Conference on Intelligent Networking and Collaborative Systems*, 552-557. IEEE.
- Sanjaya, K. W. V., Vijesekara, H. M., Wickramasinghe, I. M., & Amalraj, C. R. (2015). Orchid classification, disease identification and healthiness prediction system. *International Journal of Scientific and Technology Research*, 4(3), 215-220.
- Sankaran, S., Maja, J., Buchanon, S., y Ehsani, R. (2013). Huanglongbing (citrus greening) detection using visible, near infrared and thermal imaging techniques. *Sensors*, 13(2), 2117-2130.

- Sankaran, S., Mishra, A., Ehsani, R., & Davis, C. (2010). A review of advanced techniques for detecting plant diseases. *Computers and Electronics in Agriculture*, 72(1), 1-13.
- Sanyal, P., & Patel, S. C. (2008). Pattern recognition method to detect two diseases in rice plants. *The Imaging Science Journal*, 56(6), 319-325.
- Saravanan, C. (2010, March). Color image to grayscale image conversion. In *2010 Second International Conference on Computer Engineering and Applications* (Vol. 2, pp. 196-199). IEEE.
- Schillaci, G., Pennisi, A., Franco, F., y Longo, D. (2012). Detecting tomato crops in greenhouses using a vision based method. In *Proceedings of International Conference on Safety, Health and Welfare in Agriculture and Agro*, 3-6.
- Schmidt, U., y Roth, S. (2014). Shrinkage fields for effective image restoration. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2774-2781.
- Sethupathy, J., & Veni, S. (2016). Opencv based disease identification of mango leaves. *International Journal of Engineering Technology Science and Research-IJETS*, 8(5), 1990-1998.
- Shanmugam, M., y Asokan, R. (2015). A machine-vision-based real-time sensor system to control weeds in agricultural fields. *Sensor Letters*, 13(6), 489-495.
- Shih, H. C., & Liu, E. R. (2016). Automatic reference color selection for adaptive mathematical morphology and application in image segmentation. *IEEE transactions on Image Processing*, 25(10), 4665-4676.
- Singh, V., y Misra, A. K. (2017). Detection of plant leaf diseases using image segmentation and soft computing techniques. *Information processing in Agriculture*, 4(1), 41-49.
- Soleimanizadeh, S., Mohamad, D., Saba, T., y Rehman, A. (2015). Recognition of partially occluded objects based on the three different color spaces (RGB, YCbCr, HSV). *3D Research*, 6(3), 22.
- Soontranon, N., Srestasathiern, P., y Rakwatin, P. (2014). Rice growing stage monitoring in small-scale region using ExG vegetation index. In *2014 11th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)*, 1-5. IEEE.
- Sowmya, V., Govind, D., y Soman, K. P. (2017). Significance of incorporating chrominance information for effective color-to-grayscale image conversion. *Signal, Image and Video Processing*, 11(1), 129-136.
- Sripada, R. P., Heiniger, R. W., White, J. G., y Meijer, A. D. (2006). Aerial color infrared photography for determining early in-season nitrogen requirements in corn. *Agronomy Journal*, 98(4), 968-977.
- Stamm, M. C., Tjoa, S. K., Lin, W. S., y Liu, K. R. (2010). Anti-forensics of JPEG

- compression. In *2010 IEEE International Conference on Acoustics, Speech and Signal Processing* (pp. 1694-1697). IEEE.
- Stamm, M. C., y Liu, K. R. (2011). Anti-forensics of digital image compression. *IEEE Transactions on Information Forensics and Security*, 6(3), 1050-1065.
- Su, B., Lu, S., y Tan, C. L. (2010). Binarization of historical document images using the local maximum and minimum. In *Proceedings of the 9th IAPR International Workshop on Document Analysis Systems*, 159-166. ACM.
- Subban, R., y Mishra, R. (2014). Human skin segmentation in color images using gaussian color model. In *Recent Advances in Intelligent Informatics*, 13-21. Springer, Cham.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., y Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2818-2826.
- Tavares, J. M. R. S. (2010). Image processing and analysis: applications and trends. In *AES-ATEMA'2010 fifth international conference on advances and trends in engineering materials and their applications*, 27-41.
- Torres-Sánchez, J., López-Granados, F., De Castro, A. I., y Peña-Barragán, J. M. (2013). Configuration and specifications of an unmanned aerial vehicle (UAV) for early site specific weed management. *PloS one*, 8(3), e58210.
- Torres-Sánchez, J., López-Granados, F., y Peña, J. M. (2015). An automatic object-based method for optimal thresholding in UAV images: Application for vegetation detection in herbaceous crops. *Computers and Electronics in Agriculture*, 114, 43-52.
- Torres-Sánchez, J., Peña, J. M., de Castro, A. I., y López-Granados, F. (2014). Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV. *Computers and Electronics in Agriculture*, 103, 104-113.
- Tucker, C. C., & Chakraborty, S. (1997). Quantitative assessment of lesion characteristics and disease severity using digital image processing. *Journal of Phytopathology*, 145(7), 273-278.
- Urueña, W. A., Osorio, J. A. C., & Vargas, J. A. M. (2011). Técnicas alternativas para la conversión de imágenes a color a escala de grises en el tratamiento digital de imágenes. *Scientia et Technica*, 1(47), 207-212.
- Vala, H. J., y Baxi, A. (2013). A review on Otsu image segmentation algorithm. *International Journal of Advanced Research in Computer Engineering & Technology (IJARCET)*, 2(2), 387-389.
- Velázquez-López, N., Sasaki, Y., Nakano, K., Mejía-Muñoz, J. M., & Romanchik Kriuchkova, E. (2011). Detección de cenicilla en rosa usando procesamiento de imágenes por computadora. *Revista Chapingo. Serie horticultura*, 17(2), 151-160.

- Wang, F. M., Huang, J. F., Tang, Y. L., y Wang, X. Z. (2007). New vegetation index and its application in estimating leaf area index of rice. *Rice Science*, 14(3), 195-203.
- Wang, H., y Wang, J. (2014). An effective image representation method using kernel classification. In *2014 IEEE 26th international conference on tools with artificial intelligence*, 853-858. IEEE.
- Wang, K., Zhang, S., Wang, Z., Liu, Z., & Yang, F. (2013). Mobile smart device-based vegetable disease and insect pest recognition method. *Intelligent Automation & Soft Computing*, 19(3), 263-273.
- Wang, Q., Meng, Z., y Li, X. (2017). Locality adaptive discriminant analysis for spectral-spatial classification of hyperspectral images. *IEEE Geoscience and Remote Sensing Letters*, 14(11), 2077-2081.
- Wang, Y., y Zhang, S. (2012). Three-dimensional shape measurement with binary dithered patterns. *Applied optics*, 51(27), 6631-6636.
- Wei, Y., y Qiqiang, L. (2004). Survey on Particle Swarm Optimization Algorithm [J]. *Engineering Science*, 5(5), 87-94.
- Xiao, Y., Cao, Z., y Zhuo, W. (2011). Type-2 fuzzy thresholding using GLSC histogram of human visual nonlinearity characteristics. *Optics express*, 19(11), 10656-10672.
- Xiao, Y., Zeng, T., Yu, J., y Ng, M. K. (2011). Restoration of images corrupted by mixed Gaussian-impulse noise via l_1-l_0 minimization. *Pattern Recognition*, 44(8), 1708-1720.
- Yadav, M. K., Manohar, D. D., Mukherjee, G., y Chakraborty, C. (2013). Segmentation of chronic wound areas by clustering techniques using selected color space. *Journal of Medical Imaging and Health Informatics*, 3(1), 22-29.
- Yang, J., Ye, X., Li, K., Hou, C., y Wang, Y. (2014). Color-guided depth recovery from RGB-D data using an adaptive autoregressive model. *IEEE transactions on image processing*, 23(8), 3443-3458.
- Youlian, Z., Cheng, H., Kun, Z., & Lingjiao, P. (2015, May). Face detection method using template feature and skin color feature in rgb color space. In *The 27th Chinese Control and Decision Conference (2015 CCDC)* (pp. 6133-6137). IEEE.
- Zarate-Valdez, J. L., Whiting, M. L., Lampinen, B. D., Metcalf, S., Ustin, S. L., y Brown, P. H. (2012). Prediction of leaf area index in almonds by vegetation indexes. *Computers and electronics in agriculture*, 85, 24-32.
- Zarco-Tejada, P. J., González-Dugo, V., y Berni, J. A. (2012). Fluorescence, temperature and narrow-band indices acquired from a UAV platform for water stress detection using a micro-hyperspectral imager and a thermal camera. *Remote Sensing of Environment*, 117, 322-337.
- Zhang, X., Yan, G., Li, Q., Li, Z. L., Wan, H., y Guo, Z. (2006). Evaluating the fraction

of vegetation cover based on NDVI spatial scale correction model. *International Journal of Remote Sensing*, 27(24), 5359-5372.

Zhang, Y., Lu, K., Gao, Y., y Wang, M. (2013). NEQR: a novel enhanced quantum representation of digital images. *Quantum Information Processing*, 12(8), 2833-2860.

Zhang, Z. Y., Li, T., Ding, C., Ren, X. W., y Zhang, X. S. (2010). Binary matrix factorization for analyzing gene expression data. *Data Mining and Knowledge Discovery*, 20(1), 28.

Zhang, Z., Luo, X., Zang, Y., Hou, F., y Xu, X. (2011). Segmentation algorithm based on color feature for green crop plants. *Transactions of the Chinese Society of Agricultural Engineering*, 27(7), 183-189.

Zheng, L., Shi, D., y Zhang, J. (2010). Segmentation of green vegetation of crop canopy images based on mean shift and fisher linear discriminant. *Pattern Recognition Letters*, 31(9), 920-925.

Zhang, S., Wu, X., You, Z., & Zhang, L. (2017). Leaf image based cucumber disease recognition using sparse representation classification. *Computers and electronics in agriculture*, 134, 135-141.

Zujovic, J., Pappas, T. N., & Neuhoff, D. L. (2013). Structural texture similarity metrics for image analysis and retrieval. *IEEE Transactions on Image Processing*, 22(7), 2545-2558.

