



**EDUCACIÓN**  
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO  
NACIONAL DE MÉXICO®

Instituto Tecnológico de Acapulco



---

---

TECNOLÓGICO NACIONAL DE MÉXICO  
INSTITUTO TECNOLÓGICO DE ACAPULCO

**DETECCIÓN AUTOMÁTICA DEL DAÑO CAUSADO POR EL GUSANO  
COGOLLERO EN LA PLANTA DE MAÍZ**

TITULACIÓN INTEGRAL

TESIS PROFESIONAL

QUE PARA OBTENER EL TÍTULO DE:  
**MAESTRO EN SISTEMAS COMPUTACIONALES**

PRESENTA:  
**ING. JOSÉ LUIS BRAVO REYNA**

DIRECTOR:  
**DR. JOSÉ ANTONIO MONTERO VALVERDE**

CODIRECTOR:  
**DR. JOSÉ LUIS HERNÁNDEZ HERNÁNDEZ**

ACAPULCO, GRO. DICIEMBRE 2020

El presente trabajo de tesis fue desarrollado en la *División de Estudios de Posgrado e Investigación* del *Instituto Tecnológico de Acapulco*, perteneciente al Programa Nacional de Posgrados de Calidad (PNPC-CONACYT).

Con domicilio para recibir y oír notificaciones en Av. Instituto Tecnológico de Acapulco s/n, Crucero del Cayaco, Acapulco, Guerrero, México. C.P. 39905.

<b>Becario:</b>	Jose Luis Bravo Reyna
<b>CVU:</b>	826576
<b>Núm. de apoyo:</b>	712775
<b>Grado:</b>	Maestría



## DESCARGO DE RESPONSABILIDAD INSTITUCIONAL

Quien suscribe declara que el presente documento titulado “**Detección Automática del Daño Causado por el Gusano Cogollero en la Planta de Maíz**” es un trabajo propio y original, el cual no ha sido utilizado anteriormente en institución alguna para propósitos de evaluación, publicación y/o obtención de algún grado académico.

Además, se adelanta que se han recogido todas las fuentes de información utilizadas, las cuales han sido citadas en la sección de referencias bibliográfica de este trabajo.

Acapulco, Gro; a 15 de diciembre de 2020.

  
Jose Luis Bravo Reyna  
Nombre y Firma

## CARTA DE CESIÓN DE DERECHOS DE AUTOR

El que suscribe: Jose Luis Bravo Reyna, autor del trabajo escrito de evaluación profesional en la opción de Tesis Profesional de Maestría con el título “Detección Automática del Daño Causado por el Gusano Cogollero en la Planta de Maiz”, por medio de la presente con fundamento en lo dispuesto en los artículos 5, 18, 24, 25, 27, 30, 32 y 148 de la Ley Federal de Derechos de Autor, así como los numerales 2.15.5 de los lineamientos para la Operación de los Estudios de Posgrado; manifiesto mi autoría y originalidad de la obra mencionada que se presentó en la División de Estudios de Posgrado e Investigación, para ser evaluada con el fin de obtener el Título Profesional de Maestro en Sistemas Computacionales.

Así mismo expreso mi conformidad de ceder los derechos de reproducción, difusión y circulación de esta obra, en forma NO EXCLUSIVA, al Tecnológico Nacional de México campus Acapulco; se podrá realizar a nivel nacional e internacional, de manera parcial o total a través de cualquier medio de información que sea susceptible para ello, en una o varias ocasiones, así como en cualquier soporte documental, todo ello siempre y cuando sus fines sean académicos, humanísticos, tecnológicos, históricos, artísticos, sociales, científicos u otra manifestación de la cultura.

Entendiendo que dicha cesión no genera obligación alguna para el Tecnológico Nacional de México campus Acapulco y que podrá o no ejercer los derechos cedidos. Por lo que el autor da su consentimiento para la publicación de su trabajo escrito de evaluación profesional.

Se firma presente en la ciudad de Acapulco de Juárez, estado de Guerrero a los 14 días del mes de diciembre de 2020.



---

Jose Luis Bravo Reyna



"2020, Año de Leona Vicario, Benemérita Madre de la Patria"

Acapulco, Gro; a 7 de diciembre de 2020.

**AUTORIZACIÓN DE IMPRESIÓN DE TESIS**

Los abajo firmantes, miembros de la comisión revisora de tesis designada por la División de Estudios de Posgrado e Investigación del Tecnológico Nacional de México campus Acapulco para la evaluación de la tesis del alumno **Jose Luis Bravo Reyna**, manifiestan que después de haber revisado su tesis: "**Detección Automática del Daño Causado por el Gusano Cogollero en la Planta de Maíz**" desarrollada bajo la dirección del DIRECTOR, y el CO-DIRECTOR, el trabajo se **ACEPTA** para proceder a su impresión.

ATENTAMENTE

  
Dr. José A. Montero Valverde  
Nombre y firma del Director  
Cédula Profesional  
5662755

  
Dr. José Luis Hernández Hernández  
Nombre y firma del Co-director  
Cédula Profesional  
11063919

  
Dra. Miriam Martínez Arroyo  
Nombre y firma del Tutor  
Cédula Profesional  
5662182

  
**Enveado**  
**Dr. Enrique de la Cruz Gámez**  
Coordinador de la Maestría en Sistemas  
Computacionales



acapulco.edu.mx



Av. Instituto Tecnológico s/n Cruzera del Cayaco C. P. 39905  
e-mail de contacto:  
depi\_acapulco@tecnm.mx  
Teléfonos: (744) 4429010  
al 19 ext. 121  
www.it-



Secretaría de Educación Pública  
Instituto Tecnológico de Acapulco  
División de Estudios de Posgrado e Investigación  
Acapulco, Gro. 39905



Instituto Tecnológico de Acapulco  
División de Estudios de Posgrado e Investigación

“2020, Año de Leona Vicario, Benemérita Madre de laPatria”

**Acapulco Gro.,**

**8/Diciembre/2020** NO.

OFICIO: DEPI-203/2020

**ASUNTO:**  
AUTORIZACIÓN  
DE IMPRESIÓN DE TESIS  
PROFESIONAL

**C. JOSÉ LUIS BRAVO REYNA**

De acuerdo al reglamento de los Institutos Tecnológicos, dependiente de la Secretaría de Educación Pública y habiendo cumplido con todos los requisitos normativos respecto a su trabajo para titulación, Opción Titulación Tesis Profesional, con el proyecto titulado: DETENCIÓN AUTOMÁTICA DEL DAÑO CAUSADO POR EL GUSANO COGOLLERO EN LA PLANTA

DE MAÍZ. Se **CONCEDE** la **AUTORIZACIÓN** para que proceda a la impresión del

mismo. Sin otro particular por el momento, me es grato quedar de usted.

**A T E N T A M E N T E "**  
**Educación Tecnológica con Compromiso Social"**



SECRETARÍA DE EDUCACIÓN  
PÚBLICA  
INSTITUTO TECNOLÓGICO  
DE ACAPULCO  
DIVISIÓN DE ESTUDIOS  
DE POSGRADO E  
INVESTIGACIÓN

**EDUARDO DE LA CRUZ GÁMEZ**  
**JEFE DE LA DIVISIÓN DE ESTUDIOS**  
**DE POSGRADO E INVESTIGACIÓN**



Av. Instituto Tecnológico s/n Crucero del Cayaco C.P.  
39905 e-mail de contacto:  
depi\_acapulco@tecnm.mx  
Teléfonos: (744) 4429010 al 19 ext. 121  
www.it-acapulco.edu.mx



C.c.p. Expediente

EDG/stv

RPVL-072

Número de registro:

Fecha de emisión: 2017-04-10

## **Agradecimientos**

Quiero expresar mi agradecimiento total a Dios por la fuerza y por cada palabra de aliento que me ha dado para salir adelante y reconocer que nada de esto sería si no fuese por él.

Agradezco al Consejo Nacional de Ciencia y Tecnología (CONACyT), por el apoyo brindado el cual forma parte del trabajo realizado y agradezco a mis docentes en especial al Dr. José Antonio Montero Valverde y la Dra. Miriam Martínez Arroyo quienes me impartieron de su conocimiento en el transcurso de la maestría haciendo posible el termino el proyecto de investigación, así como también en la redacción de tesis.

Al Dr. José Antonio Montero Valverde por ser director de proyecto, gracias por impartir su conocimiento y facilitarme las herramientas para realizar el proyecto de la mejor manera.

Al Dr. Jose Luis Hernández Hernández le agradezco por su gran apoyo, amabilidad y conocimiento impartido para el termino del proyecto de investigación.

A mi amigo Jose Luis Carranza Flores y compañero de todo el transcurso de mi preparación profesional, gracias a sus consejos, correcciones, tiempo y sobre todo el gran aprecio, es menester hacer saber gran gesto en alentarme y compartir este logro a pesar de situaciones difíciles que se nos presentaron solo queda agradecer infinitamente.

## **Dedicatoria**

### **Esta tesis está dedicada:**

A mi padre José Bravo, por la paciencia de enseñarme que para conseguir cada objetivo debo ser dedicado, habrá muchas dificultades que te harán pensar en dejarlo todo, solo lucha por lo que más te gusta hacer.

A mi madre Paulita Reyna, por su grande amor, paciencia, compañía y sobre todo por estar conmigo en los momentos difíciles y como también en los momentos agradables siendo ella la motivación para seguir adelante luchando con mayor fuerza cada día.

A mis hermanos por sus palabras de aliento en cada dificultad que se presentó.

A mis hermanas agradezco su grande apoyo por alentarme y animarme en especial quiero agradecer a Griselda que en el trayecto de este proceso siempre tuvo la confianza en que podía lograrlo y por las atenciones de apoyo que sin duda fue grande.

Finalmente quiero dedicar esta tesis a mi familia en Cristo por todos los consejos y sobre todo el grande amor que me tienen al igual que yo los amo y que esto fue posible por ellos.



# Resumen

El presente trabajo consiste en un sistema que implementa técnicas de Visión Artificial para la detección automática del daño causado por el gusano cogollero en la planta de maíz. Para ello esta herramienta de software permite el análisis para determinar si existe daño o no dentro de la planta de maíz en la imagen digital.

El proceso para obtener la información se basa a imágenes digitales capturadas por una cámara fotográfica con una distancia entre 20cm a 25cm y para mejor calidad de las imágenes durante el día con luz solar la cual permitirá tener una imagen clara y visible sin dificultades para su análisis. El procesamiento digital de imágenes se aplica para segmentar y clasificar las hojas en los plantíos de maíz en los campos mexicanos haciendo uso de los modelos de color.

Las técnicas de segmentación como el método otsu para la binarización de la imagen y clasificación haciendo uso del clasificador KNN que permite realizar de manera rápido el proceso de detección.

## Índice

<b>Capítulo 1</b>	<b>Introducción</b> .....	<b>1</b>
<b>1.1</b>	<b>Antecedentes</b> .....	<b>1</b>
<b>1.2</b>	<b>Objetivo General</b> .....	<b>4</b>
<b>1.3</b>	<b>Objetivos Específicos</b> .....	<b>4</b>
<b>1.4</b>	<b>Hipótesis</b> .....	<b>4</b>
<b>1.5</b>	<b>Metodología</b> .....	<b>5</b>
<b>1.6</b>	<b>Organización de la Tesis</b> .....	<b>6</b>
<b>Capítulo 2</b>	<b>Marco Teórico</b> .....	<b>23</b>
<b>3.1</b>	<b>Introducción</b> .....	<b>23</b>
<b>3.2</b>	<b>Inteligencia Artificial</b> .....	<b>24</b>
<b>3.2.1.</b>	<b>Enfoques de la Inteligencia Artificial</b> .....	<b>25</b>
<b>3.3</b>	<b>Definición de una imagen digita</b> .....	<b>31</b>
<b>3.4</b>	<b>Espacios de color</b> .....	<b>36</b>
<b>3.5</b>	<b>El modelo RGB</b> .....	<b>39</b>
<b>3.6</b>	<b>El modelo HSI</b> .....	<b>40</b>
<b>3.7</b>	<b>Clasificador KNN</b> .....	<b>41</b>

<b>Capítulo 3</b>	<b>Trabajos Relacionados</b>	<b>7</b>
2.1.	Introducción	7
2.2	Identificación de la Enfermedad Botrytis Cinérea en la Granada Utilizando K- MEANS	7
2.3	Detección de Cenicilla en Rosa Usando Procesamiento de Imágenes por Computadora.	11
2.4	Procesamiento de Imágenes Aplicadas a la Identificación de Agentes Patógenos en el Cultivo de Plátano	13
2.5	Sistema de Visión para Agricultura de Precisión Identificación en Tiempo Real de Líneas de Cultivo y Malas Hierbas en Campos de Maíz	15
2.6	Procesamiento de Imágenes para la Identificación de Plagas en los Cultivos de Espinaca	16
2.7	Procesamiento de Imágenes para Reconocimiento de Daños Causados por Plagas en el Cultivo de Begonia Flor de Azúcar	17
2.8	Aplicación móvil PlagAPP	18
2.9	Avances en el procesamiento de imágenes para la detección de las enfermedades de las plantas	20
<b>Capítulo 4</b>	<b>Metodología</b>	<b>44</b>
4.1	Introducción	44
4.2	Metodología Utilizada	44
4.3	Adquisición de la Imagen	45
4.4	Preprocesamiento	50
4.5	Segmentación	54

<b>4.6 Extracción de Características.....</b>	<b>60</b>
<b>4.6.1 Clasificación .....</b>	<b>62</b>
<b>Capítulo 5 Pruebas y Resultados .....</b>	<b>73</b>
<b>Capítulo 6 Conclusiones y Trabajo Futuro.....</b>	<b>81</b>
<b>Bibliografía.....</b>	<b>85</b>

## Índice de Figuras

Figura 1.1 Niveles de daño en cultivo [17].....	15
Figura 1.2 Metodología en visión computacional [20].....	17
Figura 2.1 Imagen con 256 niveles de intensidad y fragmento 8x8[26].....	22
Figura 2.2 Representación gráfica del modelo RGB [12].....	25
Figura 2.3 Modelo de color HSI [13].....	26
Figura 2.8 Función del LBP.....	28
Figura 2.5 Conjunto de datos clasificados en dos categorías [15].....	29
Figura 2.6 Clasificación de un nuevo vector de datos.....	29
Figura 2.7 Selección de los K=5 vecinos más cercanos al nuevo elemento [15].....	30
Figura 2.8. 3 elementos de la categoría 1 y 2 elementos de la categoría 2[15].....	31
Figura 2.9 Asignación del nuevo elemento [15].....	31
Figura 3.1 Metodología de desarrollo [28].....	33
Figura 3.2 Granada contaminada [29].....	33
Figura 3.3 Aplicación de filtros [29].....	35
Figura 3.4 Aplicación de RGB [29].....	37
Figura 3.4 Hoja con SIGATOKA Neura [30].....	38
Figura 3.5 Adquisición de imagen [30].....	38
Figura 3.6 Procesamiento de imagen [30].....	39
Figura 3.7 Metodología [31].....	41
Figura 3.8 Metodología Compuesta [31].....	41
Figura 3.9 Aplicación de Verde [31].....	42
Figura 3.14 Imagen en rojo [33].....	43

Figura 3.15 PLAGAPP [21].....	44
Figura 3.16 PlagApp Móvil [21].....	45
Figura 3.17 Hoja enferma.....	46
Figura 4.1 Metodología consideradas en el proyecto.....	47
Figura 4.2 Hoja de la planta de Maíz.....	48
Figura 4.3. Modelo de color HSI [23].....	49
Figura 4.4 Canal de interés I.....	50
Figura 4.5. Imagen binarizada.....	52
Figura 4.6 Imagen segmentada de la región de interés.....	53
Figura 4.7 Identificar las regiones de interés del daño.....	54
Figura 4.8 Función del LBP [26].....	55
Figura 4.9 Extracción de características.....	55
Figura 4.10 Características de imágenes.....	56
Figura 4.11 Imágenes digitales.....	57
Figura 4.13 DataSet.....	57
Figura 4.14 Carpetas de imágenes binarizadas.....	58
Figura 5.2 Imágenes RGB de daños causados por el gusano cogollero.....	59

## Índice de Tablas.

Tabla 2.1 Técnicas utilizadas para el reconocimiento .....	20
--	----

# Capítulo 1

# Introducción

## 1.1 Antecedentes

Muchas enfermedades y plagas de los diferentes cultivos atacan las cosechas y disminuyen la calidad del producto, limitan la disponibilidad de alimentos y materias primas, el impacto que esto tiene para las personas que dependen de la agricultura es muy grande [2].

Los daños que pueden causar en los sembradíos son diversos, pueden provocar pérdidas de cultivos esto ocasiona peligro en los medios de subsistencia de agricultores vulnerables, la seguridad alimentaria y nutricional de millones de personas [3].

En diferentes áreas de trabajo los sistemas de visión artificial ofrecen una alternativa automatizada, que sustituyen los métodos de inspección manual tradicional y se han convertido en una respuesta sencilla y eficaz a distintos problemas en la agricultura.

En la actualidad existen aplicaciones como apoyo a la agricultura como PLANTIX (software creado por la empresa alemana PEAT) para ayudar a los agricultores es una herramienta de gestión para el diagnóstico de enfermedades vegetales, con solo capturar una fotografía la aplicación muestra los datos rápidamente, el software puede indicar donde están más extendidas algunas enfermedades o plagas y predecir la multiplicación de la enfermedad [21], y PLAGAPP, es una aplicación que se enfoca a la detección y muestra el nombre de la plaga analizada, para posterior brindar datos sobre su tamaño, maneras de erradicarla, ciclo de vida y de reproducción, entre otros datos útiles para el agricultor[22].

Existen diferentes enfermedades que se presentan en las granadas, la Botrytis Cinérea es una de ellas. Este daño perjudica la producción de los derivados de la granada, puede llegar a contaminar el producto final y por consiguiente acelerar su putrefacción. Debido a lo anterior, el objetivo es identificar la enfermedad de la Botrytis en la etapa de selección previa a la producción a través del reconocimiento de patrones utilizando el método de agrupamiento K-Means. Para llevar a cabo lo anterior, se preprocesa la imagen de entrada, la cual es convertida del formato RGB a HSV para obtener la información de los colores. El desarrollo del software para la detección de cenicilla fue realizado por medio del modelo de color HSV. La imagen fuente fue convertida del espacio de color RGB al espacio HSV y las partes de la enfermedad y la planta se extrajo de acuerdo con la información de los canales de H, S y V. Posteriormente se eliminaron los objetos de color blancos ruido.

Sistema de información que procesa imágenes para la detección de enfermedades en el cultivo de plátano como la Sigatoka Negra, Sigatoka Amarilla, el Moko del plátano y otras, que afectan su producción. Este trabajo se desarrolla en áreas de cultivo ubicadas en el municipio de Manzanillo, Colima. En la implementación del sistema, se usaron drones aéreos equipados con cámaras que utilizan sensores CMOS que obtienen imágenes de alta resolución. Los resultados obtenidos mejoran las investigaciones previas al considerar la detección de otros agentes patógenos utilizando técnicas de redes neuronales y LBP, estos resultados pueden aplicarse a otras áreas de cultivo de plátano con condiciones de producción similares. La clasificación de las hojas sanas contra las de predicción las clasifica con un 100%, las hojas con Sigatoka Amarilla las clasifica con un 50% ya que la Sigatoka Negra y Amarilla tienen casi la misma tonalidad de colores nada más se diferencia por el patrón al momento en que se desarrolla la plaga.



Esta investigación permite identificar hileras de cultivos en maíz, y distinguir entre cultivos y malezas mejora los beneficios económicos, ecológicos y comerciales de su implementación en tractores automáticos. Para comprobar la eficacia y precisión del método propuesto, se selecciona aleatoriamente el 25% de las 200 imágenes disponibles y se selecciona un total de 50 imágenes. Para cada una de estas 50 imágenes, se construye una binarización de imágenes reales a partir de sus imágenes.

Reconocimiento de plagas como flor de azúcar utilizando la visión de máquina por computador como elemento de diagnóstico. La captura de la imagen es realizada por un agente robótico aéreo (drone) equipado con una cámara que puede capturar imágenes del estado foliar de un cultivo llamado *Begonia semperflorens*. Utilice tecnología de visión artificial para procesar estas imágenes para identificar plagas en los cultivos. Compare la relación entre el valor de validez promedio de cada resolución de imagen y la distancia, y el rendimiento de la línea de tendencia que representa el comportamiento aproximado de la distancia y el comportamiento.

## 1.2 Planteamiento del Problema

El principal problema que limita la producción del maíz en el estado de Guerrero es la presencia de plagas. Particularmente el maíz es atacado por el gusano cogollero que devasta cultivos enteros en pocos días.

El gusano cogollero provoca raspaduras en el follaje tierno que después aparecen como áreas translúcidas siendo el momento óptimo para su control. Posteriormente el daño afecta al cogollo, y al desplegarse el follaje se detectan perforaciones por la lámina foliar o áreas dañadas, en esta fase es posible observar los excrementos de la plaga en forma de aserrín. Un grave daño se produce cuando la plaga ataca la inflorescencia del cultivo de maíz [18].

Los agricultores se ven preocupados por esta temible plaga en el cultivo de maíz. Cuando llega el tiempo de calor con más frecuencia aparecen con mayor fuerza. Se utilizan toda clase de medios como insecticidas para su pronta radicación.

Este gusano es considerado como una de las plagas más mortales para el cultivo de maíz en la república mexicana, que afecta a los cultivos de temporal también, a los cultivos de riego y de punta de riego [19].

Durante el ciclo vegetativo de un cultivo, podemos utilizar la escala de Davis para determinar el nivel de daño alcanzado y correlacionarlo con el tamaño de las larvas presentes en ese momento. Por ejemplo, un valor de escala de 5 es causado por larvas L4-L5 que se han depositado en la yema. Los valores de escala 1, 2 y 3 son causados por larvas de menos de 1,5 cm de largo (estadio larvario L1-L3), que suelen ser más móviles y fáciles de controlar [17].

La escala de Davis es método de valuación del daño causado por el gusano cogollero en la planta de maíz, que hace referencia y comparación del tamaño de la larva (gusano cogollero) con respecto al tamaño de su daño, donde L es el nivel de daño y los estadios hacen referencia al tamaño de la larva, cada estadio tiene un incremento de tamaño de la larva de 3mm esto para saber el nivel del daño que corresponde y poder determinar que el nivel del daño optimo es del 1 al 4, permitiendo combatir dicho daño causado por el gusano cogollero en la planta de maíz (Figura 1.1).




Figura 1.1 Niveles de daño en cultivo [17].

- a) El grado de daño en la imagen 1: Sin daño o daños como pines. Estas lesiones son causadas por las larvas de la larva de primer estadio (L1). Generalmente se encuentra que hay más huevos que larvas eclosionadas en esta etapa (Figura 1.1). [17].
- b) Las imágenes de daño de 2 a 4 son lesiones con ventana de control o pequeñas lesiones redondas (alrededor de 1 a 1,5 mm de diámetro) y / o pocas lesiones alargadas (1 a 3 cm).

El tiempo de control óptimo no es Consumir la membrana epidérmica (rascar sin agujeros). Estas lesiones son causadas por larvas de segundo y tercer estadio (Figura 1.1) [17].

- c) Imágenes de la 5 a la 6, con orificios de diferentes tamaños, y daño visible en los cogollos con una pequeña cantidad de heces blandas (aún no obstrucciones parecidas al aserrín). Dado que las larvas están en la yema, pierden la eficacia de control. Sin embargo, algunos de ellos tienen cierta actividad nocturna, que se puede lograr mediante el uso de pesticidas. (Figura 1.1) [17].
- d) Finalmente, las imágenes de la 7 a la 9 muestran que las yemas con heces tipo aserrín están obviamente dañadas en diversos grados. Las larvas L6 con tapones de aserrín pueden prevenir completamente el control químico, ver (Figura 1.1) [17].

### **1.3 Objetivo General**

Diseñar y desarrollar una herramienta basada en técnicas de visión computacional que permita la identificación del daño causado por el gusano cogollero en la planta de maíz.

### **1.4 Objetivos Específicos**

- Conocer las características relevantes que permitan detectar la plaga gusano cogollero en el cultivo de maíz.
- Determinar las características que deben tener las imágenes que serán utilizadas.
- Revisar y seleccionar las técnicas de adquisición, preprocesamiento que permitan el análisis de daño en imágenes digitales.
- Seleccionar las características como textura, color, forma y contorno que permitan identificar las regiones de interés en las imágenes digitales.
- Analizar los resultados de la segmentación de imágenes para posteriormente aplicar métodos de umbralización esto permitirá diferenciar la planta de maíz de otros tipos de cultivos.
- Realizar pruebas con el clasificador a implementar y su entrenamiento.

### **1.5 Hipótesis**

Mediante técnicas de visión computacional se logrará la detección oportuna del daño causado por el gusano cogollero en la planta de maíz.

## 1.6 Metodología

Para el desarrollo de la herramienta basada en visión computacional es necesario implementar una metodología que permita realizar las funciones adecuadamente las cuales se describen a continuación (Figura 1.2).

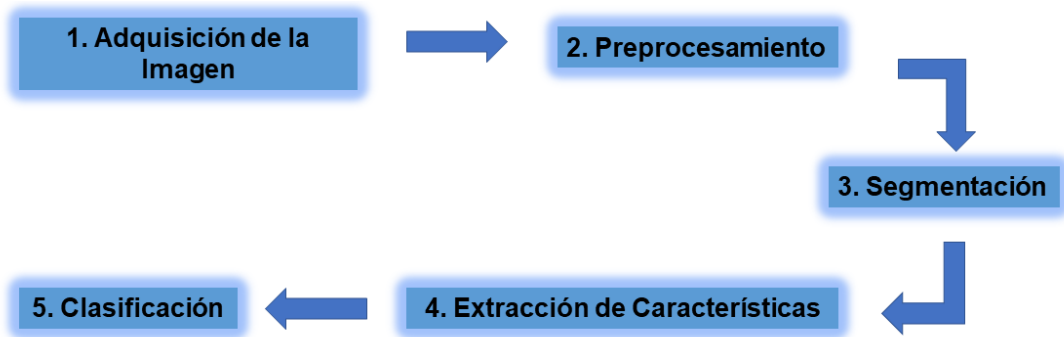


Figura 1.2 Metodología en visión computacional [20].

**Adquisición de la imagen:** esta primera etapa se debe a la obtención de la una imagen digital del cultivo de maíz para su procesamiento bajo las condiciones con luz solar y tomando en cuenta la distancia máxima de 20 a 30 centímetros de distancia.

**Preprocesamiento:** Para esta etapa se incluye técnicas tales como la reducción de ruido y realce de detalles para ello se utilizarán métodos del dominio espacial, así como también la implementación del modelo de color para obtener el canal de interés [20].

**Segmentación:** esta es la etapa siguiente para el proceso que divide a una imagen en objetos que sean de interés. Para este proceso se implementarán técnica basada en color HSI el cual se tomará

el canal I posteriormente se aplicará el método otsu para la umbralización posteriormente se obtendrá la longitud de pixeles de la región de interés [20].

**Extracción de Características:** es el proceso mediante el cual se obtienen características convenientes para diferenciar un tipo de objeto de otro, por ejemplo, tamaño y forma.

### **Clasificación**

La clasificación es un proceso en que pixeles de identidad conocida, ubicados dentro de las áreas de entrenamiento, se utilizan para clasificar pixeles de identidad desconocida [20]. La clasificación supervisada involucra las siguientes etapas:

- Etapa de entrenamiento.
- Selección del algoritmo de clasificación adecuado y clasificación.
- Operaciones de post clasificación.

## **1.7 Organización de la Tesis**

La organización de este trabajo se describe a continuación: El capítulo 2 muestra una recopilación de los trabajos más relevantes que se relacionan con el presentado. El Capítulo 3 describe los fundamentos del marco teórico utilizado. El Capítulo 4 describe la metodología utilizada y desarrollo de esta. La evaluación del modelo, pruebas y resultados, se presentan en el Capítulo 5. Finalmente, el capítulo 6 muestra las conclusiones y trabajo futuro.

## Capítulo 2

## Marco Teórico

### 2.1 Introducción

La visión artificial, así como también el procesamiento digital de imágenes son áreas de estudio relacionadas con las ciencias computacionales. Actualmente han captado el interés de diversas comunidades científicas debido en gran parte a la amplia variedad de aplicaciones donde intervienen, tales como: i) sistemas tutores, ii) navegación robótica, iii) sistemas de entretenimiento, iv) sistemas de realidad virtual, v) sistemas de apoyo al diagnóstico médico, y v) sistemas de apoyo a los agricultores, entre otras.

Al paso del tiempo se han desarrollado aplicaciones para el apoyo en el proceso de visión computacional para la agricultura implementando técnicas para el procesamiento de imágenes digitales y reconocimiento de daños o enfermedades en plantas en el caso de botrytis la enfermedad afecta la producción de los derivados de la granada “se implementó diferentes métodos de segmentación y extracción de características: binarización, crecimiento de regiones, Otsu, K-means clustering, modelo matemático de punto interior a un triángulo, generación de base de datos de píxeles, extracción de características estadística y de características del dominio de la frecuencia con transformadas Wavelets.

Unos de los principales objetivos de hacer uso del procesamiento de imágenes es mejorar el aspecto de las imágenes, resaltar detalles de interés que se desean hacer notar en una imagen. Esto se puede llevar a cabo a través de métodos ópticos o digitales esto quiere decir que se puede hacer uso de una computadora para llevar a cabo la implementación de las técnicas que permiten realizar lo antes mencionado.



## **2.1.2 Inteligencia Artificial**

La inteligencia artificial es una rama de la ciencia que se encarga de estudiar la inteligencia de los elementos hechos por el hombre y, desde una perspectiva de ingeniería, propone crear elementos con comportamiento inteligente. En otras palabras, la IA tiene como objetivo construir sistemas y máquinas que exhiban comportamientos que, si son realizados por humanos, se considerarán inteligentes. [27]

La capacidad de aprender, adaptarse a entornos cambiantes, la creatividad, etc. suelen ser aspectos relacionados con el comportamiento inteligente. Además, la inteligencia artificial es interdisciplinaria e incluye neurociencia, psicología, tecnología de la información, ciencia cognitiva, física, matemáticas y otras disciplinas. [27]

## **2.1.3 ¿Porque hacer uso de la IA?**

Para hacer uso de las técnicas de IA se entienden dos puntos de vista o métodos de IA, a saber, el técnico o de ingeniería y el científico. Algunos de los departamentos de ingeniería buscan crear sistemas inteligentes que realicen tareas que requieran inteligencia (razonamiento) [27].

De esta manera, buscar soluciones a problemas específicos, en lugar de restringir las tecnologías que se utilizarán a tecnologías utilizadas por personas inteligentes. Por otro lado, la rama científica de la inteligencia artificial se puede definir como "el estudio del comportamiento inteligente, cuya finalidad es obtener una teoría de la inteligencia que explique el comportamiento que se da en los organismos naturales inteligentes y oriente la creación de entidades. Esta inteligencia puede realizarse Programa "[27].

Desde un punto de vista técnico, la tecnología clásica ha tenido un éxito relativo y sus productos (sistemas expertos, sistemas basados en el conocimiento, etc.) se han utilizado ampliamente.

El principal problema de estas tecnologías es que no pueden adaptarse a los cambios del entorno, y deben tener una comprensión clara del problema para que se resuelva de manera satisfactoria. Estos sistemas deben ser programados, no autoprogramables, por lo que deben adaptarse a los nuevos requisitos ambientales. Para resolver este problema, se han desarrollado varios métodos de cálculo denominados "técnicas adaptativas" [27].

#### **2.1.4 Definición de una imagen digital**

Para comprender mejor el procesamiento digital de imágenes es necesario saber que se lleva a cabo haciendo una división de la imagen en un arreglo rectangular de distintos elementos, tal como se muestra en la figura 2.1. Cada uno de los elementos de la imagen dividida se le conoce con el nombre de píxel y de aquí en adelante observaremos que se estará hablando acerca de este concepto. Como siguiente paso es asignar un valor numérico a la luminancia promedio de cada uno de los píxeles.

Como tercer paso se alterarán los valores de la luminosidad de los píxeles mediante las operaciones o transformaciones matemáticas necesarias, a fin de hacer que resalten los detalles de la imagen que sean convenientes. Como último paso es la representación de los píxeles seleccionados a un monitor de televisión de alta definición, con la finalidad de mostrar la imagen

procesada, a este último término mencionado se le conoce comúnmente para denotar la unidad de medida más pequeña en una imagen (Figura 3.1). [26]

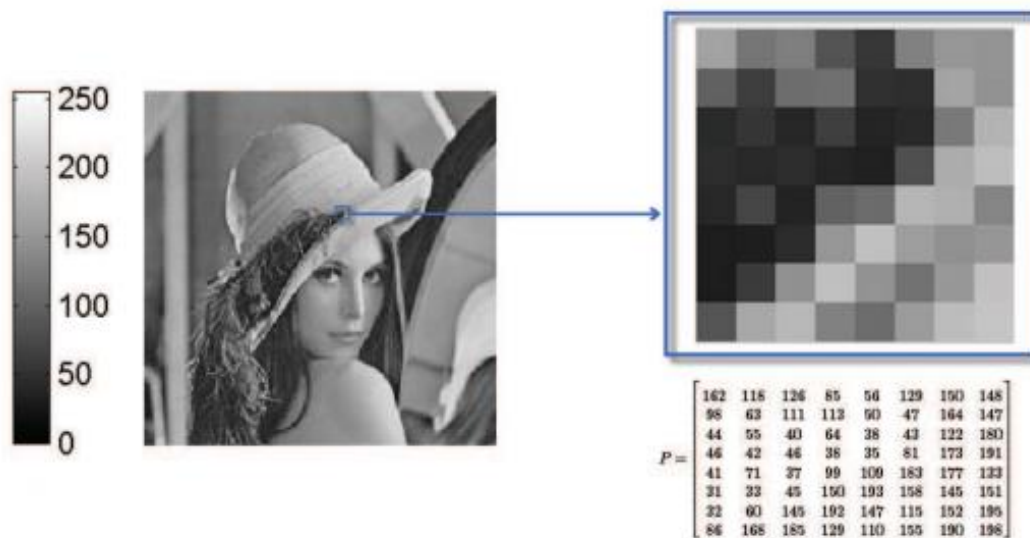


Figura 2.1 Imagen con 256 niveles de intensidad y fragmento 8x8[26].

La figura 2.1 muestra una imagen con 256 niveles de intensidad. En él, cada píxel está representado por un número entero, que se interpreta como el nivel de intensidad de la luz en la escala de grises. Al hacer zoom sobre la imagen en cualquier área, estos valores se pueden entender, estos valores se muestran como una matriz en la misma figura. Cada elemento de la matriz  $N_{ij}$  corresponde a las coordenadas del plano  $x = i, y = j$ . Uno de los datos más importantes de una imagen digital es su resolución. La resolución es la cantidad de píxeles que contiene una imagen digital. También se implementa para la clasificación todos los dispositivos inteligentes que permiten la captura o visualización de imágenes digitales, ya sean monitores, televisores, impresoras, escáneres, cámaras digitales, etc. La resolución de la imagen indica el número de píxeles que contiene la imagen de mapa de bits. La calidad de la imagen depende directamente de su resolución. [26].

## **2.3 Modelos de color**

Los canales de color es una herramienta muy importante en el procesamiento de imágenes digitales esto permiten analizar cada uno de los píxeles desde otro ángulo, Utilizando la mayor parte de la información. El trabajo en este campo involucra la segmentación en las imágenes en color, la ubicación de objetos, el análisis de texturas, la morfología matemática, la estandarización de imágenes en color, etc. Los programas no lineales son muy comunes en el espacio de color porque intentan realzar algunas particularidades de la imagen [26].

Hay muchos espacios de color, y cada espacio de color puede satisfacer necesidades tan diferentes, desde la fisiología del ojo humano (espacio de Hering o espacio de color relativo) hasta el modelo de color sustractivo (CMYK) utilizado para imprimir en papel. En esta sección, se presentará el software más comúnmente utilizado en visión artificial y análisis de imágenes. Cabe mencionar que algunos espacios de color no tienen el objetivo de visualizar los colores más detalladamente a la realidad, sino que son abstracciones matemáticas, generalmente no lineales, que permiten el procesamiento de estas [26].

### **2.3.1 El modelo RGB**

El espacio RGB es uno de los modelos más utilizados por los sistemas de software para crear y visualizar colores en dispositivos y pantallas. Se basa en la "síntesis aditiva", en las intensidades de luz referente al rojo, el verde y el azul se combinan para obtener diferentes colores, incluido el blanco y el negro [13].

La representación gráfica del modelo RGB (Figura 3.6) se realiza mediante un cubo unitario con

ejes R, G y B. El origen (0,0,0) representa el negro y las coordenadas (1,1,1) representan el blanco. Los vértices del cubo con coordenadas (1,0,0), (0,1,0) y (0,0,1) en cada uno de los ejes R, G y B representan los colores primarios de rojo, verde y azul. Los tres vértices restantes (1,0,1), (0,1,1) y (1,1,0) son magenta, cian y amarillo respectivamente, que son colores secundarios y complementarios al verde, rojo y azul respectivamente. La diagonal del cubo representa la gama de grises del negro al blanco. En esta diagonal cada punto o color se caracteriza por tener la misma cantidad de cada color primario [12].

La imagen del modelo RGB contiene tres planos de imagen independientes, uno para cada color primario. Cuando estas tres imágenes se proyectan en un monitor RGB, la pantalla de fósforo producirá una imagen de color compuesta. Cuando se utilizan tres planos de color para representar imágenes de forma natural, el procesamiento de imágenes en color con el modelo RGB tiene sentido (Figura 2.2).




Figura 2.2 Representación gráfica del modelo RGB [12].

### 2.3.2 El modelo HSI.

El modelo de color HSI (tono, saturación, tono, saturación, intensidad) se define mediante la conversión no lineal del modelo RGB. Esta transformación cambia el subespacio del cubo de la Figura 3.6, convirtiéndolo en dos conos conectados en la parte inferior [13].

Geoméricamente, el componente de saturación (componente S) corresponde a la distancia radial del cono y proporciona una medida del grado de mezcla de color blanco. Por otro lado, el tono (componente H) corresponde al ángulo con respecto al eje rojo, proporcionando así la magnitud de la longitud de onda dominante. La tonalidad cambia en el rango de  $360^\circ$ , y el intervalo angular entre cada color primario es de  $120^\circ$ , la separación angular también se mantiene entre los segundos colores. Como se muestra en la figura, cuando  $H = 0^\circ$ , el color representado es rojo, y cuando  $H = 60^\circ$ , el color representado es amarillo, y así sucesivamente [13]

El componente de intensidad "I" se obtiene como la distancia a lo largo del eje perpendicular al plano de color, que representa el valor de brillo del color, y por tanto indica la información acromática relacionada con el color. Los valores más bajos de "I" corresponden a colores oscuros, mientras que los valores más altos corresponden a colores claros hasta llegar al blanco (Figura 2.3) [13].




Figura 2.3 Modelo de color HSI [13].

## 2.4 Extracción de características

Al proceso de transformación de los datos de entrada en una representación reducida se le conoce como extracción de características. Permite la reducción de sus dimensiones. En este proceso se obtienen datos como subconjunto a partir de un conjunto original por medio de alguna función que tome la información más importante. Un vector de atributos obtenido es un conjunto de características indexadas.

La extracción de las características es prioritaria en gran parte de los algoritmos de aprendizaje formal dado que anteponen específicamente su rendimiento, y es usado como punto de inicio en mayor cantidad de algoritmos de visión artificial. No solo se obtiene en cuenta la importancia de los datos, también otros atributos como el volumen de estos.

La extracción de características es un conjunto de métodos que asignan entidades de entrada a nuevas entidades de salida. Muchos métodos de extracción de características utilizan el aprendizaje sin supervisión para extraer características.

Un uso típico de la extracción de entidades es encontrar entidades en las imágenes. El uso de estas características puede dar lugar a una mejor precisión de clasificación.

**Textura** es un atributo de las imágenes digitales que se divide en 2 grupos. El primero existen métodos o técnicas aplicados en la información espacial, que obtienen la información directamente de la imagen digital original codificado de estadísticas en los píxeles. Son simples de entender y

se obtienen buenos resultados en maneras irregulares, algunas ocasiones son sensibles al ruido, la escala y las distorsiones. Tenemos los métodos orientados en información espectral que obtienen las características de transformaciones de la imagen. Son robustos y habitualmente menos costosos.

**Morfología** para conocer la morfología la intensidad no contiene información suficiente, esto todo debido que no tiene información estructural por lo regular no son características computacionalmente hablando, porque son características de píxeles, y varían con la dimensión de la imagen. La comparación de la intensidad de dos píxeles es una de las características más simples.

Local Binary Patterns (LBP) es una técnica útil descriptiva considerada muy efectiva que se utiliza para la clasificación de objetos dentro del área de visión computacional que permite filtrar los píxeles adyacentes en la imagen mediante razones específicas y obtiene como valor binario representativo. Realiza la codificación de relación entre el píxel central con la intensidad de color de los píxeles cercanos. Esto debido a su alta capacidad discriminatoria, constituye una aproximación usual para la solución de múltiples de problemas. Particularmente una de sus características importantes es la robustez (Figura 2.8).

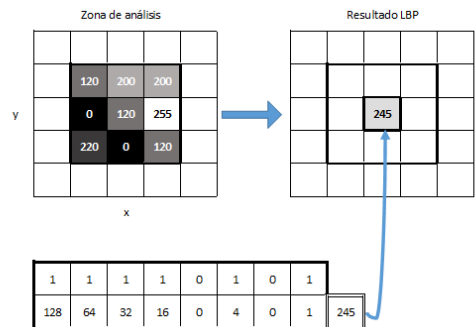




Figura 2.4 Función del LBP.

## 2.5 Clasificador KNN

Es un método cuyo principal objetivo es buscar en las observaciones más cercanas a la que se está intentando de predecir y clasifica el píxel de interés orientado en la mayoría de la información que le rodean. Como dijimos antes, es un algoritmo:

**Supervisado:** en esta etapa tenemos etiquetado nuestro conjunto de datos de entrenamiento de nuestra imagen, con la clase o resultado esperado dada «una fila» de datos.

**Basado en Instancia:** El algoritmo no busca explícitamente un modelo (como por ejemplo en regresión logística o árboles de decisión). En cambio, memoriza las instancias de entrenamiento que son usadas como «base de conocimiento» para la fase de predicción.[14].

El funcionamiento en la práctica del clasificador es la siguiente (Figura 2.5).




Figura 2.5 Clasificación de los conjuntos de datos en 2 categorías [15].

Tomando en cuenta el conjunto de datos que son clasificados en 2 categorías según la imagen, como se muestra en la figura 2.5, se necesita clasificar un conjunto nuevo de datos agrupados que está dentro de la región que muestra la siguiente gráfica (Figura 2.6).




Figura 2.6 Un nuevo vector de datos para su clasificación [15].

El algoritmo KNN en los siguientes pasos que se toman para saber a qué conjunto pertenece el siguiente dato clasificar:

1. Obtiene el número de  $K$  vecinos.
2. Adquiere los  $K$  vecinos más cercanos para el nuevo elemento de acuerdo con la distancia euclidiana
3. Entre los  $K$  vecinos, contar el número de datos que pertenece a cada categoría
4. Indicar el elemento nuevo a la categoría donde se contaron más vecinos

Para el ejemplo que  $K = 5$ , marcamos los 5 vecinos más cercanos al nuevo elemento ver Figura 2.7.




Figura 2.7 Para el nuevo elemento selecciona  $k = 5$  vecinos más cercanos [15].

Contamos que la categoría 1 tiene 3 elementos y en la categoría 2 tiene elementos entre los 5 vecinos más cercanos (Figura 2.8).




Figura 2.8. hay 2 elementos en la categoría 2 y 3 elementos en la categoría 1[15].

Como se observa la categoría 1 tiene 3 elementos el nuevo dato se asigna a la categoría 1(Figura 2.9).

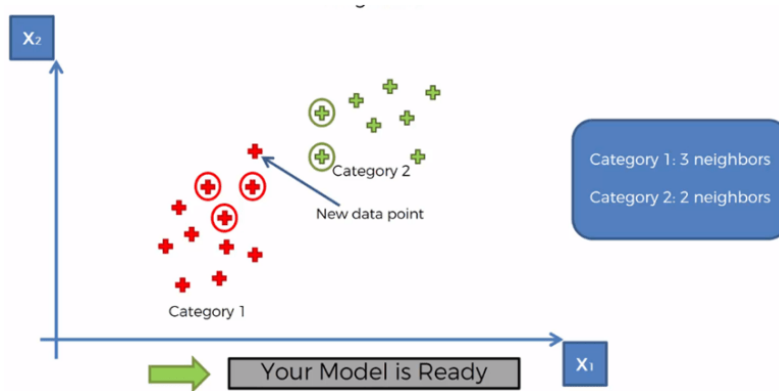


Figura 2.9 Asignación del nuevo elemento [15].

Una vez terminado de analizar lo elementos con el número mayor se asignó a la categoría 1, puesto que  $K=5$  hay más vecinos en esta categoría

## Capítulo 3

## Trabajos Relacionados

### 3.1. Introducción

Para poder apreciar cuando hay presencia de plagas o enfermedades en cualquier tipo de cultivo es la acción de alimentarse de los insectos que provocan estos daños que pueden ser visibles en muchas ocasiones con el propósito de aplicar algunos insecticidas como estrategias para el control de ellas.

Por lo regular cuando no existe un monitoreo en los cultivos o también cuando no se implementan herramientas tecnológicas para controlar las condiciones para la reproducción de las plagas y enfermedades que ocasionan muchos daños a los productos y por ende puede haber muchas pérdidas económicas a los agricultores. Los residuos que dejan los insectos que se alimentan de los nutrientes de las imágenes son parecidos al aserrín o excrementos oscuros, también se pueden observar como malezas o gránulos, otro síntoma que con el que se puede observar la presencia de estas plagas es cuando hay deformidades o las plantas no se desarrollan por completo y no crecen como se esperaban.

En muchos desarrollados las pérdidas tanto de los productos como económicas oscilan en el 10 y 20 % del total de la producción, en el país México y en especial en el estado de Guerrero cuando no se controlan a tiempo las plagas pueden ocasionar grandes pérdidas que en ocasiones oscilan en el 30%. Ello ocasiona una constante lucha para el control fitosanitarios que de acuerdo a algunos estudios tienen efectos colaterales tanto para la naturaleza como para el ser humano.

### 3.2 Identificación de la enfermedad Botrytis Cinérea en la Granada utilizando K- MEANS

Existen diferentes enfermedades que se presentan en las granadas, la Botrytis Cinérea es una de ellas. Esta enfermedad afecta la producción de los derivados de la granada, ya que puede llegar a contaminar el producto final y por consiguiente acelerar su putrefacción. Debido a lo anterior, el objetivo del presente artículo es identificar la enfermedad de la Botrytis en la etapa de selección previa a la producción a través del reconocimiento de patrones utilizando el método de agrupamiento K-Means. Para llevar a cabo lo anterior, se pre-procesa la imagen de entrada, la cual es convertida del formato RGB a HSV para obtener la información de los colores (Figura 3.1) [28].

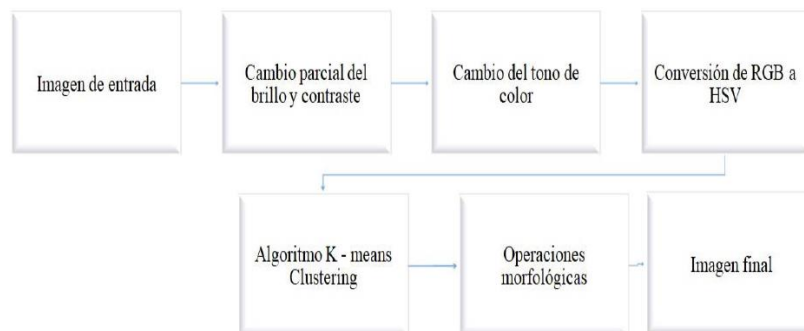


Figura 3.1 Metodología de desarrollo [28].

Con la aplicación de la metodología para el reconocimiento de patrones de una imagen de granada se logra detectar la enfermedad botrytis de acuerdo con la textura (Figura 3.2).



Figura 3.2 Granada contaminada.

En este trabajo se han segmentado las imágenes con el método de K-means clustering con un  $K=3$  y se compararon cuatro tipos de métricas de distancia, de las cuales la suma de diferencia absoluta fue la que extrae la mayor parte de la enfermedad (Figura 3.1) [28].





Suma de diferencia absoluta (CityBlock)	Distancia euclidiana (Sqeclidean)	Coseno (Cosine)	Correlacion (Correlation)
			

Tabla 3.3 Aplicación de técnicas para la detección de BOTRITIS [28]

### 3.3 Detección de cenicilla en rosa usando procesamiento de imágenes por computadora.

Las plagas y enfermedades son problemas para los cultivos ornamentales, que a su vez son problemas para el mercado internacional, por lo que deben ser controlados. Los principales mercados de flores frescas cortadas se encuentran en Europa, Estados Unidos y Japón. México es uno de los principales proveedores de Estados Unidos [29].

Para facilitar la identificación de enfermedades, la zona extraída se pinta de rosa y el fondo se pinta de negro. El esquema de color también se utilizó durante la comparación. El rojo se usa para indicar el área correspondiente y el azul se usa para indicar el área no correspondiente (Figura 3d). La Figura 3 muestra un ejemplo de la imagen original (Figura

3.3) y las imágenes de plantas y enfermedades (Figuras 3b y 3c) obtenidas después del procesamiento de la imagen. La Figura 3 también muestra la imagen de comparación (Figura 3d), que se deriva de la comparación entre la imagen principal y la imagen de la enfermedad.




Figura 3.3 Aplicación de filtros [29].

Con el fin de facilitar el reconocimiento de la enfermedad (Figura 3.3),

- A) áreas donde se encuentra el daño
- B) áreas donde se encuentra el daño
- C) las regiones extraídas fueron pintadas de color rosa.
- D) el fondo fue pintado de negro.

Cuando se realizó la comparación se utilizó un modelo de color. El canal del color rojo fue utilizado para representar el área de interés y el color azul fue utilizado para representar a la no-correspondencia (Figura 3.4) [29].






Figura 3.4 Aplicación de RGB [29].

El autor muestra que el sistema que desarrollaron es capaz de detectar los daños ocasionados por la enfermedad de cenicilla a través del espacio de color HSV con Open CV®.

Las tasas de concordancia máxima y mínima obtenidas, cuando se usaron fotografías cercanas fueron de 94.4 y 44.3 %, respectivamente. La tasa de coincidencia máxima obtenida cuando se usaron fotografías distantes fue de 85.5 % y la tasa mínima obtenida fue de 14.6 %.

### **3.4 Procesamiento de Imágenes Aplicadas a la Identificación de Agentes Patógenos en el Cultivo de Plátano.**

Se desarrolló un sistema de información que procesa imágenes para la identificación de plagas en el cultivo de plátano como la Sigatoka Negra, Sigatoka Amarilla, el Moko del plátano y otras, que afectan su producción. Este trabajo se desarrolla en áreas de cultivo ubicadas en el municipio de Manzanillo, Colima. En la implementación del sistema, se usaron drones aéreos equipados con cámaras que utilizan sensores CMOS que obtienen imágenes de alta resolución. Las cuales son procesadas utilizando técnicas de procesamiento de imágenes contenidas en la herramienta Image Processing Toolbox de MATLAB, incluyendo sus librerías de Windows para crear una interfaz amigable para el usuario, dicha interfaz presentará probabilidades de presencia de agentes patógenos. El sistema desarrollado presenta un enfoque innovador porque incluye herramientas tecnológicas de vanguardia y las condiciones agronomicas particulares de las áreas de producción

del estado de Colima. Los resultados obtenidos mejoran las investigaciones previas al considerar la detección de otros agentes patógenos utilizando técnicas de redes neuronales y LBP, estos resultados pueden aplicarse a otras áreas de cultivo de plátano con condiciones de producción similares.



Figura 3.5 Hoja con SIGATOKA Neura [30].

Sistema de información que procesa imágenes para la identificación de plagas en el cultivo de plátano como la Sigatoka Negra, Sigatoka Amarilla, el Moko del platano y otras, que afectan su producción (Figura 3.4). Este trabajo se desarrolla en áreas de cultivo ubicadas en el municipio de Manzanillo, Colima. En la implementación del sistema, se usaron drones aéreos equipados con cámaras que utilizan sensores CMOS que obtienen imágenes de alta resolución [30].

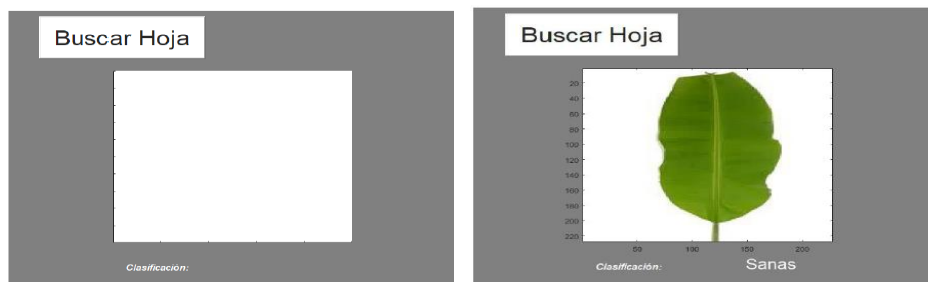


Figura 3.6 Adquisición de imagen [30].

La matriz de confusión muestra el porcentaje de la clasificación correcta, como se muestra en la clasificación de las hojas sanas contra las de predicción las clasifica con un 100%, las hojas con Sigatoka Amarilla las clasifica con un 50% ya que la Sigatoka Negra y Amarilla tienen casi la misma tonalidad de colores nada más se diferencia por el patrón al momento en que se desarrolla la plaga [30].

Para el entrenamiento de la CNN se usó el software MATLAB® y un equipo de cómputo con una GPU Nvidia GTX 1060 6GB con capacidad de cómputo de 6.1. Obtención de la Imagen La imagen es obtenida por el DRONE el cual cuenta con una cámara de 20 mega píxeles y sensor de 1 pulgada con la tecnología de Semiconductor complementario de óxido metálico (CMOS por sus siglas en inglés) con un lente focal equivalente a 24mm/F2.8, posteriormente se extraen las imágenes para realizar la clasificación con Histogram of Oriented Gradient and Local Binary Pattern with Super Vector Machine (HOG-LBP SVM) y la Convolutional Neural Network (CNN) [30].



Figura 3.7 Procesamiento de imagen [30].

El uso de redes neuronales representa herramientas adecuadas para la predicción de datos no lineales, los resultados obtenidos con la herramienta Classification Learner que utiliza HOG-LBP junto SVM no mostraron la clasificación esperada para los agentes patógenos ya que la sigatoka negra y amarilla presentan casi la misma decoloración en las hojas.

### **3.5 Sistema de visión para agricultura de precisión identificación en tiempo real de líneas de cultivo y malas hierbas en campos de maíz**

Controlar las malas hierbas en grandes extensiones de tierra es caro y, a veces, causa contaminación. En los últimos años, los avances en los sistemas de automatización y control agrícola han propiciado la aparición del concepto de agricultura de precisión (AP), que puede intervenir en los cultivos en el momento y lugar adecuados.

El origen de esta investigación proviene principalmente de dos proyectos, RHEA y AGL2011, en los cuales la identificación de líneas de cultivo en maíz y la distinción entre cultivos y malezas han mejorado los beneficios económicos, ecológicos y comerciales, con miras a su implementación en tractores automáticos (Figura 3.7) [31].

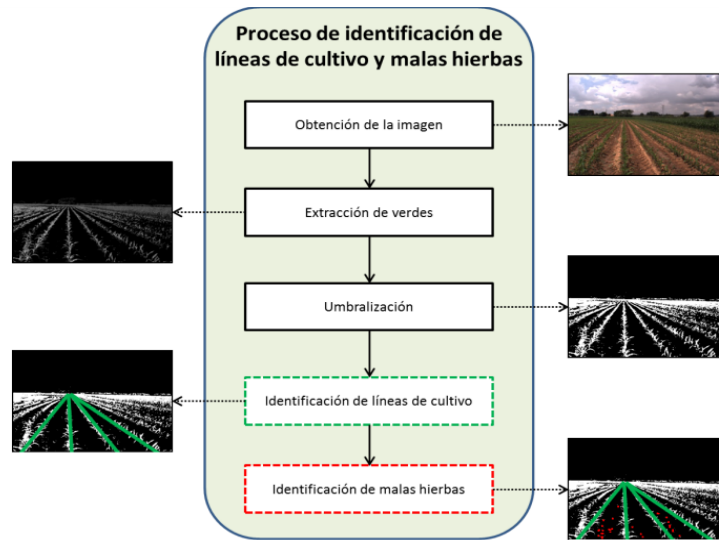


Figura 3.8 Metodología [31].

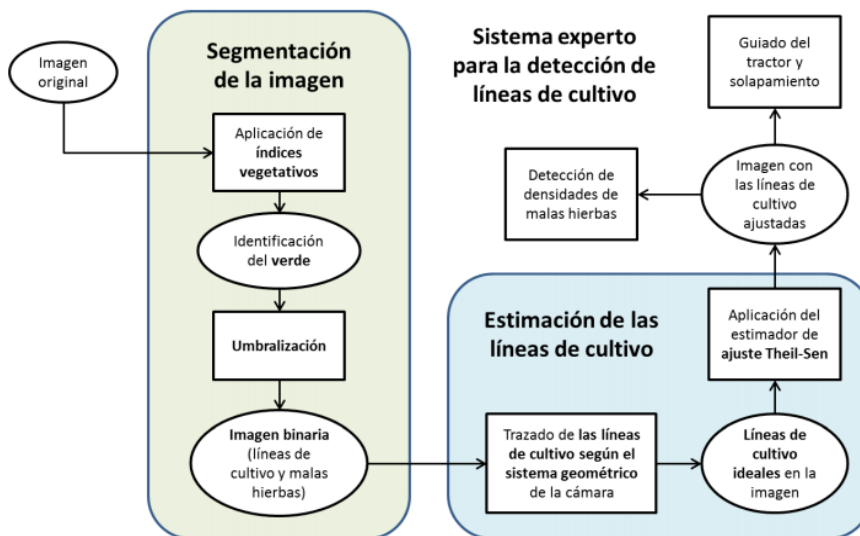


Figura 3.9 Metodología Compuesta [31].

En cuanto a la adquisición de imágenes y su procesamiento antes de la segmentación, se ha propuesto una estrategia de detección de imágenes con alta intensidad lumínica, que se utiliza como base para ajustar con precisión el tiempo de exposición en aquellas cámaras bajo esta posibilidad. Esta estrategia permite obtener imágenes de alta calidad, de manera que se evite la pérdida continua de imágenes por falta de luz, por lo que el sistema puede adaptarse a las

condiciones cambiantes del exterior sin tener que detener la tarea de aplicar la iluminación. Métodos físicos y químicos de control de malezas (Figura 3.9) [31].




Figura 3.10 Aplicación de Verde [31].

### **3.7 Procesamiento de Imágenes para Reconocimiento de Daños Causados por Plagas en el Cultivo de Begonia Flor de Azúcar**

Este trabajo describe los resultados obtenidos utilizando la visión por computadora como elemento de diagnóstico para identificar plagas. La imagen es captada por un manipulador aéreo (drone) equipado con una cámara, que permite capturar imágenes del estado foliar de un cultivo llamado flor de azúcar (*Begonia semperflorens*). Utilice tecnología de visión artificial para procesar estas imágenes para identificar plagas en los cultivos [33].

El principal problema en el desarrollo de este proyecto es determinar el umbral correcto para cada algoritmo utilizado, la solución incluye optimizar los parámetros del algoritmo a través de una red neuronal supervisada multicapa. Dicha red se utilizó como base para el análisis del software, su confiabilidad y los análisis correspondientes. El uso de dicha red, después de su comprobación con el 60% de las fotografías tomadas, fue altamente limitado por el tiempo de procesamiento que requería el análisis de cada imagen lo cual es debido al

alto número de capas utilizadas, por tanto, se tomó únicamente como referente (Figura 3.14) [33].



Figura 3.11 Imagen en rojo [33].

Las ventajas económicas y sociales de este método se reflejan en el ahorro de tiempo de los trabajadores para realizar las tareas de inspección de cultivos, lo que significa que se reduce la mano de obra, mejorando así su calidad de vida.

El uso de tecnología de procesamiento de imágenes para detectar plagas es un proceso rápido y económico, que es especialmente útil para que el sector agrícola controle grandes áreas de cultivo. [33].

### **3.8 Aplicación móvil PlagAPP**

En cuanto a la codificación de esta aplicación utilizaron software de código abierto, en los que se caracterizó la imagen de una plaga, en este caso se concentraron en la broca del café (*Hypothenemus hampei*), ya que es conocido como el insecto que más afecta a estos cultivos en el mundo.



Figura 3.12 PLAGAPP [21]

Por medio de diferentes métodos, como umbralización, apertura, cierre y aplicación de filtros, entre otros, se extrajeron las características más relevantes de la imagen para automatizar su reconocimiento”.

Luego de determinar estas particularidades, se utiliza un método supervisado llamado "clasificador bayesiano" para clasificar las muestras, el cual se basa en calcular la incidencia de características muestrales y la probabilidad de que la muestra pertenezca a una determinada categoría. Entonces, por ejemplo, cuando un agricultor toma una fotografía de una plaga, el clasificador le permitirá calcular qué tan cerca coincide con cualquier especie para determinar qué individuo es [21].

El propósito del software es detectar y reportar el nombre de la plaga analizada y luego proporcionar datos sobre su tamaño, método de erradicación, ciclo de vida y reproducción, así como otros datos útiles para los agricultores (Figura 3.6). En la aplicación, el agricultor también puede rellenar el formulario, que indica el número de individuos (plantas) que ha observado en los cultivos y el número de personas afectadas, para que la aplicación le pueda informar de la incidencia de plagas.





Figura 3.13 PlagApp Móvil [21].

También puede registrar la cantidad de órganos evaluados (como hojas, flores o tallos) y cuántos de ellos están dañados para calcular el porcentaje de infección. Otro propósito de la aplicación es establecer conexiones mutuas entre usuarios registrados para que sepan dónde existen las plagas, reduciendo así el riesgo de propagación.

En el desarrollo de este proyecto, se espera que los estudiantes Cristian Alejandro Corredor, Andrés Felipe Niño, Néstor Jaime Pérez Martínez y Julián Enrique Dueñas del Departamento de Ingeniería Agronómica de Naciones Unidas continúen su investigación experimental con fotografías de especímenes a estudiar para que la aplicación pueda identificar diferentes tipos de plagas en diversos cultivos [2]

### 3.9 Avances en el procesamiento de imágenes para la detección de las enfermedades de las plantas

Técnica de procesamiento de imágenes basada en wavelets y una red neuronal para desarrollar un método para Identificación de daños causados por plagas en frutos de pepita en huertos. Se seleccionaron tres plagas que prevalecen en los huertos como candidatos para esta investigación: el rodillo de la hoja, la polilla codling y la hoja de manzana. La transformada rápida de wavelet con un conjunto especial de Doubenchies se utilizó wavelet para extraer las características importantes. Para recuperar las imágenes relacionadas, la búsqueda se realiza en dos pasos (Figura 3.17).



Figura 3.14 Hoja enferma [22].

Hay dos características principales de la detección de enfermedades en las plantas mediante el aprendizaje automático. Los métodos que deben lograrse son: rapidez y precisión. Por lo tanto, hay un margen para trabajar en el desarrollo de algoritmos de interpretación innovadores, eficientes y rápidos que ayuden a los científicos de plantas a detectar enfermedades.

El trabajo se puede hacer de forma automática. Estimación de la severidad de la enfermedad detectada [22].

# Capítulo 4

# Metodología

## 4.1 Introducción

En este trabajo se implementaron las etapas basadas en visión computacional utilizando métodos y técnicas en cada una de ellas, permitiendo que el procesamiento de imágenes digitales del daño causado por el gusano cogollero en la planta de maíz sean las adecuadas.

A continuación, se describe la metodología utilizada.

## 4.2 Metodología Utilizada

Para aplicar las diferentes técnicas basadas en visión computacional en el procesamiento de imágenes digitales y la implementación del modelo de clasificación de las imágenes con daño y de las que no tienen daño, a continuación, se muestra la metodología con las etapas, así como también los resultados en cada una de ellas (Figura 4.1).

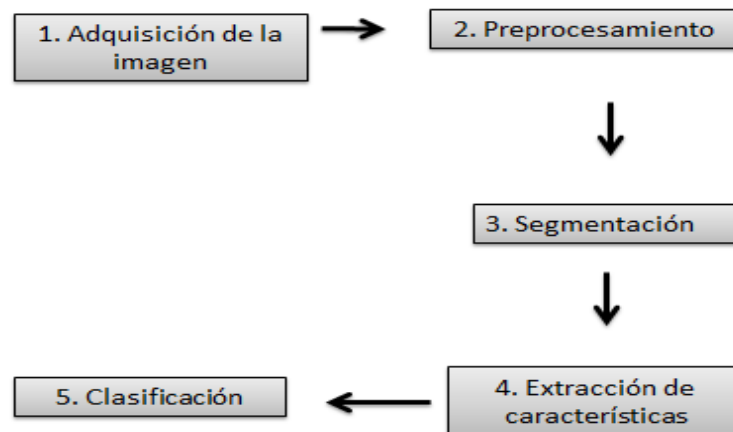


Figura 4.1 Metodología consideradas en el proyecto.

### 4.3 Adquisición de la Imagen

En esta etapa se captura la imagen digital del cultivo de maíz, para la captura de las imágenes se debe tomar en cuenta las condiciones climáticas (lluvia y cielo nublado, etc.) debido a que puede obtenerse una imagen no visible y con ruido, para ello se debe realizar la captura en un ambiente con luz solar, a una distancia de la planta y el dispositivo de 20 a 30 cm, en un horario de 9:00am a 12:00pm para facilitar el proceso de detección del daño (Figura 4.2).



Figura 4.2 Hoja de la planta de Maíz.

### 4.4 Preprocesamiento

En el modelo de color HSI los colores se diferencian unos de otros por su tono, intensidad, y saturación. El tono se asocia a la longitud de onda más dominante en una mezcla de ondas luminosas. El tono representa el color dominante, así como el ser humano lo percibe; cuando se dice que un objeto es rojo, verde o café estamos indicando su tono [23].

La intensidad representa la iluminación percibida. La intensidad se percibe que el objeto refleja más luz. Esta característica lo podemos ver claramente en un televisor en blanco y negro. La saturación se refleja a la cantidad de luz blanca una vez mezclada con el color dominante. La saturación se puede observar del color intenso de uno pálido. Los colores primarios tienen su mayor valor de saturación antes de ser mezclados con otros. Así, el azul cielo es muy claro (menos saturado), mientras que el azul marino es más opaco (más saturado). Otro ejemplo, es el color rosa (rojo y blanco) que está menos saturado; mientras que el color rojo está totalmente saturado (Figura 4.3) [23].

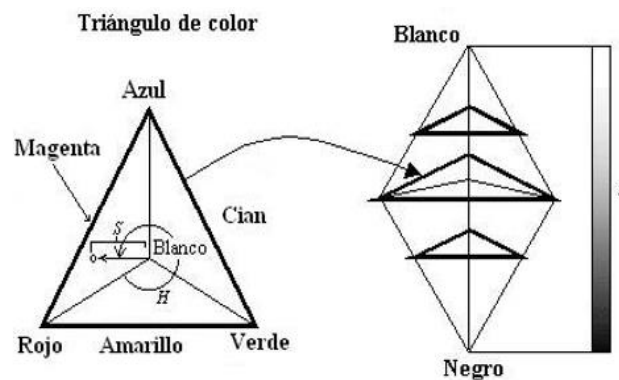


Figura 4.3. Modelo de color HSI [23].

Para la obtención de la región de interés en esta etapa, se realizó diferentes pruebas con los diferentes modelos de color, así como también los canales para determinar que canal es de interés y así proceder a las demás etapas.

Se procede a la conversión de la imagen RGB a HSI tomando el canal de interés I que hace referencia a la intensidad de los píxeles dentro de una imagen (Figura 4.4).



Figura 4.4 Canal de interés I.

## 4.5 Segmentación

La segmentación de imágenes hace referencia al objeto principal y al fondo de la imagen, permite separar o descartar zonas con algunos datos específicos como la forma o de color.

Los atributos básicos de segmentación son: la luminancia en imágenes monocromáticas, los componentes de color en imágenes en color, textura, forma, etc.

Dentro de esta etapa se encuentran técnicas como: detección de bordes, umbralización, basado en regiones y otros. [23].

La umbralización es una técnica para la segmentación simple y altamente eficiente que permite separar los píxeles dentro de una imagen en escala de grises en dos categorías a partir de cierto valor umbral de intensidad. Umbral global. El umbral fijo o global,  $T$ , es aquel que es único sobre toda la imagen como se muestra en la ecuación 1.

$$fI(x,y) = \begin{cases} 0 & \text{si } f(x,y) < t \\ 1 & \text{si } f(x,y) \geq t \end{cases} \quad (1) \text{ Ecu}[23].$$

El método de OTSU elige un umbral que minimiza la varianza intraclase de los píxeles en blanco y negro de los umbrales recibiendo la imagen obtenida del canal S del modelo de color HSL. Después se lleva a cabo un ciclo que recorre cada uno de los píxeles de la imagen y de acuerdo con el valor de umbral reemplaza todos los píxeles de la imagen de entrada con una luminancia mayor que con el color blanco, reemplazando todos los demás píxeles por el color negro

Los atributos básicos de segmentación son: la luminancia en imágenes monocromáticas, los componentes de color en imágenes en color, textura, forma, etc. Dentro de esta etapa se encuentran técnicas como: detección de bordes, umbralización, basado en regiones y otros. *La umbralización* es un método básico de binarización que sirve para diferenciar el objeto del fondo de la imagen. Consiste en que los píxeles que están marcados con 1 corresponden al objeto de la imagen. Si el objeto es oscuro con respecto al fondo, el proceso es inverso.

Como todos los métodos también en la segmentación se asigna a cada píxel un determinado grupo, generalmente llamado "segmento". Como cualquier gráfico de mapa de bits, la imagen a segmentar se compone de valores digitales (uno o más valores de color por píxel). Se determina que el píxel pertenece a un determinado segmento comparando el nivel de gris (u otro valor unidimensional) del píxel con un cierto umbral. El nivel de gris de un píxel es igual a su nivel de brillo; no se tiene en cuenta otra información sobre colores. Dado que la comparación de este valor se realiza por separado para cada píxel, el método de umbral se considera un método de segmentación orientado a píxeles.

La binarización de una imagen consiste en un proceso de reducción de la información de esta, en la que sólo persisten dos valores: verdadero y falso. En una imagen digital, estos valores, verdadero y falso, pueden representarse por los valores 0 y 1 o, más frecuentemente, por los colores negro (valor de gris 0) y blanco (valor de gris 255).

En algunos de los casos las imágenes binarizadas son el resultado de aplicar la segmentación por niveles a escala de grises o también pueden ser por la selección de un color en un rango determinado

Para la segmentación de la imagen se implementó el método de umbralización el cual recorre los píxeles de la imagen de acuerdo con la intensidad para así indicar un valor y así proceder a la binarización creando una imagen blanco y negro donde el blanco es la región de interés o región del daño causado por el gusano cogollero (Figura 4.5).



Figura 4.5. Imagen binarizada.

Posteriormente una vez al binarizar la imagen se procede a la eliminación de objetos pequeños en los que permita obtener las regiones de los píxeles del tamaño considerado del daño ocasionado por el gusano cogollero.

Dentro de la imagen existen píxeles que no son parte del daño causado por el gusano



cogollero en la planta de maíz para ello se necesita aplicar el siguiente método.

BW elimina todos los componentes conectados (objetos) que tienen menos píxeles de la imagen binaria, produciendo otra imagen binaria (Figura 4.6).




Figura 4.6 Imagen segmentada de la región de interés.

Como siguiente proceso para definir las características se procederá a medir las propiedades de las regiones de imagen de cada objeto y limitándolas por rectángulos nos permite conocer el tamaño de la región para determinar la longitud para su clasificación. Para ello se utilizaron los siguientes métodos.

Con la función `REGIONPROPS` devuelve mediciones para el conjunto de propiedades especificado por cada componente (objeto) en la imagen binaria, es estructura de arreglo que contiene una estructura para cada objeto de la imagen. Propiedades `BWSTATS` puede utilizar en regiones contiguas y regiones no contiguas (Figura 4.7).




Figura 4.7 Identificar las regiones de interés del daño.

## 4.6 Extracción de Características

La extracción de características es un conjunto de métodos que asignan entidades de entrada a nuevas entidades de salida. Muchos métodos de extracción de características utilizan el aprendizaje sin supervisión para extraer características. Un uso típico de la extracción de entidades es encontrar entidades en las imágenes. El uso de estas características puede dar lugar a una mejor precisión de clasificación.

Local Binary Patterns (LBP) es una técnica descriptiva altamente efectiva para la clasificación de objetos dentro de la visión computacional que filtra los píxeles adyacentes mediante consideraciones determinadas y obtiene un valor binario representativo. Codifica la relación del píxel central con la intensidad de color de los píxeles aledaños. Debido a su elevada capacidad discriminadora, constituye una aproximación usual para la solución de multitud de problemas. Probablemente una de sus características más importantes es la robustez (Figura 4.8) [26].

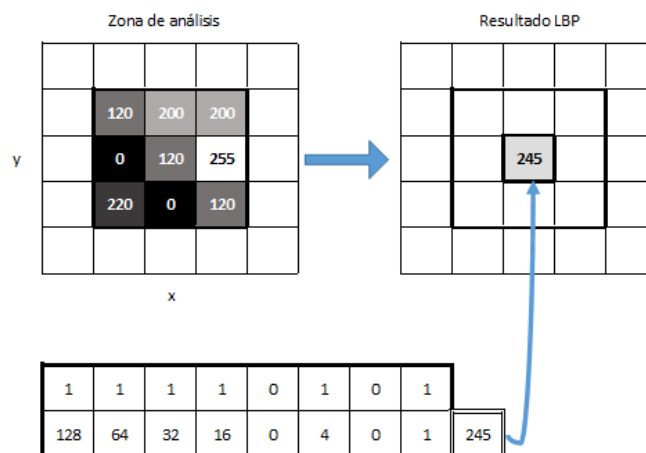


Figura 4.8 Función del LBP [26].

Inicialmente para el algoritmo LBP se debe trabajar únicamente con un canal de la imagen, usualmente se trabaja en escala de gris o se calcula un LBP por cada canal; se selecciona un píxel que será el eje del análisis, se determina adicionalmente un orden de comparación, el cual puede ser cualquiera que requiera el usuario, siempre y cuando, se mantenga constante en todos los análisis relacionados por esta técnica [26].

Algunas de las características básicas que se obtuvieron de las imágenes específicamente en las regiones de interés son área, la longitud y textura (Figura 4.9) etc.




Figura 4.9 Extracción de características.

En la figura. 4.9 Se observa los valores de algunas características que al extraerse se almacenan en un archivo para su posterior entrenamiento.

En la figura. 4.10 Se muestra algunas de las características almacenadas de imágenes clasificándolas para su entrenamiento indicando algunas características para su posterior entrenamiento.

Fields	Area	Centroid	BoundingBox
1	5415 [38.3187 3.6867e+03]	[0.5000 3.6215e+03 99 150]	
2	24270 [66.4020 3.9228e+03]	[0.5000 3.6205e+03 140 540]	
3	634 [145.9621 3.5569e+03]	[133.5000 3.4965e+03 23 122]	
4	3195 [587.5612 2.5718e+03]	[565.5000 2.5255e+03 52 87]	
5	38195 [908.8624 2.5244e+03]	[825.5000 2.2795e+03 201 635]	
6	10977 [954.9415 2.8219e+03]	[912.5000 2.6685e+03 72 276]	
7	21602 [1.1014e+03 1.9740e+03]	[1.0495e+03 1.8185e+03 105 303]	
8	12868 [1.1660e+03 1.5111e+03]	[1.1365e+03 1.3075e+03 61 392]	
9	22844 [1.6100e+03 2.2801e+03]	[1.5505e+03 1.8855e+03 116 828]	
10	5881 [1.9637e+03 4.1221e+03]	[1.9175e+03 4.0665e+03 93 94]	
11	24236 [2.0829e+03 3.9699e+03]	[1.9635e+03 3.8245e+03 254 247]	
12	631 [2.1101e+03 2.4372e+03]	[2.0995e+03 2.4115e+03 25 53]	
13	563 [2.2734e+03 4.0526e+03]	[2.2545e+03 4.0265e+03 37 46]	
14	5 [2.2968e+03 4.0454e+03]	[2.2955e+03 4.0445e+03 3 21]	

Figura 4.10 Características de imágenes.

### 4.6.1 Clasificación

La clasificación es un proceso en que pixeles de identidad conocida, ubicados dentro de las áreas de entrenamiento, se utilizan para clasificar pixeles de identidad desconocida.

La clasificación supervisada involucra las siguientes etapas:

- Etapa de entrenamiento.
- Selección del algoritmo de clasificación adecuado y clasificación.
- Operaciones de post clasificación.

El algoritmo de clasificación que se implemento es el KNN, es uno de los algoritmos de clasificación más simples, incluso con tal simplicidad puede dar resultados altamente competitivos. Pertenece al dominio de aprendizaje supervisado y puede ser utilizado para el reconocimiento de patrones, extracción de datos y detección de intrusos [23].

En la figura 4.11. se muestran algunas imágenes se del daño causado por el gusano cogollero en la planta de maíz




Figura 4.11 Imágenes digitales.

En la siguiente imagen muestra los archivos creados para su clasificación implementando el clasificado KNN y crear el DataSet para el almacenamiento de las características.

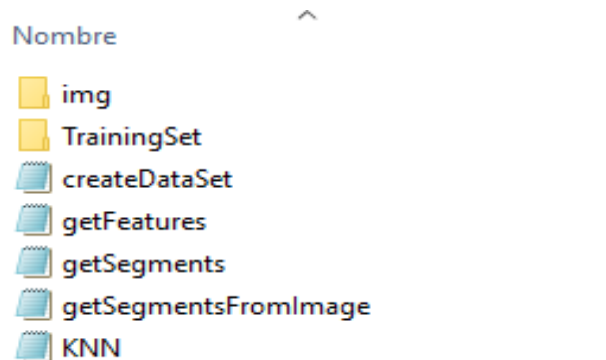


Figura 4.12 DataSet

La manera de como funciona el clasificador KNN

1. Calcular la distancia entre el píxel a clasificar y el resto de píxel del dataset del entrenamiento.
2. Seleccionar los “k” elementos más cercanos (con menor distancia, según la función que se use)
3. Realizar una “votación de mayoría” entre los k puntos: los de una clase/etiqueta que decidirán su clasificación final.

Mostrando la clasificación del daño causado por el gusano cogollero muestra la imagen reconociendo el daño encuadrándolo de color rojo e indicando a simple vista.




Figura 4.15 Clasificación de imagen con daño.

## Capítulo 5 Pruebas y Resultados

En el presente trabajo se muestra los procesos a manera de ilustración para la clasificación de daño causado por el gusano cogollero en la planta de maíz para ello se implementó el clasificador KNN, es un algoritmo basado en instancia de tipo supervisado de Machine Learning. Puede usarse para clasificar nuevas muestras (valores discretos) o para predecir (regresión, valores continuos). Al ser un método sencillo, es ideal para introducirse en el mundo del Aprendizaje Automático. Sirve esencialmente para clasificar valores buscando los puntos de datos “más similares” (por cercanía) aprendidos en la etapa de entrenamiento y haciendo conjeturas de nuevos puntos basado en esa clasificación.

Para la ejecución de las pruebas se obtuvieron principalmente imágenes RGB con daño causado por el gusano cogollero en la planta de maíz y sin daño esto nos permitirá implementar técnicas de visión computacional para determinar de una manera confiable cada una de las imágenes y clasificarlas de manera correcta mostrando alguna de ellas (Figura 5.2).




Figura 5.2 Imágenes RGB de daños causados por el gusano cogollero.

Las pruebas se realizaron mediante una imagen de entrada con o sin daño del gusano cogollero en la planta de maíz, que mediante el algoritmo desarrollado permite realizar el proceso de análisis de la imagen para su clasificación para ello se generan dos clases que se generan de manera automática, una con el número 121 que hace referencia a las imágenes que tienen el daño y el número 115 que indica que la imagen no tiene daño causado por el gusano cogollero.


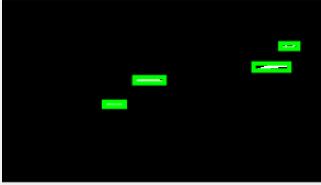
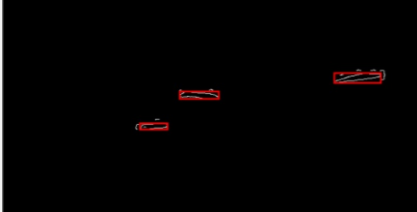

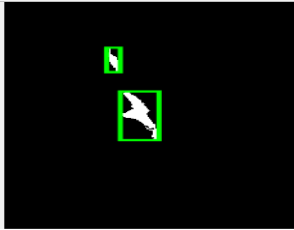
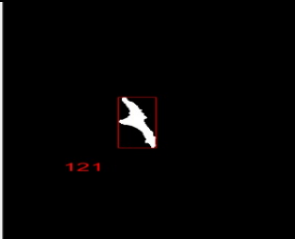


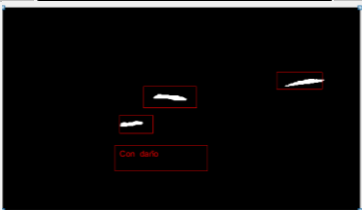
Imagen Original	Segmentación	Clasificación
		
		
		

Tabla 5.4 Pruebas de clasificación.

Se analizaron un total de 960 imágenes mostrando daño y sin daño del gusano cogollero. La aplicación del modelo de clasificación KNN que indica cuando las imágenes tienen o no daño. Se utilizaron 960 imágenes para el entrenamiento, y la misma cantidad de imágenes se utilizaron para la evaluación del modelo. Las imágenes fueron seleccionadas de forma aleatoria. La evaluación del modelo arrojó los datos mostrados en la Tabla 5.4

Tabla 5.5. Matriz de confusión muestra las cantidades de daño y no daño que fueron reconocidos de forma exitosa y los que fueron confundidos con otras regiones u objetos que no son de interés.

	Con daño	Sin daño
Con daño	457	23
Sin daño	33	447

Tabla 5.5

A través de estos resultados se desprende que la confiabilidad del modelo para la clasificación de imágenes con daño y no daño es del 88%, mientras que el porcentaje de clasificación de error es del 12%.

**Para el uso de la herramienta a continuación de muestran los formularios.**

1. Se muestra la siguiente pantalla en la cual podemos ingresar una imagen para su análisis.

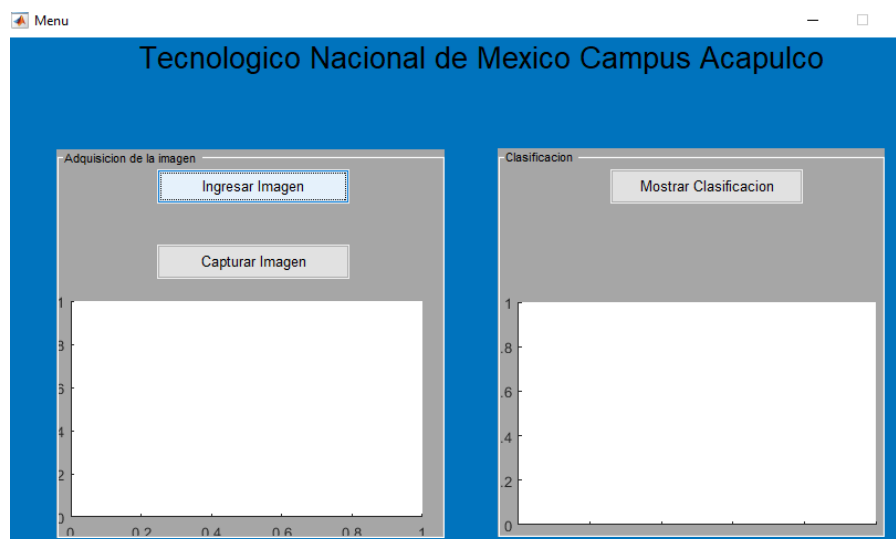


Figura 5.3 Formulario del software



2. Seleccionamos la imagen dependiendo de la dirección de origen y damos clic en abrir.

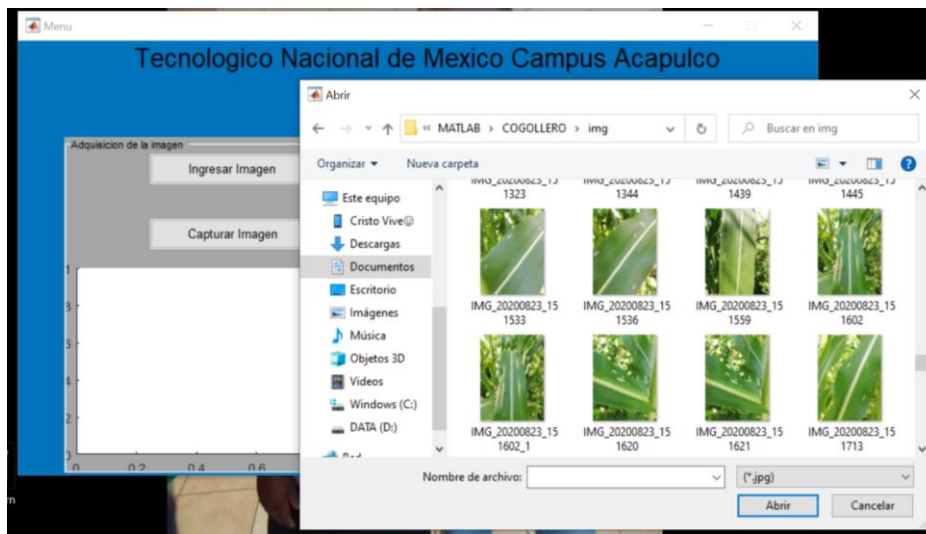


Figura 5.4 Seleccionar imagen.



Figura 5.5 Imagen de la planta de maíz seleccionada

## Capítulo 6

## Conclusiones y Trabajo Futuro

El reconocimiento de enfermedades o daños causado por diferentes tipos de plagas y además en múltiples cultivos que nos proporcionan gran parte de nuestros alimentos, la implementación de software que permiten de una rápida y confiable respuesta para apoyar a los agricultores con información relevante para la toma de decisiones es de gran importancia.

En este trabajo se muestra el proceso de clasificación de imágenes digitales con y sin daños causados por el gusano cogollero en la planta de maíz el cual el algoritmo implementado para la clasificación KNN es uno de los algoritmos básicos, obteniendo buenos resultados, para ello se implementaron algunas otras técnicas en diferentes etapas, desde la adquisición de la imagen hasta la clasificación de las imágenes.

Por lo tanto, podemos concluir lo siguiente:

I. Las técnicas de filtrado que tienen como objetivo resaltar los bordes son adecuadas cuando se integran para la extracción de características de las imágenes digitales.

II. El clasificador KNN obtienen resultados satisfactorios cuando trabajan con grandes cantidades de imágenes para el entrenamiento.

Asimismo, planteamos las siguientes actividades como trabajos futuros.

I. Para que esta herramienta pueda ser utilizada en la solución de problemas reales requiere una mayor confiabilidad en su capacidad de reconocimiento, por lo que hay que integrar más imágenes para su entrenamiento.

II. Este proyecto servirá para posteriores trabajos uno de ellos es que mediante una aplicación móvil realice los procesos de imágenes digitales en la agricultura así tener mayor disponibilidad para los agricultores.

III. Como trabajo futuro se tiene contemplado implementar un dron que realice el recorrido en las hectáreas de cultivo de maíz para la captura de las imágenes así obteniendo la información necesaria para la ayuda a los agricultores y sobre todo en el daño causado por el gusano cogollero.

Por el momento consideramos que la metodología manejada y los resultados obtenidos demuestran que estas técnicas son una alternativa satisfactoria para aplicarse en estas tareas. Asimismo, consideramos que los objetivos inicialmente planteados fueron alcanzados.

## **Bibliografía**

- [1] Ambady, N., & Rosenthal, R. (1992). Thin slices of expressive behavior as predictors of interpersonal consequences: A meta-analysis. *Psychological bulletin*, 256-274.
- [2] SIAP, Servicio de Información Agroalimentaria y Pesquera. (2016). Anuario estadístico de la producción agrícola.
- [3] Subirats-Coll, I. (2013). La web semántica y su aplicación en servicios de información: El caso de la Organización de las Naciones Unidas para la Alimentación y la Agricultura. <http://hdl.handle.net/10760/22452>.
- [4] Andrews, K. L. (1988). Latin american research on *Spodoptera frugiperda* (Lepidoptera: Noctuidae). *Florida entomologist*, 630-653.
- [5] Cruz, I., Figueiredo, M. L. C., Oliveira, A. C., & Vasconcelos, C. A. (1999). Damage of *Spodoptera frugiperda* (Smith) in different maize genotypes cultivated in soil under three levels of aluminium saturation. *International Journal of Pest Management*, 45(4), 293-296.
- [6] Banda, T. J. F.; Enkerlin, S. D.; De Alba, F. G. y Garza, B. L. E. (1981). Importancia económica de *Heliothis zea* (Boddie) y determinación del umbral económico, distribución matemática y muestreo secuencial de

*Spodoptera frugiperda* [J. E. Smith] en maíz criollo. *Fitófilo* 85: 101-118.

- [7] Lezama, R., Molina, J., López, M., Pescador, A., Galindo, E., Ángel, C. A., & Michel, A. C. (2005). Efecto del hongo entomopatógeno *Metarhizium anisopliae* sobre el control del gusano cogollero del maíz en campo. *Avances en Investigación Agropecuaria*, 9(1).
- [8] Harrison, F. P. (1984). Observations on the infestation of corn by fall armyworm (Lepidoptera: Noctuidae) with reference to plant maturity. *Florida Entomologist*, 333-335.
- [9] Mangelsdorf, P.C.; Reeves, R.G. The origin of maize. *Proc. Natl. Acad. Sci. USA* 1938, 24, 303–312.
- [10] Williams, T., Arredondo-Bernal, H. C., & Rodríguez-del-Bosque, L. A. (2013). Biological pest control in Mexico. *Annual Review of Entomology*, 58, 119-140.
- [11] Sánchez, S.J.A.; García, G.; Garza, R.A.A.; Valdez, D.K.M.; González, J.F.; Quiroz, M.H.; Rodríguez, C.V.A. Control biológico de las principales plagas de lepidópteros en pastos con *Trichogramma pretiosum* (Hymenoptera: Trichogrammatidae). In *Proceedings of the Memorias del XXII Congreso*

Nacional de Control Biológico, Texcoco, Estado de México, México, 28–29  
Octubre 1999; Rodríguez, L.E., Escobar, A.J.J., Eds.; Sociedad Mexicana de  
Control Biológico: Montecillo, Estado de México, México, 1999; pp. 183–  
185.

- [12] Nora La Serna Palomino con el proyecto “Técnicas de Segmentación en  
Procesamiento Digital de Imágenes” del año 2009.
  
- [13] J.J. Báez Rojas y M.A. Alonso Pérez con el proyecto “Uso del sistema HSI  
para asignar falso color a objetos en imágenes digitales” del año 2008.
  
- [14] Astrid Vanessa Padilla Jiménez con el proyecto “Procesamiento de  
imágenes para la identificación de plagas en los cultivos de espinaca” del  
año 2016.
  
- [15] Nayid Triana “Técnicas de umbralización para el procesamiento digital de  
imágenes de GEMFoil” diciembre 2016.
  
- [16] Carlos a. Cattaneo “métodos de umbralización de imágenes digitales  
basados en entropía de Shannon y otros” noviembre del 2011.

- [17] Plan de Manejo de Resistencia de Insectos propuesto por A.S.A.”, Manejo de Gusano Cogollero en el Cultivo de Maíz” enero 2018.
- [18] Farmagro Daños del gusano cogollero en el maíz (en línea, sitio web) , Disponible en: <https://www.farmagro.com/noticias/132-da%C3%B1os-del-gusano-cogollero-en-el-ma%C3%ADz>, Diciembre 2018.
- [19] Panorama Agropecuario, Gusano Cogollero (en línea, sitio web), Disponible: <https://panorama-agro.com/?p=505>, octubre 2018.
- [20] Universidad Nacional de San Juan (Argentina) Procesamiento digital de imágenes, departamento de electrónica y automática, Disponible: <http://dea.unsj.edu.ar/imagenes/recursos/Capitulo1.pdf>, octubre 2019.
- [21] PEAT empresa alemana, herramienta de gestión para el diagnóstico de enfermedades vegetales (PLANTIX), Disponible en: <https://plantix.net/es/>, enero 2019.
- [22] Richard Alejandro Moreno, Andrés Felipe Niño, Néstor Jaime Pérez Martínez y Julián Enrique Dueñas, Plagapp una herramienta para reconocer plagas en cultivos, marzo 2017.

- [23] Camilo Andrés Cáceres Flórez, Darío Amaya Hurtado and Olga Lucía Ramos Sandoval “Procesamiento de imágenes para reconocimiento de daños causados por plagas en el cultivo de Begonia semperflorens Link & Otto (flor de azúcar)” Faculty of Engineering. GAV Group. Universidad Militar Nueva Granada, Bogotá, Colombia. E-ISSN 2323-0118.
- [24] J.J. Baez Rojas y M.A. Alonso Perez Coordinacion de Optica INAOE, “Uso del sistema HSI para asignar falso color a objetos en imágenes digitales”, enero 2010.
- [25] ÁLVAREZ G., DAMIÁN A.; GUEVARA G., MARTA L.; HOLGUÍN L., GERMÁN A. “preprocesamiento de imágenes aplicadas a mamografías digitales”, agosto del 2016.
- [26] Cesar Troya S. “LBP y ULBP – Local Binary Patterns y Uniform Local Binary Patterns, Febrero 2016.
- [27] Garcia, Juan, Farías, Nicandro, Benavides, Reyes, Escobar, Emmanuel Procesamiento de imágenes aplicadas a la identificación de agentespatógenos en el cultivo de plátano enero 2013.