



EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

Tecnológico Nacional de México

Centro Nacional de Investigación
y Desarrollo Tecnológico

Tesis de Maestría

Segmentación de Árboles de Higos en Imágenes
Aéreas, mediante Visión Artificial

presentada por

Ing. Eduardo González Sánchez

como requisito para la obtención del grado de
Maestro en Ciencias de la Computación

Directora de tesis

Dra. Andrea Magadan Salazar

Codirector de tesis

Dr. Jorge Alberto Fuentes Pacheco

Cuernavaca, Morelos, México. Julio de 2020.



Cuernavaca, Mor., 24/julio/2020

OFICIO No. DCC/109/2020
Asunto: Aceptación de documento de tesis
CENIDET-AC-004-M14-OFICIO

C. DR. GERARDO VICENTE GUERRERO RAMÍREZ
SUBDIRECTOR ACADÉMICO
PRESENTE

Por este conducto, los integrantes de Comité Tutorial del **C. Ing. Eduardo González Sánchez**, con número de control M17CE091, de la Maestría en Ciencias de la Computación, le informamos que hemos revisado el trabajo de tesis de grado titulado **"Segmentación de Árboles de Higos en Imágenes Aéreas, mediante Visión Artificial"** y hemos encontrado que se han atendido todas las observaciones que se le indicaron, por lo que hemos acordado aceptar el documento de tesis y le solicitamos la autorización de impresión definitiva.

Dra. Andrea Magadán Salazar
Doctorado en Ciencias Computacionales
10654097
Directora de tesis

Dr. Jorge Alberto Fuentes Pacheco
Doctor en Ciencias de la Computación
8533951
Co-director de tesis

Dr. Dante Mújica Vargas
Doctor en Comunicaciones y Electrónica
09131756
Revisor 1

Dr. Raúl Pinto Elías
Doctor en Ciencias en la Especialidad de
Ingeniería Eléctrica
3890453
Revisor 2

C.c.p. Depto. Servicios Escolares
Expediente / Estudiante
JGGS/Imz



EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

Centro Nacional de Investigación y Desarrollo Tecnológico

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

Cuernavaca, Morelos **27/julio/2020**

OFICIO No. SAC/ 242/2020

Asunto: Autorización de impresión de tesis

EDUARDO GONZÁLEZ SÁNCHEZ
CANDIDATO AL GRADO DE MAESTRO EN CIENCIAS
DE LA COMPUTACIÓN
PRESENTE

Por este conducto tengo el agrado de comunicarle que el Comité Tutorial asignado a su trabajo de tesis titulado "*Segmentación de Árboles de Higos en Imágenes Aéreas, mediante Visión Artificial*", ha informado a esta Subdirección Académica, que están de acuerdo con el trabajo presentado. Por lo anterior, se le autoriza a que proceda con la impresión definitiva de su trabajo de tesis.

Esperando que el logro del mismo sea acorde con sus aspiraciones profesionales, reciba un cordial saludo.

ATENTAMENTE

Excelencia en Educación Tecnológica
"Conocimiento y tecnología al servicio de México"

DR. GERARDO VICENTE GUERRERO RAMÍREZ
SUBDIRECTOR ACADÉMICO


CENTRO NACIONAL
DE INVESTIGACIÓN
Y DESARROLLO
TECNOLÓGICO
SUBDIRECCIÓN
ACADÉMICA

C.c.p. M.E. Guadalupe Garrido Rivera. Jefa del Departamento de Servicios Escolares
Expediente
CVGR/CHG



Interior Internado Palmira S/N, Col. Palmira, C. P. 62490, Cuernavaca, Morelos.

Tel. (01) 777 3 62 77 70, ext. 4106, e-mail: dir_cenidet@tecnm.mx

www.tecnm.mx | www.cenidet.edu.mx



Resumen

En este trabajo se desarrolló un sistema de visión artificial, para la segmentación de imágenes aéreas correspondientes a plantaciones de árboles de higos, ubicadas en el estado de Morelos, obtenidas a través de un vehículo aéreo no tripulado (*dron*). El objetivo fue segmentar imágenes aéreas a través de un sistema de visión artificial, para detectar las regiones correspondientes a árboles de higos presentes en las imágenes, por lo que fue necesario eliminar sombras, maleza y áreas de terreno rocalloso.

La propuesta de solución se integra de las siguientes etapas: Primero se aplica un preprocesamiento transformando las imágenes originales, con formato *RGB* a un espacio de color *HSV*, seleccionando la imagen correspondiente al canal *H*, se umbraliza para detectar las áreas en color verde. Para lograr una localización más precisa de las regiones correspondientes al tono verde en las cuales se encuentran los árboles de higos, se utilizó el algoritmo de agrupamiento *Fuzzy C-Means*.

Sin embargo, algunas imágenes cuentan con vegetación de otro tipo ajeno al de interés y que se empalma con los árboles, por lo que fue necesario recurrir a la implementación de descriptores de textura para llevar a cabo una segmentación con mayor detalle y de esta manera realizar la separación de regiones entre los diversos tipos de vegetación presentes en las imágenes. Después, para la etapa de reconocimiento se implementó el clasificador de aprendizaje automático Máquinas de Soporte Vectorial, cuya entrada fue la información generada a través de los descriptores de textura y se evalúa a través de la implementación de métricas como *Precision*, *Recall*, *Accuracy* y así determinar la separación entre los diferentes tipos de vegetación. Finalmente, se evalúa la segmentación de imágenes que se realiza con el sistema de visión artificial, la cual se lleva a cabo a través de las métricas para evaluar la segmentación, “Variation of Information” (*VOI*), “Índice Probabilístico Aleatorio”, (*PRI*) y “Coeficiente Jaccard” (*JC*); con resultados que cumplen las expectativas esperadas.

Palabras Clave: Dron, Fuzzy C-Means, Máquinas de Soporte Vectorial.

Abstract

In this work an artificial vision system was developed, for the segmentation of aerial images corresponding to fig tree plantations, located in the state of Morelos, obtained through an unmanned aerial vehicle (drone). The objective was to segment aerial images through an artificial vision system, to detect the regions corresponding to fig trees present in the images, so it was necessary to remove shadows, weeds and areas of rocky terrain.

The solution proposal is integrated from the following steps: First a preprocessing is applied transforming the original images, RGB format to an HSV color space, selecting the image corresponding to the H-channel, is thresholded to detect areas in green. To achieve a more precise location of the regions corresponding to the green tone in which the fig trees are located, the Fuzzy C-Means grouping algorithm was used.

However, some images have vegetation of another type other than that of interest and that is spliced with trees, so it was necessary to resort to implementing texture descriptors to carry out a segmentation in greater detail and thus perform the separation of regions between the different types of vegetation present in the images. Then, for the reconnaissance stage was implemented the machine learning classifier Vector Support Machines, whose input was the information generated through texture descriptors and is evaluated through the implementation of metrics as Precision, Recall and Accuracy to determine the separation between different vegetation types. Finally, image segmentation is evaluated with the machine vision system, which is performed through metrics to evaluate the segmentation, "Variation of Information" (VOI), "Rand Probabilistic Index", (PRI) and "Jaccard Coefficient" (JC); with results that meet the expected expectations.

Keywords: Drone, Fuzzy C-Means, Vector Support Machines.

Dedicatoria

Quiero dedicar este trabajo de tesis a cada una de las personas que forman parte de mi vida, por contribuir en la motivación y apoyo incondicional para llevar a cabo el desarrollo de este tema de investigación y permitirme el haber llegado a este momento tan importante de mi formación profesional. Por lo que les quiero agradecer sinceramente por brindarme una segunda oportunidad en mi formación académica, personal y de esta manera realizar un cambio radical en mi vida, por lo que no me queda más que decir MUCHAS GRACIAS.

Agradecimientos

Agradezco al Tecnológico Nacional de México / CENIDET por haberme aceptado como alumno de esta institución y por el aprendizaje obtenido durante la maestría.

Agradezco al Consejo Nacional de Ciencia y Tecnología CONACYT por el apoyo económico brindado durante los dos años de estudio de posgrado para el desarrollo de este tema de tesis.

Agradezco a la Fundación Telmex por el apoyo brindado durante el desarrollo de la maestría.

Agradezco a mi directora de tesis la Dra. Andrea Magadán Salazar, así como a mi codirector el Dr. Jorge Alberto Fuentes Pacheco, por su asesoría y comentarios durante la implementación de este proyecto de investigación.

Agradezco cordialmente a mi comité revisor, el Dr. Dante Mújica Vargas y el Dr. Raúl Pinto Elías por las observaciones, recomendaciones y comentarios brindados ya que fueron de gran utilidad para el desarrollo y conclusión de este trabajo de investigación.

Agradezco al personal administrativo del CENIDET que siempre me brindo un buen servicio y de manera cordial, en especial a Liliana Mérida Zagal por brindarme su apoyo en todos los trámites necesarios para obtener el grado de Maestro en Ciencias.

Contenido

Resumen	v
Abstract	vi
Dedicatoria	vii
Agradecimientos	viii
Lista de figuras	xii
Lista de tablas	xiii
Acrónimos	xiv
Capítulo 1	1
1.1 Introducción.....	1
1.2 Delimitación del problema	2
1.3 Propuesta de solución.....	2
1.3.1 Objetivo general.....	2
1.3.2 Objetivos específicos	2
1.4 Alcances y limitaciones.....	3
1.5 Metodología de solución	3
1.6 Organización de la tesis.....	4
Capítulo 2 . Estado del arte	6
2.1 Introducción	6
2.2 Antecedentes del proyecto realizados en CENIDET	6
2.3 Estado del arte	9
2.4 Comentarios.....	18
Capítulo 3 . Metodología de solución y marco teórico	19
3.1 Introducción	19
3.2 Metodología de solución	20
3.3 Marco teórico.....	21
3.3.1 Preprocesamiento con el modelo de color <i>HSV</i>	21
3.3.2 Algoritmo de agrupamiento <i>Fuzzy c-means</i>	22
3.3.3 Representación y descripción	24
3.3.3.1 Descriptor Local Binary Patterns (LBP)	24
3.3.3.2 Descriptor filtros de Gabor	26
3.3.3.2.1 Diferentes parámetros que controlan la forma y el tamaño del filtro 2D de <i>Gabor</i>	28
3.3.3.3 Medidas de Haralick.....	31

3.3.3.3.1 Cálculo de la matriz de co-ocurrencia	33
3.3.3.3.2 Medidas estadísticas de la textura	35
3.3.4 Reconocimiento e interpretación	38
3.3.4.1 Clasificador Máquinas de Soporte Vectorial (MVS).....	38
3.3.5 Métricas para evaluar la segmentación	40
3.3.6 Comentarios.....	42
Capítulo 4 . Análisis, diseño e implementación del sistema	43
4.1 Introducción	43
4.2 Análisis del sistema.....	43
4.3 Diseño del sistema.....	43
4.4 Software utilizado para desarrollo del sistema	45
4.5 Interfaz gráfica	45
Capítulo 5 . Experimentación y resultados	50
5.1 Introducción	50
5.2 Banco de imágenes.....	50
5.3 Experimentación y resultados.....	52
5.3.1 Experimentación con el modelo de color HSV	52
5.3.2 Experimentación con el algoritmo de agrupamiento fuzzy c-means	55
5.3.3 Experimentación con descriptores de textura	58
5.3.3.1 Descriptor Local Binary Patterns (LBP)	58
5.3.3.2 Fusión entre los descriptores medidas de Haralick y filtros Gabor.....	59
5.3.3.3 Clasificación con Máquinas de Soporte vectorial.....	62
5.3.4 Evaluación de la segmentación con fuzzy c means	64
Capítulo 6 . Conclusiones	70
5.1 Introducción	70
5.2 Objetivos alcanzados	70
5.3 Aportaciones.....	73
5.4 Conclusiones	73
5.5 Trabajos futuros.....	74
5.5 Productos adicionales académicos	74
Referencias	76
Anexos.....	80

Anexo A. Participación en el 1er coloquio “Artificial Intelligence”, 2019	80
Anexo B. Participación en “2019 IEEE Summer School on Computational Intelligence and Robotics”	81
Anexo C. Participación en la escuela de Inteligencia Artificial (IA), octubre de 2018	82
Anexo D. Participación 1er Jornada de Ciencia y Tecnología Aplicada, noviembre de 2018...	83
Anexo E. Participación en el Concurso de Proyectos de Innovación, noviembre de 2018	84

Lista de figuras

Figura 1.1 Ejemplo de una imagen original (a), con su Ground Truth (b) y su respectiva segmentación elaborada manualmente (c), (BSDS-300).	1
Figura 3.1 Esquema de Visión Artificial (dado por Gonzalez & Woods, 2002).	19
Figura 3.2 Esquema de la metodología de solución para la segmentación de imágenes aéreas correspondientes a plantaciones de árboles de higos.	20
Figura 3.3 Representación gráfica del espacio de color HSV (García-Lamont et al. 2018).	22
Figura 3.4 El primer paso para construir una LBP es tomar el vecindario de 8 píxeles que rodea un píxel central y establecer un umbral para construir un conjunto de 8 dígitos binarios (Li w.et al. 2015).	25
Figura 3.5 Ejemplo del cálculo de la representación LBP (derecha), imagen de entrada original (izquierda) (Rosebrock A. 2015).	25
Figura 3.6 Finalmente, se calcula un histograma que tabula el número de veces que ocurre cada patrón LBP. Los valores del histograma resultan ser el vector de características (Rosebrock A. 2015).	26
Figura 3.7 Banco de 16 filtros de Gabor orientados en diferentes ángulos (Rafael & Oliveros, 2015).	27
Figura 3.8 (a) izquierda La imagen de entrada de Lenna y (b) derecha la imagen de salida después de pasarla a través del banco de filtros de Gabor (Rafael & Oliveros, 2015).	28
Figura 3.9 Representación gráfica del parámetro Lambda con tres diferentes valores (Tadic et al. 2016).	29
Figura 3.10 Representación gráfica de Tetha con diferentes valores en cuanto al ángulo de orientación (Tadic et al. 2016).	29
Figura 3.11 Representación gráfica de Gamma que controla la altura de la función de Gabor (Tadic et al. 2016).	30
Figura 3.12 Representación gráfica de sigma que controla el tamaño total de la envoltura de Gabor (Tadic et al. 2016).	30
Figura 3.13 En a) se muestra una imagen con su respectiva ventana móvil de 5x5 en dos posiciones y el píxel central que recibe el resultado. En b) se muestra el resultado de toda la operación (Presutti, M. 2004).	32
Figura 3.14 Los 8 vecinos del pixel X de acuerdo al ángulo utilizado en el cálculo de la matriz de co-ocurrencia (Presutti, M. 2004).	33
Figura 3.15 Muestra de una imagen original donde se puede observar 4 valores con distintos niveles de gris (0, 1, 2, 3) (Leal, A. 2006).	33
Figura 3.16 Total de pares posibles para una relación espacial (1,0) si la matriz es de 4 x 4 (Leal, A. 2006).	35
Figura 3.17 Representación de separador lineal de las MVS. La frontera de decisión debe estar tan lejos de los datos de ambas clases como sea (Colmenares, 2012).	39
Figura 3.18 MVS no linealmente separable inducida por una función kernel (Colmenares, 2012).	40
Figura 4.1 Etapas del sistema para segmentación de imágenes aéreas	44
Figura 4.2 Ventana principal del sistema segmentación de imágenes aéreas mediante visión artificial.	46
Figura 4.3 Selección de imagen o imágenes por carpeta para aplicarles el preprocesamiento.	46
Figura 4.4 Transformación de color RGB a HSV y extracción de color verde, utilizando en especial la banda H.	47
Figura 4.5 Etapa de segmentación imagen obtenida después de realizar la transformación de color RGB a HSV.	48

Figura 4.6 Etapa de extracción de características, a través de la aplicación de descriptores en imágenes donde se empalman los árboles de higos con otro tipo de vegetación.....	48
Figura 4.7 Etapa de clasificación en la que se lleva a cabo la separación de clases, a través de aprendizaje automático y aplicación de descriptores de textura.....	49
Figura 5.1 Ejemplos de imágenes con plantaciones de árboles de higos, en las cuales no existe otro tipo de vegetación adicional a los árboles, solo se puede ver suelo y rocas.	51
Figura 5.2 Imágenes con plantaciones de árboles de higo, en las cuales, si existe otro tipo de vegetación adicional a los árboles, donde se puede observar pasto, hierbas, suelo y rocas.....	51
Figura 5.3 Imágenes del Ground truth elaboradas por el grupo de trabajo de la Universidad del Estado de Morelos.....	52
Figura 5.4 Ejemplo de segmentación obtenida con el algoritmo fuzzy c-means e imagen del ground truth.	64
Figura 5.5 Se presenta la imagen original 083.jpg, el resultado de su segmentación con fuzzy c-means y el ground truth.....	65
Figura 5.6 Se presenta la imagen original 0101.jpg, el resultado de su segmentación con fuzzy c-means y el ground truth.....	67
Figura 5.7 Se presenta la imagen original 010.jpg, el resultado de su segmentación con fuzzy c-means y el ground truth.....	68

Lista de tablas

Tabla 2.1 Artículos referentes a la segmentación de imágenes.	15
Tabla 2.2 Descriptor de textura Patrones Locales Binarios (LBP).....	17
Tabla 3.1 Todas las posibles combinaciones de los 4 niveles de gris de la imagen original.	34
Tabla 5.1 Casos A1, B1, C1 y D1, son ejemplos de la experimentación que se realizó para la obtención del tono verde, en la etapa de preprocesamiento.	54
Tabla 5.2 Casos A2 y B2 en los cuales hay árboles de higo, casos C2 y D2 con traslape de vegetación.	56
Tabla 5.3 Casos A3 y B3 en los cuales se aplicó el descriptor LBP a la imagen completa y los casos C3 y D3 es la aplicación del descriptor a las imágenes de 128x128 píxeles.	60
Tabla 5.4 Casos A4 y B4 se aplicó la combinación de los descriptores filtros de Gabor con las medidas de Haralick, pero a toda la imagen, en cambio en los casos C4 y D4 se les aplicó a las imágenes fragmentadas de 128x128 píxeles.....	61
Tabla 5.5 Comparación de la aplicación de los descriptores de textura aplicados en la etapa de entrenamiento.	62
Tabla 5.6 Comparación entre los descriptores aplicados en la etapa de prueba caso B2.....	63
Tabla 5.7 Comparación entre los descriptores aplicados en la etapa de prueba caso D2.	63
Tabla 5.8 Métricas aplicadas para evaluar la segmentación de la imagen 036.jpg.	65
Tabla 5.9 Métricas para evaluar la segmentación de la imagen 083.jpg.....	66
Tabla 5.10 Métricas para evaluar la segmentación de la imagen 0101.jpg.....	67
Tabla 5.11 Métricas para evaluar la segmentación de la imagen 010.jpg.....	69
Tabla 6.1 Descripción de objetivos específicos y la solución que se implementó para cada uno.....	71
Tabla 6.2 Alcances propuestos y reales.....	72

Acrónimos

Listado de los acrónimos utilizados en este documento.

- ASM** *Angular Second Moment*, es una medida de uniformidad textural en una imagen.
- ERBF** *Exponential Radial Basis Function*, función de la distancia euclidiana entre vectores.
- FCM** *Fuzzy C-Means*, es un algoritmo de agrupamiento difuso para segmentación de imágenes.
- GT** *Ground truth*, es la “verdad fundamental” o segmentación correcta a la que se desea aproximar la segmentación.
- GLCM** *Grey Level Co-occurrence Matrix*, Matriz de co-ocurrencia en nivel de color gris en base a los píxeles de una imagen.
- HSV** Por sus siglas en inglés (*Hue, Saturation, Value*), en español Matiz, Saturación y Brillo.
- JI** *Jaccard Index*, Índice de Jaccard, medida para evaluar segmentación de imágenes.
- LBP** *Local Binary Patterns*, Patrones Locales Binarios es un descriptor de texturas.
- MSV** Máquinas de Soporte Vectorial, es un algoritmo para la clasificación de información.
- PRI** *Probabilistic Rand Index*, Índice de Probabilidad Aleatoria, evalúa la segmentación.
- RBF** *Radial Basis Function*, es una función kernel utilizada en aprendizaje automático.
- RGB** Modelo cromático que consiste en representar distintos colores a partir de la mezcla de estos tres colores primarios (Rojo, Verde, Azul).
- SLIC** *Simple Linear Iterative Clustering*, algoritmo de agrupamiento basado en super-píxeles.
- VOI** *Variation of Information*. Variación de la Información, medida para evaluar la segmentación.

Capítulo 1

1.1 Introducción

En las últimas décadas, la visión artificial ha sido ampliamente estudiada y utilizada en el sector agronómico mejorando la gestión de calidad que conforman los sistemas de control de malezas, para llevar a cabo la identificación y detección de plantas, así como para otras aplicaciones agrícolas donde se involucran sistemas robóticos como la clasificación y recolección de frutos. Esta evolución ha llevado a muchos investigadores a desarrollar métodos de procesamiento de imágenes para trabajar en diferentes campos y en entornos con condiciones controladas y no controladas (Hamuda, Glavin, and Jones 2016).

El éxito del desarrollo de estos sistemas de visión artificial es cada vez mayor y, un ejemplo de ello es que, con la información generada, el agricultor se apoya para tomar de decisiones para la fertirrigación, podas o aclareos, para conocer el estado de salud de sus árboles, entre otras cosas. El principal inconveniente en su implementación es la automatización del procesamiento de imágenes adquiridas en condiciones reales.

Una etapa esencial para el análisis automático de imágenes eficiente, es el contar con un buen proceso de segmentación; no obstante, debido a su complejidad sigue siendo uno de los temas de investigación que más importancia tiene en el área de la visión por computadora. La segmentación de imágenes hace referencia al agrupamiento de regiones que comparten una propiedad en común como el color, la textura, etc.; este proceso se lleva a cabo a través de una fusión entre los píxeles de las imágenes y de esta manera formar regiones homogéneas, ver ejemplo en figura 1.1

La segmentación de imágenes no es una tarea fácil, debido a que depende bastante de las condiciones que presentan las imágenes que se desean analizar. La segmentación de imágenes es un proceso decisivo para el reconocimiento de objetos e interpretación de la imagen, en un sistema de visión artificial (García-Lamont et al. 2018).

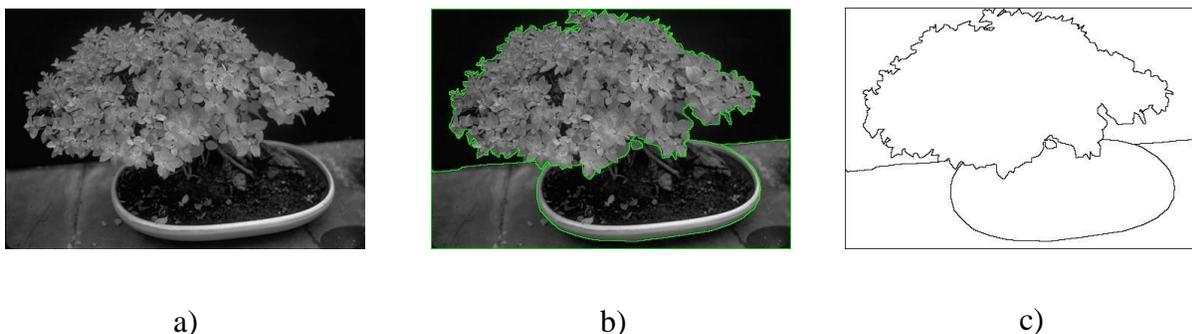


Figura 1.1 Ejemplo de una imagen original (a), con su Ground Truth (b) y su respectiva segmentación elaborada manualmente (c), (BSDS-300).

1.2 Delimitación del problema

El ser humano cuenta con un grupo de sentidos que le son de gran utilidad para su sobrevivencia; la vista es uno de ellos. Este sentido le permite observar el conjunto de objetos que integran una imagen, la capacidad de percibir todo el contenido de forma detallada, adquiriendo información de la relación que existe entre ellos, la forma, color, etc., de tal forma que logra obtener una descripción y representación de los objetos presentes para su reconocimiento e interpretación de la escena. En este trabajo se pretende simular tal capacidad para una aplicación agrícola específica.

Actualmente, productores de higo analizan de manera manual imágenes aéreas de árboles de higos para localizar y posteriormente contabilizar el número de árboles presentes en un área. Para lograr esto de manera automática, es necesario contar con un sistema de visión artificial que realice una segmentación automática de los árboles en un ambiente no controlado; sin embargo, como ya se mencionó es una tarea compleja debido a la presencia de sombras, vegetación presente y de arbustos; además de cambios en la intensidad luminosa en las imágenes, perspectivas y escala.

En la actualidad, no se encontró un sistema de visión artificial, el cual realice la segmentación de plantaciones de higos, en imágenes aéreas de alta resolución, capturadas por una cámara RGB montada en un vehículo aéreo no tripulado.

1.3 Propuesta de solución

En el siguiente apartado se describen los objetivos, alcances y limitaciones de este proyecto de tesis, así como la metodología de solución para este trabajo de investigación.

1.3.1 Objetivo general

Desarrollar e implementar un sistema de visión artificial que realice la segmentación de la zona correspondiente a árboles de higos, a partir del análisis de imágenes aéreas adquiridas con drones.

1.3.2 Objetivos específicos

- Estudiar y analizar diferentes algoritmos para segmentar imágenes.
- Implementar un algoritmo de segmentación de imágenes que permita localizar la zona correspondiente a árboles de higos en una imagen adquirida a través de un vehículo aéreo no tripulado.
- Estudiar y analizar diferentes descriptores de textura y color para zonas de vegetación.

- Definir e implementar las características que permitan la descripción e identificación de la región correspondiente a árboles de higos.

1.4 Alcances y limitaciones

Alcances:

- Se realiza la segmentación automática de áreas correspondientes a árboles de higos, independientemente de la edad del árbol.
- El sistema es capaz de segmentar las zonas correspondientes a árboles de higos, descartando áreas correspondientes a pasto, tierra, sombras y otros objetos presentes en la imagen.
- El sistema de visión artificial es capaz de trabajar con imágenes adquiridas con diferentes intensidades luminosas.
- El desarrollo del sistema se realiza en el lenguaje de programación *Python* y se utilizan las bibliotecas de desarrollo de *OpenCV*, también se utilizó *PyQT* para el desarrollo de la interfaz gráfica.

Limitaciones:

- El sistema no realiza el conteo de árboles que se presentan en la imagen analizada.
- No se toma en cuenta el estado de salud de los árboles de higos para este proyecto.

1.5 Metodología de solución

Las etapas que se siguieron para dar solución al problema planteado son las siguientes:

- **Revisión del estado del arte**

En este apartado se realizó una revisión de la diversidad de métodos y algoritmos que existen en la literatura reciente aplicados para llevar a cabo la segmentación de imágenes y de esta manera encontrar alternativas para dar solución al problema que se tiene en este tema de investigación.

- **Antecedentes sobre el tema de tesis, realizados en CENIDET**

En esta sección se realizó un análisis, de trabajos de tesis relacionados con este tema de investigación, desarrollados en CENIDET y que apoyaron esta tesis a través de la revisión de los métodos utilizados en esas investigaciones.

- **Adquisición de Imágenes**

Este apartado describe las características de las imágenes que fueron utilizadas. La adquisición de dichas imágenes se llevó a cabo por un grupo de trabajo de la Universidad Autónoma del Estado de Morelos, permitiendo contar con un conjunto de datos propio.

- **Pre-Procesamiento**

En este apartado se trató de mejorar las condiciones de la imagen de entrada, en términos de contraste y/o de los diferentes modelos de color, para posteriormente realizar la segmentación.

- **Segmentación**

Este apartado se encarga de localizar las potenciales zonas de árboles presentes en las imágenes.

- **Representación y descripción**

Este apartado es el encargado de describir las regiones, antes localizadas como correspondientes a árboles, en término de sus características más representativas, en este caso a través del color y textura.

- **Reconocimiento e interpretación**

El objetivo de este módulo es identificar de manera precisa las zonas pertenecientes a árboles de higos, al realizar la clasificación de la información con la ayuda de un algoritmo de aprendizaje automático.

- **Experimentación y resultados**

En este apartado se presentan y analizan los resultados obtenidos de todo el proceso antes mencionado, mostrando visualmente la región de interés segmentada, que en este caso sería la zona correspondiente a árboles de higos.

1.6 Organización de la tesis

En el capítulo 2 se presenta el análisis de investigaciones revisadas del estado del arte, que permitieron conocer los métodos utilizados para realizar transformaciones de espacios de color, segmentación de imágenes y la aplicación de diversos descriptores de color y textura. El análisis resultante se puede observar, en una tabla, de manera condensada y ordenada, los diferentes métodos utilizados para llevar a cabo el proceso de segmentación de imágenes. También contiene el estudio de los trabajos de tesis realizados en CENIDET. Finalmente, se puede encontrar una breve conclusión del capítulo.

El capítulo 3 contiene la metodología de solución para este tema de investigación, así mismo se puede encontrar un contenido teórico de cada una de las técnicas que la conforman, al finalizar este contenido se pueden encontrar comentarios y conclusiones acerca de este capítulo.

En el capítulo 4 se explican las características del conjunto de imágenes utilizado, el objetivo de las pruebas y la experimentación y resultados obtenidos de manera detallada a través de las métricas

respectivas. Además, se mencionan las diferentes herramientas que se tomaron en cuenta para el desarrollo del sistema de visión artificial.

En el capítulo 5 se pueden encontrar las conclusiones finales de esta tesis, el logro de los objetivos alcanzados, las aportaciones y se plantean los trabajos futuros relacionados con el tema desarrollado.

Capítulo 2 . Estado del arte

2.1 Introducción

Este capítulo presenta de manera sintetizada, un conjunto de artículos relacionados con la segmentación de imágenes, en donde se presentan métodos para llevar a cabo dicha actividad tanto en ambientes controlados como no controlados; así mismo se pueden ver algunos de los resultados que obtuvieron, las métricas de evaluación y conjuntos de datos que se utilizaron en la segmentación. También se muestra un conjunto de artículos que corresponden a la técnica *Local Binary Pattern (LBP)*, que se utiliza para la extracción de características, principalmente lo emplean para la textura y color. Además, el capítulo incluye los antecedentes relacionados con este tema de investigación de tesis, realizados en el CENIDET.

2.2 Antecedentes del proyecto realizados en CENIDET

El Tecnológico Nacional de México campus CENIDET cuenta con cuatro investigaciones que se relacionan directamente con el tema desarrollado y que se muestran a continuación:

1. David Domínguez López, Tesis de maestría. “Extracción de Superpíxeles y Fusión Local Mediante un Algoritmo de Agrupamiento Difuso Intuitivo”. Dirigida por el Dr. Dante Mújica Vargas y el Dr. Raúl Pinto Elías. Junio del 2019.

El objetivo de la tesis fue Implementar y adaptar el algoritmo de agrupamiento difuso intuitivo para una extracción eficiente de superpíxeles en imágenes de resonancia magnética del cerebro. En el trabajo se desarrolló una metodología basada en una adaptación del algoritmo de agrupamiento difuso intuitivo para la extracción de superpíxeles en imágenes de resonancia magnética del cerebro. El método propuesto se basó en el método de inicialización del algoritmo *SLIC*. El método puede usarse en imágenes a color, teniendo una buena adaptación con los bordes de la imagen. En general, el método propuesto tuvo un buen rendimiento en las experimentaciones realizadas en los conjuntos de datos de *BrainWeb* y *BSD500*.

2. Tesis de maestría, concluida en julio del 2020 denominada “Diseño e Implementación de un Modelo Autoadaptable de Segmentación de Imágenes Digitales por Discontinuidades”. Realizada por José Manuel Pérez Tovar y dirigida por el Dr. Raúl pinto Elías.

El objetivo de este trabajo fue diseñar e implementar un modelo que aprenda cómo ajustar un sistema de visión artificial clásico, para resolver un problema específico, partiendo de un conjunto de primitivas o técnicas aplicadas a un conjunto de imágenes. Se implementaron siete técnicas de segmentación por discontinuidad: *Canny*, *Scharr*, *Sobel*, *Laplaciano*, segmentación morfológica y *Prewitt* y cinco algoritmos de aprendizaje supervisado: *IB1* (aprendizaje con base en instancias), *KNN* (K-vecinos más cercanos), *SVM* (máquina de soporte vectorial) con *kernel* lineal, *SVM* con *kernel* polinomial y *SVM* con *kernel* de base radial. Al final se concluye que el modelo implementado puede registrar la secuencia de técnicas exitosas y no exitosas diferenciadas por el valor de su métrica de similitud. Las características se describen a través de los descriptores visuales y estadísticos.

3. Mildred Morales Xicohtencatl. Tesis de maestría de octubre de 2018. “Segmentación no paramétrica de tejidos cerebrales mediante una arquitectura paralela de redes neuronales convolucionales”. Dirigida por el Dr. Dante Mújica Vargas y el Dr. Raúl Pinto Elías.

El objetivo fue segmentar imágenes de resonancia magnética cerebral utilizando una red neuronal convolucional, logrando una arquitectura paralela convolucional que logra segmentar las regiones de una imagen cerebral, sin especificar de forma previa el número de regiones existentes, independientemente de la imagen. La arquitectura presentada no requiere inicialización de parámetros y permite realizar la segmentación en imágenes sin procesamiento.

4. Diego Gabriel Suárez Santiago. Tesis de maestría concluida en enero del 2018. “Sintonización de una Red Totalmente Conectada para Segmentación de Dos Clases de Objetos en Imágenes”. Dirigida por el Dr. Dante Mújica Vargas y el Dr. Manuel Mejía Lavalle.

El objetivo del trabajo fue Sintonizar una Red Neuronal Convolucional para segmentar dos clases de objetos (persona y ave) del repositorio *BSDS500* implementada en una Unidad de Procesamiento Gráfico. El autor concluye que la tesis ofrece una recopilación de antecedentes para quienes requieran entrenar una red neuronal convolucional a partir de un repositorio proporcionado, ya que se describen los procedimientos para poder hacerlo. También presenta su modelo propuesto denominado *FCN-8s* que tiene mejores resultados en la segmentación de dos clases: pájaros y personas, mejorando los resultados de *FCN-Alexnet*.

5. Tesis “Indexado y Recuperación de Imágenes por Contenido” (*Troncoso 2007*). El objetivo principal de Troncoso fue estudiar las técnicas de indexado y recuperación de imágenes para desarrollar un sistema de recuperación de imágenes por contenido, incluyendo caracterización, mediante descripciones parciales de los elementos de la imagen, clasificación y recuperación automática de imágenes por contenido.

Se menciona específicamente que, para realizar el procesamiento digital de imágenes, existen métodos para llevar a cabo una extracción de información basándose en las características más sobresalientes de una imagen, como los son: el color, la textura y formas. La autora propone

utilizar imágenes artificiales para evaluar las técnicas de indexado y recuperación, así como utilizar al menos diez descriptores de características.

Finalmente, la autora concluye que cumplió con sus objetivos y alcances al utilizar imágenes reales en lugar de artificiales, con 4 categorías y 29 descriptores, obteniendo buenos resultados en su experimentación.

6. Tesis “Caracterización Automática de Imágenes en un Dominio Transformado” (*Galeana 2008*). El objetivo del trabajo fue estudiar, seleccionar e implementar técnicas de transformación de dominio y funciones de caracterización aplicables en el dominio transformado, y evaluar experimentalmente la hipótesis de que transformando el dominio de la imagen sería posible obtener una mejor caracterización de su contenido y buscar descriptores en otros dominios independientes del color y la forma de los objetos, también conocer si son mejores que aplicados en el dominio original de la imagen.

Galeana menciona que logró validar la hipótesis de que transformando el dominio de la imagen se obtienen mejores valores de caracterización. Para demostrarlo realizó una comparación del dominio original de las imágenes, del paramétrico y los modelos de color. Hace mención que las transformadas wavelets proporcionan mejores resultados que el dominio original, cuando se trabaja con cambios de escala y rotación. Con la wavelet Daubechies 8 en combinación con algoritmos de clasificación, se alcanzó: con el algoritmo AdaBoostM1 2% de ganancia con respecto al dominio original, con Bagging 1.5% y MultiBoostAB 1.25%.

7. Tesis “Caracterización de Texturas Naturales” (*Avellaneda 2009*). El objetivo primordial de la tesis fue estudiar las técnicas de segmentación de imágenes y las de caracterización de texturas, elegir una de estas técnicas y adaptarla o desarrollar una nueva para implementarla en la segmentación de imágenes con escenas naturales.

Avellaneda propone una metodología para segmentar una imagen y reconocer las texturas presentes en ella. La metodología utiliza las reglas generadas por See5 en la etapa de entrenamiento, el algoritmo K-Means Difuso y una caracterización de las clases de texturas.

Concluye que su objetivo se cumplió, ya que realizó un estudio de las técnicas de caracterización de texturas y de segmentación de imágenes, de acuerdo a este estudio se eligieron diferentes técnicas para la caracterización de texturas y se eligió el algoritmo K-Means difuso para realizar la segmentación de imágenes. Estas técnicas se implementaron en un sistema de visión artificial en el cual se pudo realizar la caracterización y segmentación de imágenes con escenas naturales.

Las investigaciones desarrolladas en CENIDET permitieron analizar y comprender la introducción a los temas de segmentación de imágenes y descriptores de color y textura, debido a que presentan interesantes metodologías para realizar la selección, extracción y clasificación de características presentes en imágenes de escenas naturales. Se considera importante analizar algunas de las características de color y textura consideradas en los trabajos y evaluar su capacidad para localizar las regiones pertenecientes a árboles en imágenes capturadas en ambientes reales.

2.3 Estado del arte

Este apartado consiste en la recopilación y estudio sobre el estado del arte en donde se detallan los trabajos más recientes que tienen una relación directa o parcial con este documento de tesis. De manera general en esta sección se habla de diferentes técnicas que se están utilizando para segmentar imágenes correspondientes a escenas naturales, así como técnicas para describir las mismas. Sin embargo, se presentan solamente aquellos que se consideran tienen mayor relación con el tema de tesis.

A continuación, se muestra un conjunto de artículos sintetizados en tablas, los cuales fueron de gran contribución para el desarrollo de este tema de tesis. Como se puede observar, se presenta un análisis de los trabajos relacionados con las transformaciones de modelos de color y la segmentación de imágenes, que han sido empleadas en los últimos años a través de diferentes trabajos de investigación ya desarrollados, los cuales son presentados en la tabla 2.1. En la tabla 2.2 se realizó un análisis de descriptores de textura y color, los cuales fueron tomados en cuenta para ser aplicados en este trabajo de investigación para la extracción de características.

“Automatic computing of number of clusters for color image segmentation employing fuzzy c-means by extracting chromaticity features of colors” (García et al. 2018)

En este trabajo de investigación los autores proponen un método para la segmentación de imágenes a color mediante el cálculo automático del número de grupos de píxeles, utilizando el algoritmo *fuzzy c-means*; ellos tratan de emular la percepción humana, a través de la implementación de una red neuronal no supervisada.

El aprendizaje de las redes neuronales que proponen se realiza sólo una vez y, luego se puede usar en cualquier imagen dada sin entrenarla de nuevo. De acuerdo con su evaluación cuantitativa y el promedio de las neuronas más activadas, el mejor rendimiento se obtiene utilizando un mapa autoorganizado de 4x4 neuronas. Los autores determinan que su propuesta es, hasta cierto punto, robusta a la iluminación no uniforme. En este caso utilizan la base de datos *Berkeley (BSD-300)*.

Calculan y comparan la evaluación cuantitativa de las imágenes segmentadas obtenidas con trabajos relacionados utilizando el índice aleatorio probabilístico y la variación de información que son métricas que se utilizan para evaluar la segmentación de imágenes.

“Segmentation of images by color features: A Survey” (García et al. 2018)

En este trabajo de investigación se lleva a cabo un análisis de diferentes trabajos que abordan la segmentación de imágenes basada en las características de color. En este artículo se pueden observar los diferentes métodos que se han utilizado en los últimos años para realizar segmentación de imágenes, entre los que se pueden encontrar los siguientes: técnicas basadas en detección de bordes, umbralización, umbral de histograma, región, agrupamiento de características y redes neuronales.

En la mayoría de los trabajos se reporta el uso de diferentes espacios de color para realizar la segmentación de imágenes tales como *HSV*, *HSI*, *CieLab*, *YCrBr*, así como métodos de agrupamiento como *fuzzy c-means* o *k-means*; en otros tantos ocupan redes neuronales supervisadas y no supervisadas. Por lo que cada método tiene su complejidad y sus beneficios para llevar a cabo la segmentación de imágenes, ya que todo depende del contenido y las características de los objetos que se encuentren en las imágenes a procesar.

“Comparativa del coste computacional del algoritmo de segmentación OTSU en imágenes satelitales utilizando estrategias de paralelización con CUDA” (Icaya et al. 2018)

En esta investigación los autores realizan una optimización al algoritmo *OTSU* para la segmentación de imágenes satelitales utilizando las estrategias de paralelización mediante la plataforma *CUDA*. También se lleva a cabo una evaluación del rendimiento del algoritmo paralelizado y a través de ello verificar la viabilidad del algoritmo para realizar una segmentación multinivel.

En la implementación comparan el método clásico de umbralización *OTSU* respecto al cálculo del histograma para realizar la paralelización del algoritmo la plataforma *CUDA*. Al poner a trabajar el algoritmo mencionan que a medida que el tamaño de la imagen se incrementa, se incrementará el tiempo requerido para el cálculo del histograma y el cálculo de la imagen de salida. Los factores que afectan en mayor medida la velocidad del algoritmo paralelizado, son el tamaño de la imagen y el número de umbrales.

Las etapas en las que se nota, en mayor medida, los beneficios del algoritmo paralelizado, son el cálculo del histograma, los umbrales detectados y la imagen de salida. En base a los resultados, pudieron determinar que la versión paralela del algoritmo *OTSU*, es 4.66 veces más rápido en el peor de los casos y hasta 25.26 veces más rápido en el mejor de los casos con respecto a la versión secuencial.

“Automatic Crop Detection under Field Conditions Using the HSV Colour Space and Morphological Operations” (Hamuda et al. 2017)

El propósito de los autores es desarrollar un sistema de desmalezado automático donde es importante la detección robusta de la ubicación exacta del cultivo para protegerlo de daños. Para ello proponen implementar un algoritmo basado en características de color, erosión y dilatación morfológica. Mencionan que el algoritmo propuesto utiliza el espacio de color *HSV* (*Hue*, *Saturation*, *Value*) para discriminar cultivos, malezas y suelo, la región de interés la definen filtrando cada uno de los canales de *HSV* entre ciertos valores (valores de umbral mínimo y máximo), posteriormente la región la refinan mediante el uso de filtros morfológicos de erosión y dilatación.

Hacen mención que el rendimiento del algoritmo lo evaluaron comparando los resultados obtenidos con el ground truth (anotación manual). Logrando obtener una sensibilidad de 98.91% y una precisión de 99.04%.

En este trabajo, se propone un nuevo algoritmo basado en la combinación de características del color y las operaciones morfológicas de erosión y dilatación. Este proceso segmenta las regiones de cultivo de coliflor en la imagen separando las malezas y el suelo, trabajando con iluminación natural (nublado, parcialmente nublado y soleado).

“Detección automática de áreas vegetales en zonas urbanas basadas en imágenes aéreas capturadas por un vehículo aéreo no tripulado” (Alvarado-Robles et al. 2016)

El presente artículo muestra una reseña de las recientes áreas de investigación, que se están aplicando en la segmentación de imágenes capturadas desde un vehículo aéreo no tripulado, utilizando los espacios de color *HSV* e *IHSL*, desde la perspectiva de visión artificial y reconocimiento de patrones.

La segmentación con el uso de diferentes espacios de color como son *HSV* y *HSL*, en combinación de histogramas bi-variables presenta una herramienta útil para este tipo de estudios, debido a que se reduce la cantidad de colores en la imagen y hace más fácil detectar áreas verdes automáticamente.

En la presentación de sus resultados definen que, cuando hacen uso de histogramas acromáticos tienen una mayor posibilidad de obtener una segmentación de color errónea, especialmente en los tonos de verde. Por otro lado, cuando utilizan los histogramas cromáticos obtienen una segmentación más adecuada para este tipo de estudios, lo que les da como posibilidad utilizar otros espacios de color para realizar experimentos en un futuro.

“Segmentación Automática de Texturas en Imágenes Agrícolas” (Riomoros, 2016)

Riomoros propone un método de segmentación automático combinando índices de vegetación y agrupamiento difuso. La investigación se centró en el análisis de las texturas existentes en las imágenes captadas por los sistemas de visión en campos de maíz y cereales, lo cual se ha realizado desde dos puntos de vista: cromático y espacial.

El autor utiliza los siguientes índices de vegetación *ExG*, *ExGR*, *CIVE* y *VEG*. Así como los métodos de preprocesamiento como son la transformada wavelet y la umbralización *OTSU*, además de llevar a cabo la segmentación de las imágenes con el algoritmo de agrupamiento difuso.

Como resultado final concluye que al momento de combinar índices de vegetación cromática e incorporar información de textura espacial le funcionó adecuadamente. Además, con la Transformación Directa Wavelet (*WAV*) obtuvo el error promedio más bajo de 7.12%. Las imágenes utilizadas en este trabajo pertenecen a dos tipos de cultivos cereales y maíz. Las imágenes se almacenaron en el formato de 24 bits y en el espacio de color RGB, con resoluciones de 1152 x 864 píxeles.

“A forest structure habitat index based on airborne laser scanning data” (Coops et al. 2016)

Los autores realizaron un estudio basado en el uso de sistemas de precisión y exploración láser vía aérea para la biodiversidad, proponen un índice tridimensional que captura los tres componentes principales de la vegetación vertical y horizontal, los cuales son altura, cobertura y complejidad.

Se menciona que la precisión temática global del mapa, según lo estimado por el extenso conjunto de datos de validación, es del 75% con un máximo de once clases y del 88% si estas clases se agrupan en cinco clases generales. Además de realizar la cobertura del suelo, también utilizaron la estratificación de subregión natural, que separa geográficamente la provincia en seis áreas relativamente homogéneas basadas en patrones de paisaje, especialmente vegetación, suelos y características fisiográficas.

El desarrollo y la aplicación de sistemas altamente precisos de exploración láser en el aire (*ALS*), que son capaces de describir la distribución tridimensional de la vegetación, tienen un gran valor potencial para derivar relaciones cuantitativas entre las distribuciones de especies y la estructura del hábitat.

“Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV” (Torres-Sánchez et al. 2014)

Los autores utilizaron un dron equipado con una cámara comercial (espectro visible) para la adquisición de imágenes, de alta resolución, correspondientes a un campo de trigo en el periodo de edad temprana. Analizaron las imágenes mediante la evaluación de seis índices espectrales visibles (*CIVE*, *ExG*, *ExGR*, *Woebbecke Index*, *NGRDI*, *VEG*) y dos combinaciones de estos índices para el mapeo de fracción de vegetación.

Los autores utilizan el método *OTSU* para el mapeo de la vegetación en imágenes capturadas desde un dron. Obteniendo como resultados mapas georreferenciados de resolución espacial muy alta y detectando si existe maleza en los cultivos, así como enfermedades existentes en los mismos.

Al final, concluyen que entre los índices evaluados, los dos más exitosos fueron *ExG* y *VEG*, logrando la mejor precisión en el mapeo de fracción de vegetación, con valores que van del 87.73% al 91.99% a una altitud de 30 m de vuelo y del 83.74% al 87.82% a una altitud de vuelo de 60 m, siendo *ExG* el mejor para aplicaciones prácticas y agrícolas debido a su mayor simplicidad y precisión, lo que permite un mapeo preciso de la vegetación en todo el campo de trigo en cualquier fecha del año.

“An Automatic Object-Based Method for Optimal Thresholding in UAV Images: Application for Vegetation Detection in Herbaceous Crops” (Torres-Sánchez, López-Granados, and Peña 2015)

El objetivo de los autores es contar plantas para el monitoreo de la germinación o detectar malezas en sitios específicos correspondientes a los cultivos herbáceos (maíz, girasol y trigo). Mencionan que para alcanzar su objetivo fue de suma importancia hacer uso de imágenes de alta resolución obtenidas desde

un Vehículo Aéreo no Tripulado (*UAV*), así como la implementación del algoritmo que proponen llamado “Análisis de Imagen Basado en Objetos” (*OBIA*).

Establecen que el desarrollo del algoritmo *OBIA*, de umbral innovador, está basado en el método *OTSU* y estudia cómo los resultados de este algoritmo se ven afectados por los diferentes parámetros de segmentación (escala, forma y compacidad).

En la presentación de pruebas analizaron el rendimiento del algoritmo *OBIA* para clasificar la cobertura de vegetación afectada por distintos umbrales, seleccionados automáticamente mediante el cálculo en las imágenes de dos índices de vegetación: El Exceso de Verde (*ExG*) y el Índice de Vegetación de Diferencia Normalizada (*NDVI*). Las técnicas para medir la relevancia de las características fueron: Análisis de Componentes Principales (*PCA* por sus siglas en inglés) y diferentes variantes propuestas a partir de esta.

“Segmentación de Imágenes por Intensidad de Color Mediante Método Iterativo Basado en Superpíxeles y Fuzzy C-Means” (Cerón et al. 2016)

En este trabajo de investigación proponen un algoritmo para segmentar imágenes mediante la intensidad de color, por lo que utilizan el algoritmo basado en el método *Simple Linear Iterative Clustering SLIC* con el que realizaron una segmentación dura. Para una segmentación más profunda utilizaron el algoritmo de agrupamiento *fuzzy c-means*. Por lo que el algoritmo es recursivo y emplea un análisis estadístico de cada clúster.

En la etapa de preprocesamiento utilizan el espacio de color *CIELAB* para la transformación de color de las imágenes. Los autores determinan que el algoritmo propuesto en este trabajo permite segmentar imágenes por intensidad de color con una adherencia a bordes que es controlada mediante un umbral de segmentación.

Mencionan que el desempeño del algoritmo es recomendado para imágenes que poseen una baja dinámica de color como ocurre con imágenes médicas de color falso o en escala de grises. Para imágenes con dinámica alta se deben hacer las adecuaciones que el caso requiera.

“Local extrema co-occurrence pattern for color and texture image retrieval” (Verma et al. 2016)

En este trabajo de investigación los autores proponen un algoritmo para realizar la recuperación de imágenes por contenido considerando los descriptores de color y textura. En esta investigación aplican el espacio de color *HSV* para trabajar con el tono, la intensidad y el brillo de las imágenes; también utilizan el histograma y los patrones locales binarios para la obtención de un vector de características, manejado con el uso de la *matriz de co-ocurrencia* en base al nivel de gris. Para sus pruebas los autores utilizaron cinco bases de datos estándar llamadas *Corel*, *MIT*, *VisTex* y *STex*; además de las variaciones de la base de datos *Corel* llamadas *Corel-1k*, *Corel-5k* y *Corel-10k*.

Finalmente, los autores concluyen que el rendimiento del método depende de la distribución del color y la textura de las imágenes presentes en las bases de datos, debido a que en algunas obtienen resultados favorables y en otras no.

b) Descriptor de textura *Local Binary Pattern*

“Local Binary Pattern-Based Hyperspectral Image Classification With Superpixel Guidance” (Jia et al. 2018)

En este trabajo de investigación los autores proponen un método a nivel superpíxel basado en la técnica de *Local Binary Pattern* (*LBP*, en español Patrón Binario Local) que denominaron *ULBP-SPG*. Utilizaron el método para mejorar el rendimiento de clasificación en el espacio de color *HSI*. Trabajaron con el espacio de color *HSL*, para después segmentar muchas regiones homogéneas utilizando el método de segmentación considerando la tasa de entropía. Luego, aplican un proceso de fusión de regiones para hacer que los superpíxeles obtenidos sean más homogéneos. Extraen las características locales de la imagen para formular la descripción de probabilidad de cada píxel que pertenece a cada clase, y utilizan una máquina de soporte vectorial para realizar el proceso de clasificación.

Los resultados experimentales muestran consistentemente que el *ULBP-SPG* exhibe un mejor rendimiento. Por lo que el método propuesto puede ser bastante ventajoso con la incorporación del nivel superpíxel basada en la fusión de regiones. Mencionan que, la resolución espacial de *HSL* se ha vuelto mucho más alta con el progreso de la tecnología de sensor hiper-espectral, esto quiere decir que se emplea ampliamente para medir la sanidad vegetal y calcular el índice de vegetación.

“Local Neighborhood Intensity Pattern – A new texture feature descriptor for image retrieval” (Banerjee et al. 2018)

Se propone un descriptor de textura basado en la diferencia de intensidad de vecindad local, para la recuperación de imágenes basadas en contenido. Los autores utilizan el espacio de color *HSV* en la etapa de preprocesamiento. Para realizar sus pruebas utilizan las bases de datos *Brodatz* y *VisTex* de *MIT*.

Los valores de precisión y recuperación observados en estas bases de datos los compararon con algunos patrones locales (vecinos), debido a que contienen una cantidad significativa de información de textura que puede considerarse para una representación de textura eficiente. Finalmente, concluyen que el método propuesto mostró una mejora significativa sobre muchos otros métodos existentes.

“LBP Histogram Selection based on Sparse Representation for Color Texture Classification” (Hoang et al. 2017)

En esta investigación los autores proponen un método de selección a través del histograma basado en la distancia de Jeffrey y la matriz de similitud dispersa. Para llevar a cabo sus pruebas utilizan diferentes espacios de color tales como: *HSV*, *RGB*, *HLS*, *ISH*, *Lab*, *XYZ*, *YUV*. La selección del histograma propuesto, que integra intensidades suaves en los píxeles de una imagen, mejora los resultados de la clasificación por textura y color. Al final los autores muestran que el método propuesto mejora el rendimiento de la clasificación, mostrando en la evaluación altos valores en la tasa de precisión y en la velocidad de recuperación.

Tabla 2.1 Artículos referentes a la segmentación de imágenes.

Artículo	Objetivo	Técnicas o áreas	Resultados o conclusiones	Comentarios
“Comparativa del coste computacional del algoritmo de segmentación OTSU en imágenes satelitales utilizando estrategias de paralelización con CUDA” (Icaya et al. 2018).	Realizar una optimización al algoritmo <i>OTSU</i> para la segmentación de imágenes satelitales utilizando las estrategias de paralelización mediante la plataforma <i>CUDA</i> .	Método de umbralización <i>OTSU</i> . Cálculo del histograma. Plataforma <i>CUDA</i> .	En base a los resultados, pudieron determinar que la versión paralela del algoritmo <i>OTSU</i> , es 4.66 veces más rápido en el peor de los casos y hasta 25.26 veces más rápido en el mejor de los casos con respecto a la versión secuencial.	Áreas de investigación relacionados al tema de tesis. A medida que el tamaño de la imagen se incrementa, aumentará el tiempo requerido para el cálculo del histograma y el cálculo de la imagen de salida. Los factores que afectan en mayor medida la velocidad del algoritmo paralelizado son: el tamaño de la imagen y el número de umbrales.
“Local Binary Pattern-Based Hyperspectral Image Classification With Superpixel Guidance” (Jia et al. 2018).	Proponen un método a nivel superpíxel basado en <i>Local Binary Pattern (LBP)</i> , métodos que fusionan para mejorar el rendimiento de clasificación del espacio de color <i>HSL</i> .	Algoritmo para extracción de características <i>Local Binary Pattern (LBP)</i> . Espacio de color <i>HSL</i> . Análisis del Componente Principal (<i>PCA</i>).	Los resultados experimentales muestran consistentemente que el <i>ULBP-SPG</i> exhibe un mejor rendimiento. Por lo que el método propuesto <i>ULBP-SPG</i> puede ser bastante ventajoso con la incorporación del nivel superpíxel basada en la fusión de regiones.	Áreas de investigación relacionados al tema de tesis. Mencionan que, la resolución espacial de <i>HSL</i> se ha vuelto mucho más alta con el progreso de la tecnología de sensor hiper-espectral Base de datos: Indian Pines.
“Segmentación Automática de Texturas en Imágenes Agrícolas” (Riomoros, 2016).	Riomoros propone un método de segmentación automática combinando índices de vegetación y agrupamiento difuso.	Índices de vegetación <i>ExG</i> , <i>ExGR</i> , <i>CIVE</i> y <i>VEG</i> . Agrupamiento Difuso. Umbralización mediante <i>Otsu</i> . Transformada <i>Wavelet</i> .	Como resultado final concluye que el combinar índices de vegetación cromática e incorporar información de textura espacial le funcionó adecuadamente. Además, con la Transformación Directa <i>Wavelet (WAV)</i> obtuvo el error promedio más bajo de 7.12%.	Técnicas para la segmentación de imágenes relacionadas con el tema de tesis. Las imágenes utilizadas en este trabajo pertenecen a dos tipos de cultivos cereales y maíz. Las imágenes se almacenaron en el formato de 24 bits y en el espacio de color <i>RGB</i> , con resoluciones de 1152 x 864 píxeles. Base de Datos: Propia

Segmentación de Árboles de Higos en Imágenes Aéreas, mediante Visión Artificial.

Continuación de tabla 2.1 Artículos de Segmentación de Imágenes.				
Artículo	Objetivo	Técnicas o áreas	Resultados o conclusiones	Comentarios
<p>“Automatic computing of number of clusters for color image segmentation employing fuzzy c-means by extracting chromaticity features of colors” (García et al. 2018).</p>	<p>Proponen un método para la segmentación de imágenes a color, tratando de emular la percepción humana.</p>	<p>Algoritmo <i>Fuzzy C-Means</i>.</p> <p>Red Neuronal no Supervisada.</p>	<p>La capacitación de redes neuronales que proponen se realiza sólo una vez y, luego se puede usar en cualquier imagen dada sin entrenarla de nuevo.</p> <p>De acuerdo con su evaluación cuantitativa y el promedio de las neuronas más activadas, el mejor rendimiento se obtiene utilizando un mapa auto-organizado de 4x4 neuronas.</p>	<p>Áreas de investigación relacionados al tema de tesis</p> <p>Los autores determinan que su propuesta es hasta cierto punto robusta a la iluminación no uniforme.</p> <p>Base de Datos: <i>Berkeley (BSD-300)</i></p>
<p>“Segmentation of images by color features: A survey” (García et al. 2018).</p>	<p>En este estudio los autores presentan diferentes trabajos que abordan la parte de segmentación de imágenes por características de color.</p>	<p>Espacios de color <i>HSV, HSI, CieLab, YCrBr</i>.</p> <p>Algoritmo <i>Fuzzy C-Means</i>.</p> <p>Redes Neuronales Artificiales.</p>	<p>Mencionan que los métodos generalmente empleados para la segmentación de la imagen en color son los algoritmos <i>fuzzy c-means</i> y los mapas de auto-organización, debido a la fácil implementación, la baja complejidad computacional y los resultados competitivos obtenidos.</p>	<p>Áreas de investigación relacionados al tema de tesis</p> <p>Por lo general, las redes neuronales se entrenan con los colores de la imagen para procesar, luego, la imagen se segmenta mediante la red neuronal entrenada.</p>
<p>“Segmentación de Imágenes por Intensidad de Color Mediante Método Iterativo Basado en Superpíxeles y Fuzzy C-Means” (Cerón et al. 2016).</p>	<p>Proponen un algoritmo de segmentación de imágenes mediante la intensidad de color que se basa en el método <i>Simple Linear Iterative Clustering (SLIC)</i>.</p>	<p><i>Espacio de color CIELAB</i>.</p> <p>Algoritmo <i>Fuzzy C-Means</i>.</p>	<p>Los autores concluyen que el algoritmo propuesto en este trabajo permite segmentar imágenes por intensidad de color con una adherencia a bordes que es controlada mediante un umbral de segmentación.</p>	<p>Áreas de investigación relacionados al tema de tesis.</p> <p>Mencionan que el desempeño del algoritmo es recomendado para imágenes que poseen una baja dinámica de color como ocurre con imágenes médicas de color falso o en escala de grises. Para imágenes con dinámica alta se deben hacer las adecuaciones que el caso requiera.</p>

Tabla 2.2 *Descriptor de textura Patrones Locales Binarios (LBP).*

Artículo	Objetivo	Técnicas o áreas	Resultados o conclusiones	Comentarios
“Local extrema co-occurrence pattern for color and texture image retrieval” (Verma et al. 2016).	Proponen un método para la recuperación de imágenes por contenido (textura).	Espacio de color <i>HSV</i> . Cálculo del histograma.	Finalmente, los autores concluyen que el rendimiento del método depende de la distribución del color y la textura de las imágenes presentes en las bases de datos, debido a que en algunas obtienen resultados favorables y en otras no.	Áreas de investigación relacionados al tema de tesis. Los métodos son el color y la textura, los compararon con el método propuesto y calcularon la recuperación y precisión, que son medidas de evaluación. Base de Datos: <i>Corel</i> y <i>MIT VisTex</i> .
“Color local binary patterns: compact descriptors for texture classification” (Ledoux et al. 2016).	En este trabajo se propone la extensión del método Patrones Locales Binarios (<i>LBP</i>), para la descripción de textura en imágenes a color.	Bases de datos Outex_TC_00013,43 Barktex, 46 y USPTex15. Espacio de color <i>CIELab</i> y <i>HSV</i> .	Mencionan que <i>LBP</i> con color, requiere la definición de un orden de colores para comparar los colores de los píxeles vecinos. Finalmente, concluyen que <i>MCOLBP</i> mejora la precisión de la clasificación respecto a <i>LBP</i> .	Áreas de investigación relacionados al tema de tesis. Confirman que la cromaticidad es de poco interés en comparación con la luminancia de un color para la clasificación de textura con <i>LBP</i> .
“Local Neighborhood Intensity Pattern – A new texture feature descriptor for image retrieval” (Banerjee et al. 2018).	Se propone un descriptor de textura basado en la diferencia de intensidad de vecindad local, para la recuperación de imágenes basadas en su contenido.	Espacio de color <i>HSV</i> .	Los autores concluyen que el método propuesto mostró una mejora significativa sobre muchos otros métodos existentes.	Áreas de investigación relacionados al tema de tesis. Base de datos: <i>Brodatz</i> , y <i>VisTex</i> de <i>MIT</i> . Los valores de precisión y recuperación observados en estas bases de datos los compararon con algunos patrones locales (píxeles vecinos).
“LBP Histogram Selection based on Sparse Representation for Color Texture Classification” (Hoang et al, 2017).	Proponen un método de selección a través del histograma basado en la distancia de Jeffrey y la matriz de similitud dispersa.	Espacios de color <i>HSV</i> , <i>RGB</i> , <i>HLS</i> , <i>ISH</i> , <i>Lab</i> , <i>XYZ</i> , <i>YUV</i> .	Los autores muestran que el método propuesto mejora el rendimiento de la clasificación de la textura del color representada en diferentes espacios de color, mostrando en la evaluación la tasa de precisión y la velocidad de recuperación.	Áreas de investigación relacionados al tema de tesis. La selección del histograma propuesto que integra intensidades suaves en los píxeles de una imagen, mejora los resultados de la clasificación por textura de color.

2.4 Comentarios

El análisis de los trabajos realizados en el CENIDET y en el estado del arte respecto a la segmentación de imágenes a color y extracción de características, permitió conocer e introducir al tema de investigación que se desarrolló, debido a que se pudo observar y analizar cuáles son los métodos que se han utilizado en las diferentes investigaciones, de manera local y en diferentes partes del mundo y, de esta manera proponer una solución para este tema de investigación y desarrollar el sistema de visión artificial para la segmentación de árboles de higos, en imágenes aéreas.

Capítulo 3 . Metodología de solución y marco teórico

3.1 Introducción

En este capítulo se describe, de forma teórica, la metodología que se empleó para solucionar el problema de segmentación de árboles de higos en imágenes aéreas, mediante visión artificial. Para ello, se tomó como base la arquitectura general de un sistema de visión artificial propuesto por (*Gonzalez & Woods, 2002*), el cual se puede observar en la figura 3.1.

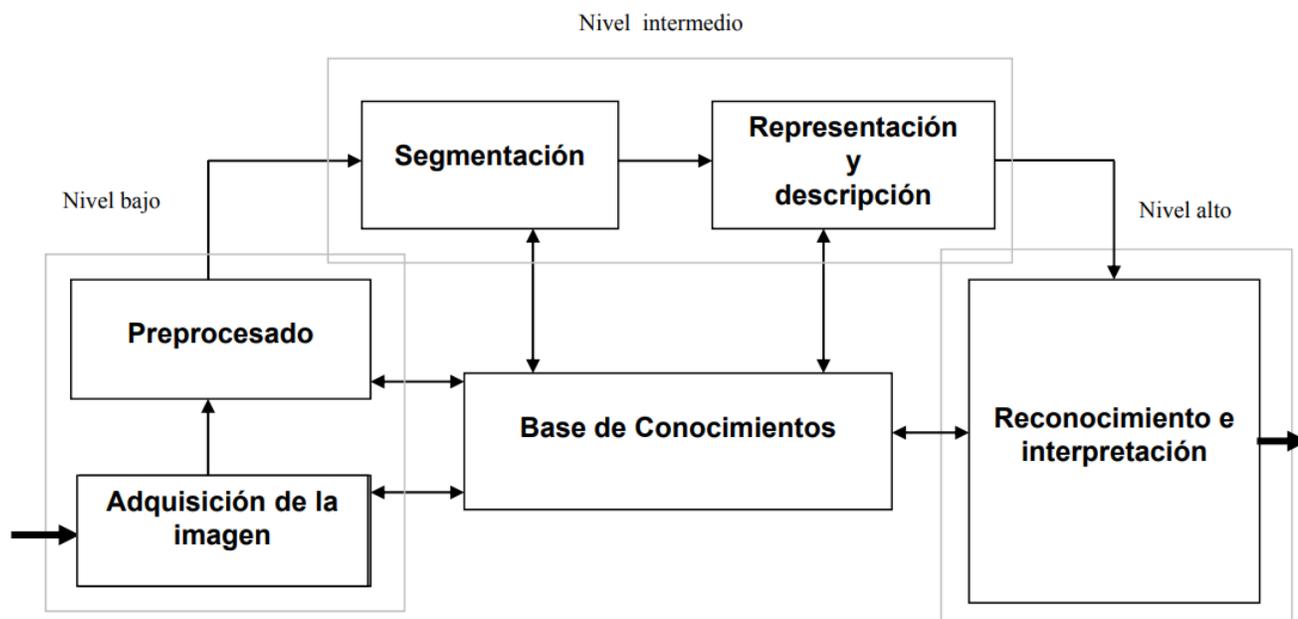


Figura 3.1 Esquema de Visión Artificial (dato por *Gonzalez & Woods, 2002*).

En el capítulo se incluye la parte teórica de las técnicas utilizadas, tales como la transformación de color *RGB* a *HSV*, el algoritmo de agrupamiento *fuzzy c-means*, para la extracción de características se aplicaron descriptores de textura *Local Binary Patterns (LBP)*, filtros de *Gabor* y medidas de *Haralick* y para el reconocimiento se aplicó el algoritmo Máquinas de Soporte Vectorial (*MVS*) que es un algoritmo utilizado para el aprendizaje automático supervisado.

3.2 Metodología de solución

La figura 3.2 muestra de manera visual la metodología de solución que se llevó a cabo para segmentar las zonas de árboles de higos en las imágenes aéreas que fueron proporcionadas por la Universidad Autónoma del Estado de Morelos, a través del desarrollo de un sistema de visión artificial. En el esquema se pueden observar las técnicas empleadas en cada una de las etapas que conforman este proyecto de tesis.

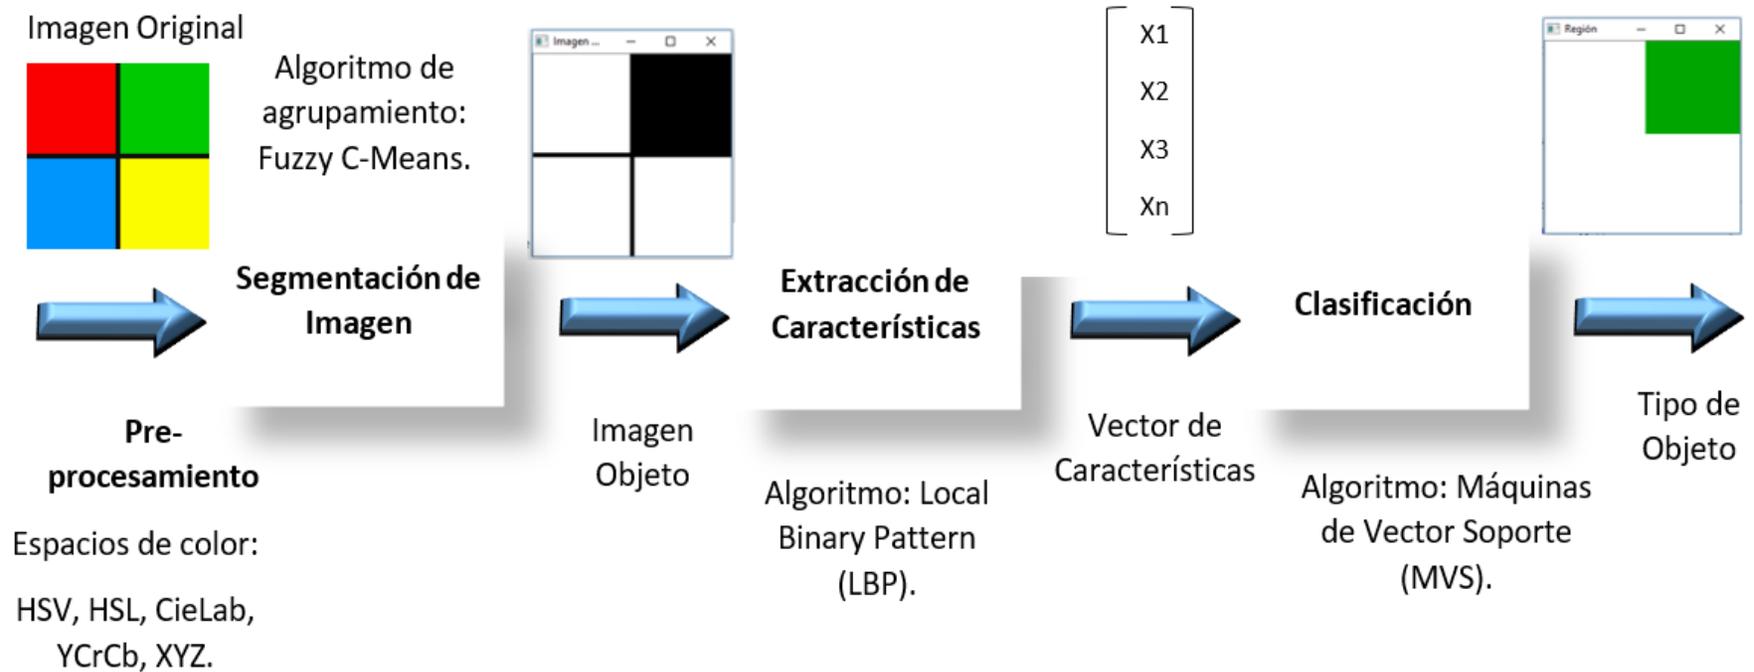


Figura 3.2 Esquema de la metodología de solución para la segmentación de imágenes aéreas correspondientes a plantaciones de árboles de higos.

3.3 Marco teórico

Las técnicas se presentarán de acuerdo a su aparición en la figura 3.2

3.3.1 Preprocesamiento con el modelo de color *HSV*

El objetivo de la etapa de procesamiento es la de mejorar las condiciones iniciales de la imagen, de tal forma que los procesos posteriores obtengan un resultado satisfactorio. Para este trabajo, el procesamiento consistió en transformar la imagen a otro modelo de color, de tal forma que en este nuevo espacio se pasaran como fondo a todos los píxeles con un tono diferente al verde, además, de tratar de eliminar o reducir la influencia de la intensidad luminosa.

La visión del color se puede procesar utilizando el espacio de color *RGB* o el espacio de color *HSV*. El espacio de color *RGB* describe los colores en términos de la cantidad de rojo, verde y azul presentes en la imagen. El espacio de color *HSV* describe los colores en términos de Tono, Saturación y Valor. En situaciones donde la descripción del color juega un papel integral, el modelo de color *HSV* a menudo se prefiere al modelo *RGB*.

HSV (*Hue*, *Saturation*, *Value*) es un espacio de color implementado con frecuencia para la segmentación de imágenes en color. Al manipular este espacio de color se puede lograr la eficiencia de organizar cualquier imagen en color, de la misma manera en que los ojos del ser humano lo pueden percibir.

El espacio de color *HSV* se muestra tradicionalmente como una pirámide invertida, como se observa en la figura 3.3. La pirámide tiene seis caras, donde el eje vertical representa el valor de *V* (valor), la distancia horizontal desde el eje el valor de *S* (saturación) y el ángulo el valor de *H* (tono). El espacio de *HSV* tiene dos características importantes.

1. El componente de intensidad, el valor, está desacoplado de los datos de matiz.
2. Los componentes de matiz y saturación emulan la percepción humana del color.

Con estas características, el espacio *HSV* se convierte en una herramienta útil para desarrollar algoritmos de procesamiento de imágenes basados en algunas propiedades de la percepción del color humano (*García-Lamont et al. 2018*).

El tono está en el rango $[0, 2\pi] \subset \mathbb{R}$; la saturación está en el rango real $[0, 1]$, mientras que el valor está a menudo en el rango $[0, 255]$. El espacio *HSV* tiene forma de cono, como se muestra en la figura 3.3. Geométricamente, el radio y la altura del cono representan los componentes de saturación y valor, respectivamente. Se toma en cuenta que, para los colores, negro, blanco y gris, el parámetro de tono no está definido, debido a que estos colores se consideran como singularidades dentro de este espacio de color; porque no tienen una cromaticidad específica (*García-Lamont et al. 2018*).

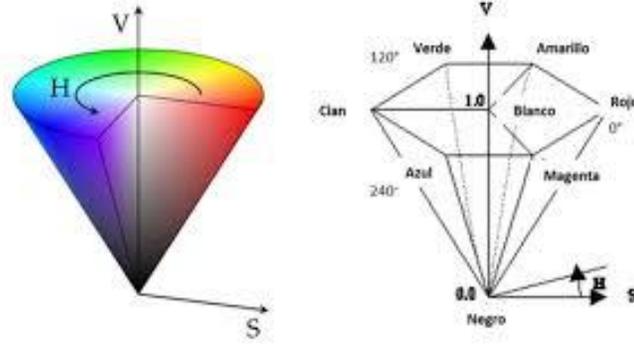


Figura 3.3 Representación gráfica del espacio de color HSV (*García-Lamont et al. 2018*).

La asignación de un color *RGB* al espacio *HSV* implica las siguientes operaciones. Sea $\phi = [r, g, b]$ el vector de color *RGB*, y $\varphi = [h, s, v]$ el vector resultante al mapear ϕ con el espacio *HSV*. El tono, la saturación y el valor se calculan utilizando las siguientes expresiones (*García-Lamont et al. 2018*):

$$\theta = \begin{cases} \cos^{-1}\left(\frac{(r-g) + (r-b)}{\sqrt{(r-g)^2 + (r-b)(g-b)}}\right), & r=g=b \\ \text{otherwise} \end{cases} \quad (3.1)$$

$$h = \begin{cases} \theta, & b \leq g \\ 2\pi - \theta, & b > g \end{cases} \quad (3.2)$$

$$s = \begin{cases} 0, & \max(r,g,b)=0 \\ 1 - \frac{\min(r,g,b)}{\max(r,g,b)}, & \text{otherwise} \end{cases} \quad (3.3)$$

$$v = \max(r, g, b) \quad (3.4)$$

En el capítulo de experimentación y resultados, se pueden observar algunos de los resultados obtenidos al aplicar la transformación de color *HSV* a la imagen original. La banda *H* fue de gran utilidad para realizar la binarización de la imagen, primer proceso para obtener la segmentación requerida.

3.3.2 Algoritmo de agrupamiento *Fuzzy c-means*

La segmentación de una imagen puede considerarse como el proceso de fusión de píxeles de imágenes similares en sus grupos o regiones. La imagen segmentada es entonces la unión de grupos distintos, donde los píxeles de regiones homogéneas se asocian a los mismos grupos. Numerosas técnicas han sido

propuestas, donde las características de color, textura o bordes se utilizan para describir cada grupo (*García-Lamont et al. 2018*).

Para la etapa de segmentación se estudió e implementó el algoritmo de agrupamiento *fuzzy c-means* para realizar la segmentación de imágenes aéreas. La aplicación del algoritmo se realizó sobre las imágenes que se obtuvieron del preprocesamiento, etapa en la que se trabajó con el espacio de color *HSV*, en especial con la banda *H*, que fue la que otorgó mejores resultados en cuanto a la obtención de color. En este caso, el color que más prevalecía era el verde por el contenido de las imágenes a segmentar. Es por ello que esta investigación se centró en el enfoque de agrupamiento.

El agrupamiento es el proceso de organizar o estructurar una colección de objetos en grupos o clústeres de forma tal que exista una semejanza relativamente alta (o mínima distancia) entre los objetos del mismo grupo en contraposición con la existente entre objetos de grupos diferentes (*Bustince et al. 2016*).

El agrupamiento difuso pertenece a una clase de algoritmos de agrupamiento donde cada elemento tiene un grado de pertenencia difuso a los grupos que se forman y se describe por,

$$J_m = \sum_{i=1}^D \sum_{j=1}^N \mu_{ij}^m \|X_i - C_j\|_2^2 \quad (3.5)$$

Donde D es el número de datos, N es el número de grupos, X_i es el i -ésimo dato, C_j es el j -ésimo agrupamiento, μ_{ij} es el grado de pertenencia y m es el exponente difuso para controlar el grado de traslape difuso con $m > 1$. El algoritmo funciona de la siguiente manera:

1. Se toma la imagen de entrada preprocesada
2. Se inicializan de manera aleatoria los valores de pertenencia de los agrupamientos μ_{ij} ,
3. Se calculan los centros de cada agrupamiento mediante la siguiente expresión,

$$C_j = \frac{\sum_{i=1}^D \mu_{ij}^m X_i}{\sum_{i=1}^D \mu_{ij}^m} \quad (3.6)$$

4. Posteriormente actualizar μ_{ij} de acuerdo con la expresión,

$$\mu_{ij} = \frac{1}{\sum_{k=1}^N \left(\left\| \frac{X_i - C_j}{X_i - C_k} \right\| \right)^{\frac{2}{m-1}}} \quad (3.7)$$

5. Calcular la función objetiva J_m ,

6. Repetir pasos 2-4 hasta que J_m se aproxime a un valor umbral mínimo que es 0.005 especificado o un máximo número de iteraciones (1000) especificado.

Este tipo de algoritmos surge de la necesidad de resolver una deficiencia del agrupamiento exclusivo, que considera que cada elemento se puede agrupar inequívocamente con los elementos de su clúster y que, por lo tanto, no se asemeja al resto de los elementos.

Fuzzy C-Means o *C-Means Difuso* es uno de los algoritmos para realizar el agrupamiento de partición difusa más difundido. Se utiliza en múltiples ámbitos que van desde las ciencias sociales hasta la ingeniería pasando por la ciencia básica. Su uso es muy habitual en el reconocimiento de patrones, la segmentación de imágenes, agrupamiento de imágenes y Big Data (*García-Lamont et al. 2018*).

3.3.3 Representación y descripción

Como ya se ha mencionado en la introducción de este tema de investigación, el objetivo principal es realizar la localización exacta de las zonas de árboles en imágenes aéreas correspondientes a plantaciones de higos. Sin embargo, al momento de observar los resultados obtenidos de la etapa de segmentación, se pudo observar que se tienen problemas con aquellas imágenes cuyo contenido incluía hierba, pasto u otro tipo de árbol ajeno al de interés y también con las que tienen versatilidad en cuanto la intensidad luminosa.

Por esta razón, se decidió realizar una segmentación a detalle de estas zonas, y para ello se hizo una revisión en la literatura sobre descriptores de textura y color. Para poder reconocer los objetos es necesario describirlos de alguna manera; para posteriormente utilizar dicha descripción para su reconocimiento.

En este apartado se muestra el estudio que se realizó sobre los descriptores de color y textura, los cuales son: *Local Binary Patterns (LBP)* en español patrones locales binarios, filtros *Gabor* y las medidas de *Haralick*. Estos descriptores fueron los que se emplearon para realizar la extracción de características en el presente trabajo, debido a que la textura y color son características importantes para el análisis de las imágenes con vegetación.

3.3.3.1 Descriptor Local Binary Patterns (LBP)

Los patrones binarios locales (*LBP*) son un descriptor de texturas popularizado por el trabajo de (*Ojala et al.2002*), *Multiresolution Grayscale and Rotation Invariant Texture Classification* con patrones binarios locales (aunque el concepto de *LBP* se introdujo desde 1993).

A diferencia de las características de textura de *Haralick* que calculan una representación global de la textura basada en la matriz de Co-ocurrencia del nivel de gris, las *LBP* calculan una representación local de la textura. Esta representación local se construye comparando cada píxel con su vecindario circundante de píxeles (*Li W. et al. 2015*).

Los patrones binarios locales se encuentran entre los descriptores de textura recientes. El primer paso para construir el descriptor de textura *LBP* es convertir la imagen a escala de grises ver figura 3.4 (*Gia et*

al. 2018). Para cada píxel en la imagen en escala de grises, se selecciona un vecindario de tamaño r que rodea el píxel central. Luego se calcula un valor LBP para este píxel central y se almacena en la matriz 2D de salida con el mismo ancho y alto que la imagen de entrada.

Cada píxel central se compara con sus ocho vecinos; los vecinos que tengan un valor menor que el del píxel central, se le asigna el bit 0, y los demás vecinos que tengan un valor igual o mayor que el píxel central tendrán el bit 1 (Dornaika et al. 2017).

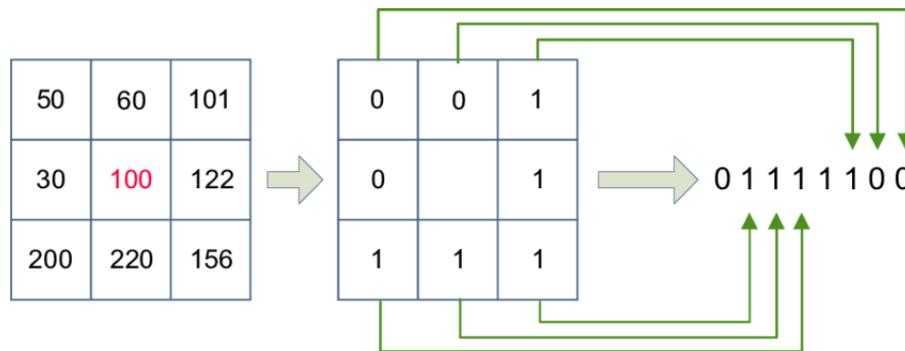


Figura 3.4 El primer paso para construir una LBP es tomar el vecindario de 8 píxeles que rodea un píxel central y establecer un umbral para construir un conjunto de 8 dígitos binarios (Li w. et al. 2015).

A partir de ahí, se debe calcular el valor LBP para el píxel central. Se puede comenzar desde cualquier píxel vecino y avanzar en el sentido de las agujas del reloj o en el sentido contrario, pero el orden debe mantenerse constante para todos los píxeles de la imagen y todas las imágenes en el conjunto de datos. Dado un vecindario de 3×3 , se obtienen 8 vecinos con los que se debe de realizar una prueba binaria. Los resultados de esta prueba binaria se almacenan en una matriz de 8 bits, que luego se convierte a decimal (Jia et al. 2018).

Este proceso de creación de umbrales, acumulación de cadenas binarias y almacenamiento del valor decimal de salida en la matriz LBP se repite para cada píxel en la imagen de entrada. Este es un ejemplo, figura 3.5, de cómo calcular y visualizar una matriz 2D LBP completa:



Figura 3.5 Ejemplo del cálculo de la representación LBP (derecha), imagen de entrada original (izquierda) (Rosebrock A. 2015).

El último paso es calcular un histograma sobre la matriz de salida *LBP*. Con una vecindad de 3×3 que tiene $2^8 = 256$ patrones posibles, por lo que la matriz *LBP 2D* tiene un valor *mínimo de 0* y un valor *máximo de 255*, esto permite construir un histograma de 256 bandejas de códigos *LBP* como el vector de características y a partir de ahí trabajar la clasificación de la información, ver figura 3.6:

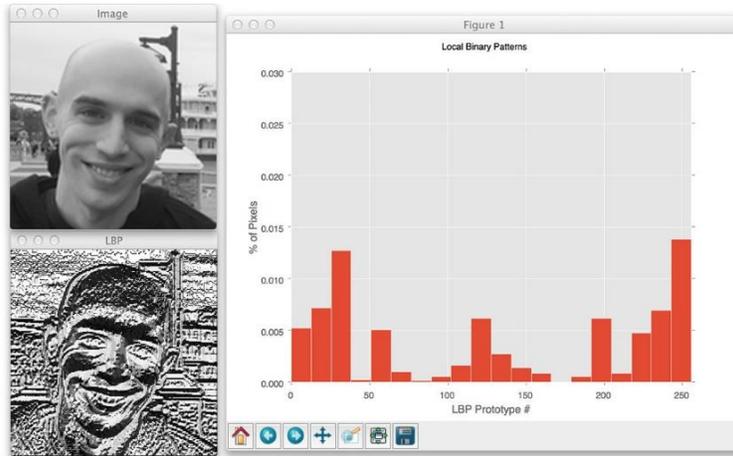


Figura 3.6 Finalmente, se calcula un histograma que tabula el número de veces que ocurre cada patrón *LBP*. Los valores del histograma resultan ser el vector de características (Rosebrock A. 2015).

Un beneficio principal de esta implementación original de *LBP* es que se pueden capturar detalles extremadamente finos en la imagen. Sin embargo, ser capaz de capturar detalles a una escala tan pequeña también es el mayor inconveniente del algoritmo: no se puede capturar detalles en escalas variables, sólo en la escala fija de 3×3 (Hoang et al. 2017).

En el apartado de experimentación se muestran los resultados obtenidos al trabajar con el descriptor *LBP*.

3.3.3.2 Descriptor filtros de Gabor

El filtro de *Gabor*, que lleva el nombre de Dennis Gabor, es un filtro lineal que se utiliza en miles de aplicaciones de procesamiento de imágenes para la detección de bordes, análisis de texturas, extracción de características, etc. Se ha demostrado que estos filtros poseen propiedades de localización óptimas tanto en el dominio espacial como en el de frecuencia y, por lo tanto, son adecuados para problemas de descripción de texturas.

Los filtros de *Gabor* son una clase especial de filtros de paso de banda, es decir, permiten una cierta "banda" de frecuencias y rechazan las otras. Un filtro *Gabor* puede verse como una señal sinusoidal de frecuencia y orientación particular, modulada por una onda gaussiana (Rafael & Oliveros, 2015).

En la práctica, para analizar la textura u obtener una característica de la imagen, se utiliza un filtro de banco de *Gabor* con varias orientaciones diferentes. Por ejemplo, si se tiene una imagen de entrada con

un patrón o varios y existe una orientación diferente entre ellos, para resaltar o extraer todos esos patrones, se pueden utilizar un banco de 16 filtros *Gabor* con una orientación de 11.250 (es decir, si el primer filtro está en 00, el segundo estará en 11.250, el tercero estará en 22.50, el cuarto estará en 33.750, el quinto estará en 45.00, el sexto estará en 56.250, el séptimo estará en 67.500, el octavo estará en 78.750, el noveno estará en 90.00, el décimo estará en 101.250, el onceavo estará en 112.500, el doceavo estará en 123.750, el treceavo estará en 135.00, el catorceavo estará en 146.250, el quinceavo estará en 157.500, el dieciseisavo estará en 168.750). La figura 3.7 muestra todo el banco de filtros de 16 filtros (*Rafael & Oliveros, 2015*).

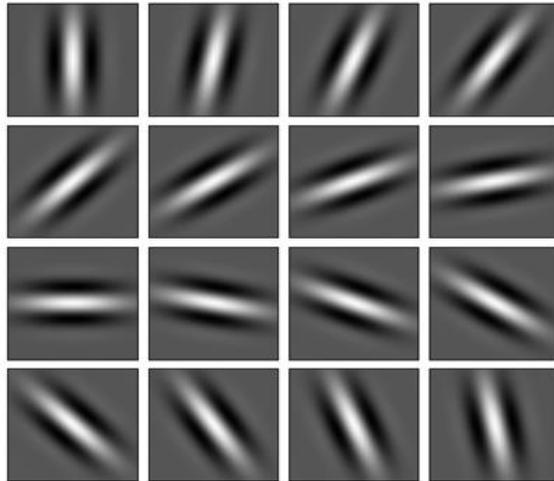


Figura 3.7 Banco de 16 filtros de Gabor orientados en diferentes ángulos (*Rafael & Oliveros, 2015*).

Cuando la imagen de entrada se combina con todos los filtros de *Gabor*, los patrones se resaltan fácilmente como se muestra en la figura 3.8. Cuando se aplica un filtro de *Gabor* a una imagen, se obtiene la mayor respuesta en los bordes y en los puntos donde cambia la textura. Cuando un filtro responde a una característica particular, se puede decir que el filtro tiene un valor distintivo en la ubicación espacial de esa característica.



Figura 3.8 (a) izquierda La imagen de entrada de Lenna y (b) derecha la imagen de salida después de pasarla a través del banco de filtros de Gabor (*Rafael & Oliveros, 2015*).

3.3.3.2.1 Diferentes parámetros que controlan la forma y el tamaño del filtro 2D de Gabor

Hay ciertos parámetros que controlan cómo será el banco de filtros de *Gabor* y a qué características responderá. Un filtro de *Gabor* 2D puede verse como una señal sinusoidal de frecuencia y orientación particulares, modulada por una onda gaussiana. El filtro tiene un componente real e imaginario que representa direcciones ortogonales. Los dos componentes pueden formarse en un número complejo o usarse individualmente. Las ecuaciones se muestran a continuación (*Rafael & Oliveros, 2015*):

Complex:

$$g(x, y; \lambda, \theta, \psi, \sigma, \gamma) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \exp\left(i\left(2\pi\frac{x'}{\lambda} + \psi\right)\right) \quad (3.8)$$

Real:

$$g(x, y; \lambda, \theta, \psi, \sigma, \gamma) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \cos\left(i\left(2\pi\frac{x'}{\lambda} + \psi\right)\right) \quad (3.9)$$

Imaginary:

$$g(x, y; \lambda, \theta, \psi, \sigma, \gamma) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \sin\left(i\left(2\pi\frac{x'}{\lambda} + \psi\right)\right) \quad (3.10)$$

Donde

$$x' = x \cos\theta + y \sin\theta$$

Y

$$y' = -x \sin\theta + y \cos\theta$$

En las expresiones anteriores:

λ - Longitud de onda de la componente sinusoidal.

Θ - La orientación de la normal a las franjas paralelas de la función de Gabor.

Ψ - El desplazamiento de fase de la función sinusoidal.

σ - La desviación sigma / estándar de la envoltura gaussiana

γ - La relación de aspecto espacial específica la elipticidad del soporte de la función de *Gabor*.

Los cinco parámetros mencionados anteriormente controlan la forma y el tamaño de la función de *Gabor*. La función de cada parámetro se explica en detalle a continuación.

***Lambda* (λ):**

La longitud de onda gobierna el ancho de las tiras de la función de *Gabor*, figura 3.9. Aumentar la longitud de onda produce franjas más gruesas y disminuir la longitud de onda produce franjas más finas. Manteniendo otros parámetros sin cambios y cambiando la lambda a 60 y 100, las rayas se vuelven más gruesas (*Tadic et al. 2016*).

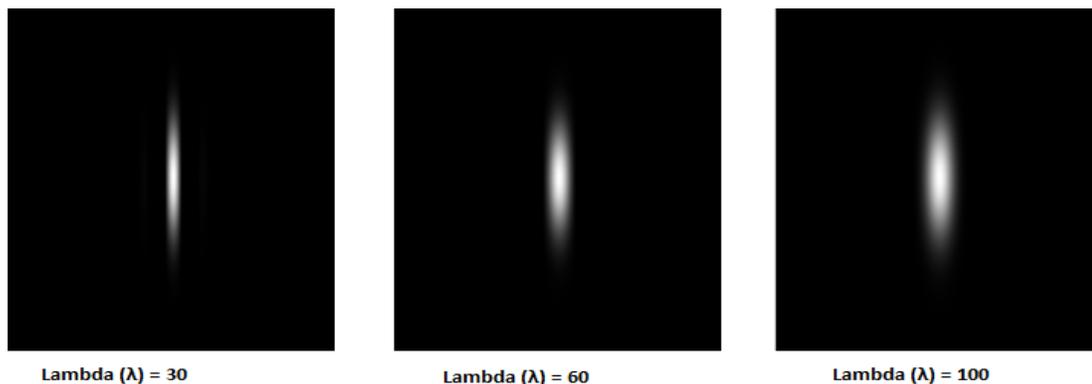


Figura 3.9 Representación gráfica del parámetro Lambda con tres diferentes valores (*Tadic et al. 2016*).

***Theta* (Θ):**

Theta controla la orientación de la función de *Gabor*, figura 3.10. El grado cero de *theta* corresponde a la posición vertical de la función de *Gabor*.

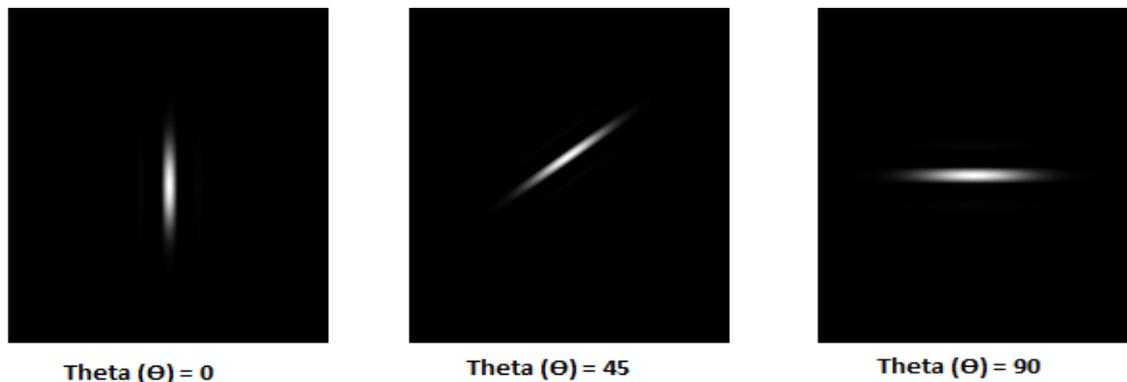


Figura 3.10 Representación gráfica de *Tetha* con diferentes valores en cuanto al ángulo de orientación (*Tadic et al. 2016*).

Gamma (γ):

La relación de aspecto o gamma controla la altura de la función de *Gabor*, se puede observar en la figura 3.11. Para una relación de aspecto muy alta, la altura se vuelve muy pequeña y para un valor gamma muy pequeño la altura se vuelve bastante grande. Al aumentar el valor de gamma a 0.5 y 0.75, manteniendo otros parámetros sin cambios, la altura de la función de *Gabor* se reduce.

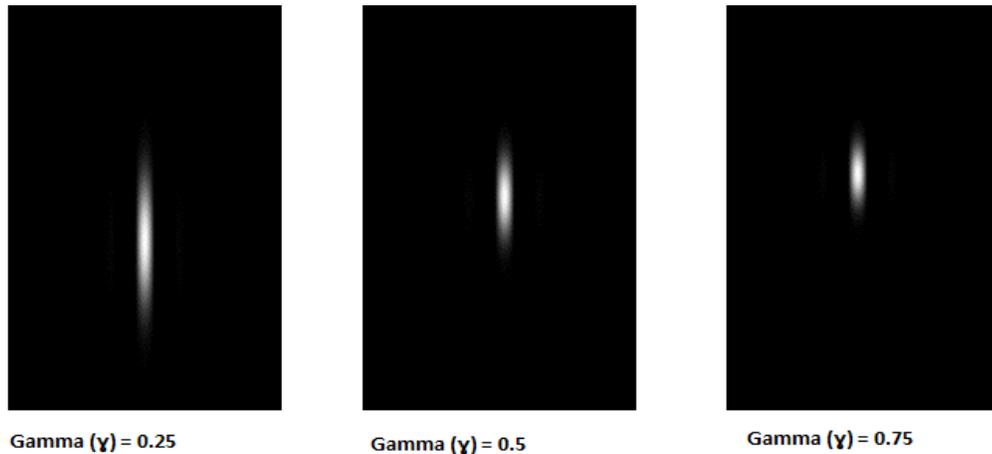


Figura 3.11 Representación gráfica de Gamma que controla la altura de la función de Gabor (*Tadic et al. 2016*).

Sigma (σ):

El ancho de banda o sigma controla el tamaño total de la envoltura de *Gabor*, ver figura 3.12. Para un ancho de banda mayor, el aumento de envolvente permite más franjas y con un ancho de banda pequeño, el sobre se tensa. Al aumentar *sigma* a 30 y 45, aumenta el número de bandas en la función de *Gabor*.

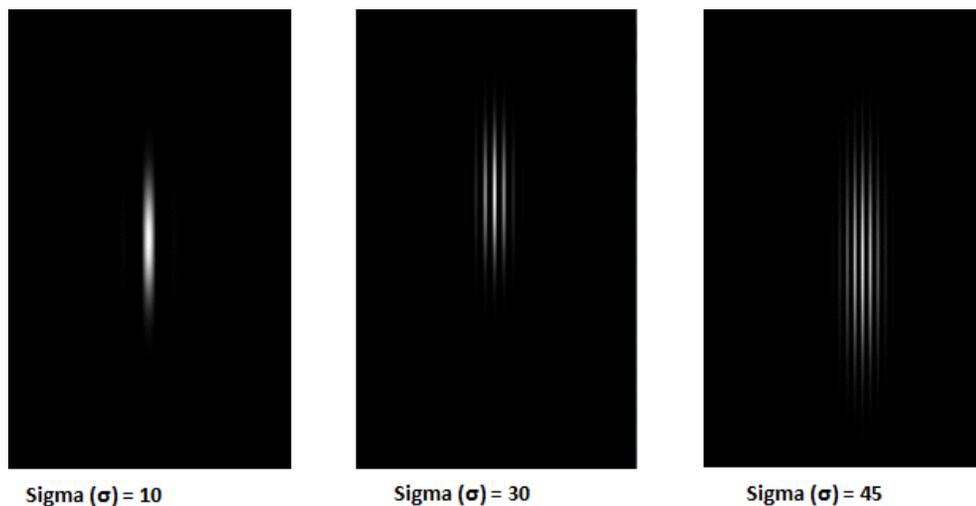


Figura 3.12 Representación gráfica de sigma que controla el tamaño total de la envoltura de Gabor (*Tadic et al. 2016*).

Psi (Ψ):

Es el desplazamiento de fase de la función sinusoidal.

En base a la literatura, se puede observar que se siguen utilizando los filtros de *Gabor* para hacer extracción de características de textura, ya que a pesar de ser una técnica clásica sigue otorgando resultados aceptables para la mayoría de aplicaciones realizadas en visión artificial.

3.3.3.3 Medidas de Haralick

En el trabajo de investigación (*Haralick et al. 1973*) publicaron que ha tenido un gran impacto en el campo del análisis de imagen porque permite cuantificar las características texturales presentes en una imagen. Al método lo denominaron *Grey Level Co-occurrence Matrix (GLCM)* y lo aplicaron con el objetivo de discriminar distintos tipos de terreno en las imágenes por satélite. Desde entonces se ha utilizado para describir la resolución de texturas. Así, se ha aplicado con éxito en el ámbito de la cartografía y ecología para mejorar las técnicas de identificación de terrenos y ecosistemas a través de fotografías aéreas (*Rios-Díaz et. al 2009*).

La matriz de co-ocurrencia describe la frecuencia de un nivel de gris que aparece en una relación espacial específica con otro valor de gris, dentro del área de una ventana determinada. La matriz de co-ocurrencia es un resumen de la forma en que los valores de los píxeles ocurren al lado de otro valor en una pequeña ventana. A continuación, se presentan los pasos para generar la matriz de co-ocurrencia (*Rios-Díaz et. al 2009*).

Para un mejor entendimiento se realizan una serie de pasos que llevan finalmente a la generación de imágenes de textura:

1. Tamaño de la ventana, que está relacionada con la cantidad de niveles de grises de la imagen de entrada.
2. Componente espacial (la distancia entre píxeles y el ángulo para el cálculo de la matriz de co-ocurrencia).
3. Cálculo de matriz simétrica.
4. Cálculo de matriz de probabilidad.
5. Cálculo de imágenes de textura.

Respecto al tamaño de la ventana, esta debe ser cuadrada y de un número impar de píxeles. El resultado del cálculo es un único valor que representa la ventana completa, el cual es puesto en el lugar del píxel central. Luego, la ventana se mueve un píxel y el cálculo se repite para la nueva posición de la matriz de co-ocurrencia, y así sucesivamente se recorre toda la imagen de manera recursiva, ver figura 3.13.

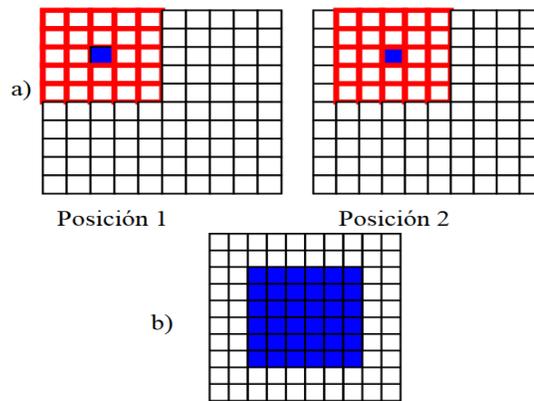


Figura 3.13 En a) se muestra una imagen con su respectiva ventana móvil de 5×5 en dos posiciones y el píxel central que recibe el resultado. En b) se muestra el resultado de toda la operación (Presutti, M. 2004).

Cada celda de la ventana debe situarse en una celda que esté ocupada en la imagen original. Esto significa que el píxel central de la ventana no puede ocupar un borde la imagen. Si una ventana tiene dimensiones $N \times N$, una franja de $(N-1) / 2$ píxeles alrededor de la imagen permanecerán sin resultados, ver figura 3.13.

Usualmente los píxeles de borde representan una pequeña fracción de las imágenes, por lo cual es un problema menor. Sin embargo, si la imagen es muy pequeña o la ventana muy grande, este efecto debe considerarse en el análisis de los resultados. Una forma de solucionar este problema es llenar esas celdas con el valor calculado para el píxel más cercano.

Por otra parte, el tamaño relativo de la ventana y de los objetos en la imagen determina la utilidad de esta medida para la clasificación. Es recomendable que la ventana sea menor que el objeto y lo suficientemente grande como para capturar la variabilidad del mismo. Por ejemplo, en un bosque la textura está determinada por las luces y sombras de las copas. Una ventana con el tamaño de un solo árbol no medirá la textura del bosque. Otra ventana cubriendo todo el bosque y los campos vecinos a él, tampoco medirá la textura del mismo.

La relación espacial entre el píxel de referencia y su vecino puede ser en cualquiera de las 8 direcciones (N , S , E , O y las 4 diagonales), pero sólo se toman cuatro, ya que la N es opuesta a la S y en vez de contarlas separadamente hay formas más sencillas de medirlas (matriz simétrica, que más adelante se detalla). Cuando se habla de una relación “espacialmente invariante” se eligen las cuatro direcciones N , NE , E y SE y se promedian. (Esto también se expresa respectivamente como 0° , 45° , 90° y 135°) ver figura 3.14.

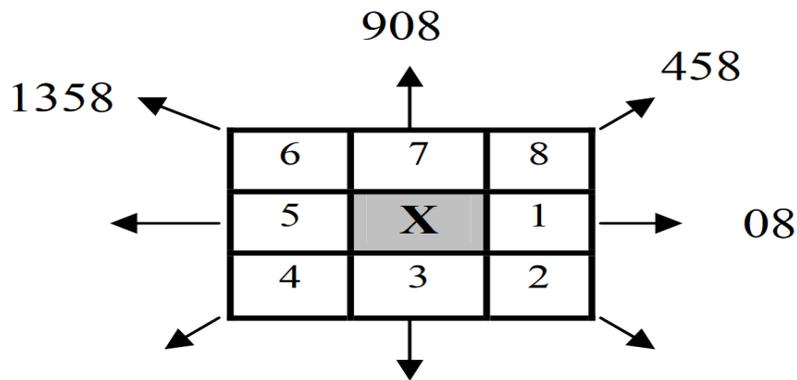


Figura 3.14 Los 8 vecinos del píxel X de acuerdo al ángulo utilizado en el cálculo de la matriz de co-ocurrencia (Presutti, M. 2004).

3.3.3.1 Cálculo de la matriz de co-ocurrencia

La matriz de co-ocurrencia es una tabla que indica cómo están relacionadas las distintas combinaciones de los valores de brillo de los píxeles (niveles de grises) que se presentan en la imagen, por lo que la matriz de co-ocurrencia tendrá dimensiones de $N \times N$ si existen N niveles de grises. Para una imagen de 256 niveles de grises se tendrá una matriz de co-ocurrencia de 256×256 para cada dirección y ventana. En la figura 3.15 se considera una imagen de prueba donde los valores corresponden a los valores de grises. La imagen tiene cuatro niveles de grises (0, 1, 2, 3) por lo tanto se obtendrá una matriz de co-ocurrencia de 4×4 .

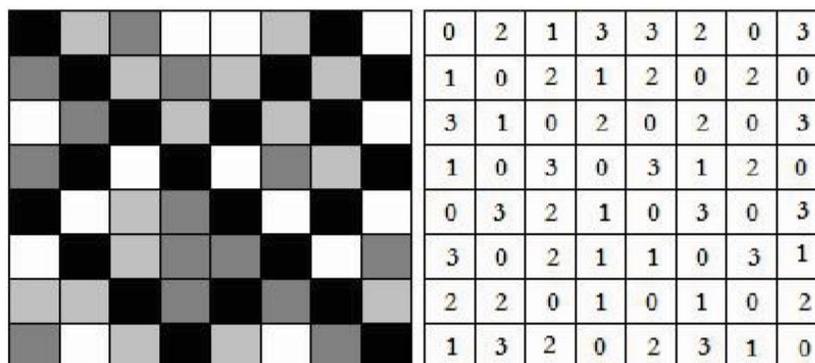


Figura 3.15 Muestra de una imagen original donde se puede observar 4 valores con distintos niveles de gris (0, 1, 2, 3) (Leal, A. 2006).

La matriz de co-ocurrencia considera la relación espacial entre dos píxeles, llamados píxeles de referencia y píxel vecino. Por ejemplo, si se escoge el píxel vecino que está situado a la derecha de cada píxel de referencia, este se expresa como (1,0): 1 será el píxel en la dirección x y 0 será un píxel en la

dirección y. Así, cada píxel en la ventana se convierte en el píxel de referencia empezando por el ubicado arriba a la izquierda y finalizando abajo a la derecha.

Así, se pueden utilizar las diferentes relaciones entre píxeles:

- (1,0) o 0° un píxel a la derecha
- (1,1) o 45° un píxel a la derecha y un píxel arriba
- (0,1) o 90° un píxel arriba.
- (-1,1) o 135° un píxel a la izquierda y un píxel arriba

Tomando en cuenta la dirección (1,0) mencionada anteriormente y que el píxel de referencia estará inmediatamente después de su píxel vecino, las posibles combinaciones entre los cuatro niveles de grises están mostrados en la tabla 3.1.

Tabla 3.1 Todas las posibles combinaciones de los 4 niveles de gris de la imagen original.

Píxel vecino	0	1	2	3
Píxel de referencia				
0	(0,0)	(1,0)	(2,0)	(3,0)
1	(1,0)	(1,1)	(2,1)	(3,1)
2	(2,0)	(2,1)	(2,2)	(3,2)
3	(3,0)	(3,1)	(3,2)	(3,3)

La matriz anterior se lee como: La primera celda debe ser llenada con la cantidad de veces que ocurre la combinación (0,0), es decir, cuántas veces en el área de la ventana un píxel con valor de gris igual a 0 (píxel vecino), está situado a la derecha de otro píxel con valor 0 (píxel de referencia). Por lo tanto, existen diferentes matrices de co-ocurrencia para cada relación espacial según se considere el vecino de arriba, al lado o en diagonal.

En la matriz precedente, se cuenta cada píxel de referencia con su vecino a la derecha. Si el cálculo se realiza sólo de este modo, usando sólo una dirección, entonces el número de veces que aparece la combinación (2,3) no es el mismo que la combinación (3,2), por lo tanto, la matriz no es simétrica respecto de la diagonal.

Sin embargo, la simetría es necesaria para el cálculo. Esto se logra si cada par de píxeles se cuentan dos veces: una vez a la derecha y otra vez a la izquierda (se intercambian los píxeles de referencia y vecino en el segundo cálculo). Para obtener una matriz simétrica la forma más sencilla, en vez de contar dos veces, es sumarle a esta matriz su matriz traspuesta. La matriz traspuesta se logra intercambiando las filas y columnas de la matriz original (Leal, A. 2006).

Una vez obtenida la matriz simétrica, el paso siguiente es expresar esta matriz como probabilidad. La definición más simple de la probabilidad es: “el número de veces que un evento ocurre, dividido por el número total de posibles eventos”, la ecuación (3.11) muestra cómo se realiza su cálculo:

$$C_{i,j} = \frac{P_{i,j}}{\sum_{i,j=0}^{N-1} P_{i,j}} \quad (3.11)$$

Donde:

i es el número de filas y j el número de columnas

P es el valor de la celda (i,j) en la ventana

$C_{i,j}$ es la probabilidad en la celda i,j

N es el número de filas o columnas

Considerando una imagen de prueba de 4 x 4 píxeles, y la relación (1,0) el número total de posibles pares es de 12, como muestra la figura 3.16, y para una relación horizontal (derecha más izquierda) ese número se duplica (24).

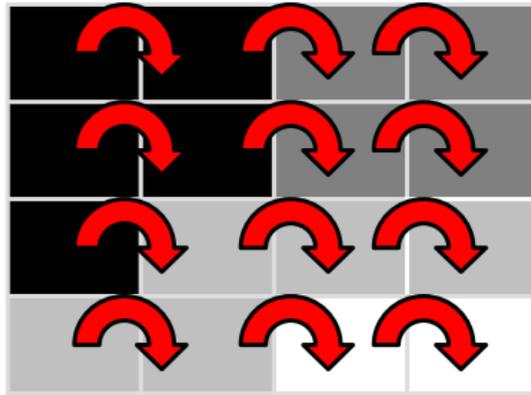


Figura 3.16 Total de pares posibles para una relación espacial (1,0) si la matriz es de 4 x 4 (Leal, A. 2006).

La ecuación (3.11) transforma la matriz de co-ocurrencia en una aproximación de tabla de probabilidad. Entonces se dice, que es una aproximación, porque una verdadera probabilidad requiere de valores continuos, y los valores de grises son valores enteros, por lo tanto, discretos.

Hasta este punto se ha detallado cómo se crea una matriz normalizada, expresada como probabilidad, para una determinada relación espacial entre dos píxeles vecinos. Una vez construida, de esta matriz pueden derivarse diferentes medidas, en esta sección se definen algunas de ellas, y se desarrollan con mayor profundidad las medidas.

A continuación, se muestra una breve explicación de las medidas de textura en imágenes que se aplicaron en este trabajo de investigación.

3.3.3.2 Medidas estadísticas de la textura

Homogeneidad: Una imagen resulta homogénea si los valores de la diagonal principal de la matriz de co-ocurrencia son altos, esto porque al observar la ecuación (3.12) de homogeneidad los valores de

probabilidad en la matriz son mayores en la diagonal principal y su peso decae exponencialmente al alejarse de la diagonal.

$$\sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1 + (i - j)^2} \quad (3.12)$$

Siendo $P_{i,j}$ la probabilidad de co-ocurrencia de los valores de gris de i y j , para una distancia dada, variables que se definen y utilizan de la misma manera en la presente fórmula y en las siguientes (Leal, A. 2006).

Contraste: Este concepto es totalmente opuesto a la homogeneidad donde el contraste tendrá un valor alto si los valores altos están concentrados lejos de la diagonal principal y el peso de la probabilidad aumenta, pero en forma cuadrática y se calcula mediante la ecuación 3.13.

$$\sum_{i,j=0}^{N-1} P_{i,j} \cdot (i - j)^2 \quad (3.13)$$

La matriz de pesos, toma valores que crecen exponencialmente a medida que se aleja de la diagonal (Leal, A. 2006).

Disimilaridad: Es similar al contraste, un alto contraste indica un valor alto de disimilaridad, la diferencia está en que su peso se incrementa linealmente, ecuación 3.14 (Leal, A. 2006).

$$\sum_{i,j=0}^{N-1} P_{i,j} \cdot |i - j| \quad (3.14)$$

ASM (Angular Second Moment): Esta medida da valores altos cuando en la matriz de coocurrencia tiene pocas entradas de gran magnitud, y es baja cuando todas las entradas son similares. Es una medida de la homogeneidad local.

La raíz cuadrada del ASM se denomina Energía o Uniformidad, y también es usada como medida textural y se obtiene mediante ecuación 3.15.

$$\sum_{i,j=0}^{N-1} P_{i,j}^2 \quad (3.15)$$

Entropía: Es alta cuando los elementos de la matriz de coocurrencia tienen relativamente valores iguales. Es baja cuando los elementos son cercanos a 0 o 1 (por ejemplo, cuando la imagen es uniforme dentro de la ventana) y se calcula empleando la ecuación 3.16 (Leal, A. 2006).

$$\sum_{i,j=0}^{N-1} -P_{i,j} \ln(P_{i,j}) \quad (3.16)$$

Se asume que $0 * \ln(0) = 0$.

Si $P_{i,j}$ es una probabilidad y toma valores entre 0 y 1, entonces el $\ln(P_{i,j})$ siempre tomará valores de 0 o negativos. Cuanto más pequeño sea el valor de $P_{i,j}$, es decir que la ocurrencia de esa combinación de píxeles es poco común, el valor absoluto de $\ln(P_{i,j})$ será mayor.

Correlación: Esta medida se calcula de una forma diferente a las anteriores, por lo cual la información que suministra es esencialmente distinta, es independiente a los otros criterios. Por lo tanto, es esperable que pueda ser usada en combinación con otra medida textural y se obtiene utilizando la ecuación 3.17.

Algunas propiedades de la Correlación son:

- Un objeto tiene más correlación alta dentro de él, que entre objetos adyacentes.
- Píxeles cercanos están más correlacionado entre sí que los píxeles más distantes.

$$\sum_{i,j=0}^{N-1} P_{i,j} \left[\frac{(i - \mu_i)(j - \mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \quad (3.17)$$

Donde i y j representa la frecuencia relativa de cada combinación espacial en un determinado par de i y j , $(P_{i,j})$ indica la posición i, j de la matriz de concurrencia, la media j señala el valor medio en filas y N el número de columnas y líneas de la matriz (Ariza et al. 2005).

3.3.4 Reconocimiento e interpretación

La visión de alto nivel busca encontrar una interpretación consistente de las características obtenidas en visión de nivel bajo e intermedio. Se conoce también como visión sofisticada. Se utiliza conocimiento específico de cada dominio para refinar la información obtenida de visión de nivel bajo e intermedio, conocida también como percepción primitiva (*Sucar & Gómez, 2011*).

Este proceso se basa en utilizar conocimiento de los objetos en el dominio de interés, en base al conocimiento y las características, se realiza el reconocimiento. Para llevar a cabo esta etapa es de gran utilidad saber cómo llevar a cabo la representación que sería la forma de modelar el mundo, de forma particular los objetos de interés para el sistema y la descripción de imágenes, esto permite identificar los objetos en las mismas.

En esta sección se explica el clasificador Máquinas de Soporte Vectorial (*MVS*) de aprendizaje supervisado, algoritmo que se seleccionó y utilizó para llevar a cabo la identificación de zonas pertenecientes a árboles de higos o a otras zonas de vegetación; en el capítulo de experimentación se pueden ver los resultados obtenidos.

3.3.4.1 Clasificador Máquinas de Soporte Vectorial (*MVS*)

El aprendizaje automático es una rama de la inteligencia artificial cuyo objetivo es el diseño de sistemas capaces de adaptarse, mejorando su comportamiento de manera autónoma, por interacción con el medio o un instructor (*Bishop, 2013*).

Las máquinas de soporte vectorial (en inglés “*Support Vector Machine*”, *SVM*) es un algoritmo de aprendizaje automático supervisado cuyo objetivo es encontrar un hiperplano para la separación de clases en un espacio extendido por maximización del margen de clasificación. La frontera de separación entre las clases es lineal en el espacio extendido, pero no lineal en el espacio original. El algoritmo fue desarrollado por *Vladimir Vapnik* y su equipo en los años 90 (*Bishop, 2013*).

Estas máquinas pueden ser aplicadas en problemas de clasificación y de regresión. En la actualidad se utilizan con éxito en campos como el reconocimiento de imágenes y textos, la recuperación de información dañada, en aplicaciones biomédicas o en la mejora de motores de búsqueda en internet.

Las *MVS* ofrecen la ventaja de que las mismas pueden ser utilizadas para resolver tanto problemas lineales como no lineales.

Separador Lineal

En el caso de ser linealmente separable, las *MVS* conforman hiperplanos que separan los datos de entrada en dos subgrupos que poseen una etiqueta propia. En medio de todos los posibles planos de separación de las dos clases etiquetadas como $\{-1, +1\}$, existe sólo un hiperplano de separación óptimo,

de forma que la distancia entre el hiperplano óptimo y el valor de entrada más cercano sea máxima (maximización del margen) con la intención de forzar la generalización de la máquina que se esté construyendo (Colmenares, 2012).

Aquellos puntos o ejemplos sobre los cuales se apoya el margen máximo son los denominados vectores de soporte. Un ejemplo de este caso se puede observar en la figura 3.17.

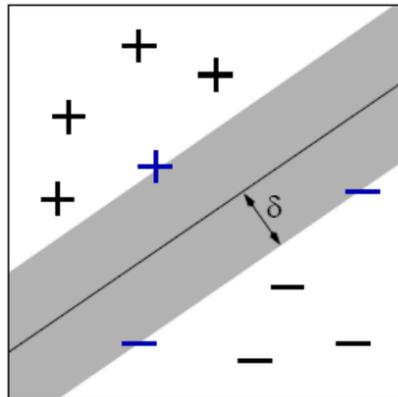


Figura 3.17 Representación de separador lineal de las MVS. La frontera de decisión debe estar tan lejos de los datos de ambas clases como sea posible (Colmenares, 2012).

Separador no Lineal

Para el caso no lineal existen dos casos que vale la pena mencionar:

- El primero de estos se presenta cuando los datos pueden ser separables con margen máximo, pero en un espacio de características (el cual es de una mayor dimensionalidad y se obtiene a través de una transformación a las variables del espacio de entrada) mediante el uso de una función *kernel*.
- El segundo caso especial de las MVS denominado “*Soft Margin*” o margen blando, es utilizado cuando no es posible encontrar una transformación de los datos que permita separarlos linealmente, bien sea en el espacio de entrada o en el espacio de características (Colmenares, 2012).

MVS con margen máximo en el espacio de características

Hay casos donde los datos no pueden ser separados linealmente a través de un hiperplano óptimo en el espacio de entrada. En muchas situaciones, los datos, a través de una transformación no lineal del espacio de entradas, pueden ser separados linealmente, pero en un espacio de características se pueden aplicar los mismos razonamientos que para las MVS lineal con margen máximo.

La transformación de los datos en un espacio inicial a otro de mayor dimensión se logra mediante el uso de la función *kernel*.

Una función núcleo o *kernel* es un producto interno en el espacio de características, que tiene su equivalente en el espacio de entrada, ver expresión (3.18).

$$K(x, x') = \langle \phi(x), \phi(x') \rangle \quad (3.18)$$

donde K , es una función simétrica positiva definida, x es el vector de entrada para realizar el entrenamiento y x' es el vector para realizar la prueba. De manera gráfica se puede observar en la figura 3.18 cómo la función *kernel* permite realizar la separación y el traslado de los datos al espacio de características (*Colmenares, 2012*).

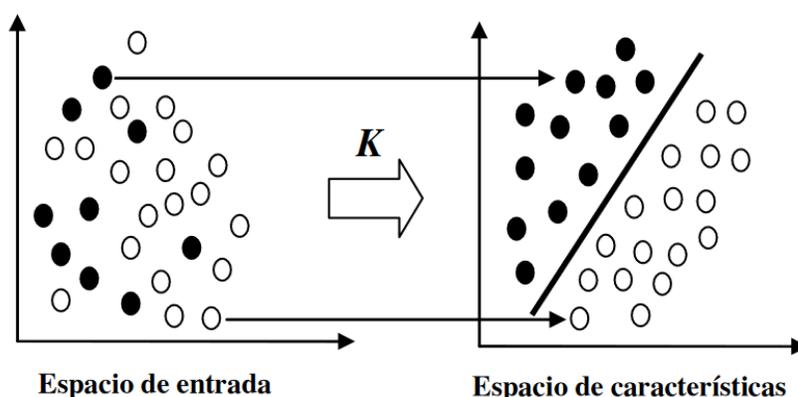


Figura 3.18 MVS no linealmente separable inducida por una función kernel (*Colmenares, 2012*).

Entre los *kernels* más comunes, se encuentran: la función *lineal*, *polinomial*, *RBF* (*Radial Basis Function*), *ERBF* (*Exponential Radial Basis Function*), entre otros.

3.3.5 Métricas para evaluar la segmentación

Se han propuesto diversos métodos para evaluar la segmentación de imágenes. Sin embargo, todos se basan en diferentes principios subyacentes funcionales y hacen diferentes suposiciones sobre la información que se presenta en una imagen. Por lo que se debe de hacer una elección de métricas que sean adecuadas para el problema que se presenta y hacer su aplicación. Las siguientes son algunas de las medidas disponibles en la literatura, las cuales fueron utilizadas para evaluar la segmentación obtenida con el *Ground truth*.

Probabilistic Rand Index (PRI)

El índice de probabilidad aleatoria (*PRI*), permite dar la precisión de la comparación entre imágenes, comparando la considerada como “Deseada” y la imagen segmentada. Esta medida representa la cercanía del *ground truth* y la resultante y, de esta manera tener la variabilidad del sistema de visión humana.

El *PRI* toma valores en el rango [0, 1]. Un valor de puntuación de 1 significa que la segmentación es de calidad perfecta, mientras que un valor de puntuación igual a 0 significa que la segmentación es de peor calidad. La desventaja del *PRI* es que tiene un pequeño rango dinámico de [0, 1], por lo que sus valores a través de imágenes y algoritmos a menudo son similares (Zhang et. al 2008). La fórmula que permite calcular la distancia es la siguiente:

$$R(GT, S) = \frac{1}{\binom{N}{2}} \sum_{i,j, i \neq j} [I(l_i = l_j \wedge l'_i = l'_j) + I(l_i \neq l_j \wedge l'_i \neq l'_j)] \quad (3.19)$$

Donde R es la relación que existe entre GT y S considerando el número de pares de puntos (píxeles) en común y N es la función de identidad y el denominador es el número de posibles pares únicos entre n puntos de datos. Se debe tomar en cuenta que no existe restricción alguna en el número de etiquetas únicas en GT y S que sean iguales.

Variation of Information (VOI)

La métrica de variación de información (*VOI*) define la distancia entre dos segmentaciones como entropía condicional promedio de una segmentación dada a la otra y, por lo tanto, mide aproximadamente la cantidad de aleatoriedad en una segmentación que no puede ser explicada por el otro (Zhang et. al 2008). *VOI* se define como:

$$VOI(c, c') = H(c) + H(c') - 2I(c, c') \quad (3.20)$$

donde, $H(c)$ y $H(c')$ son las entropías asociadas con el grupo c' ; I es la información mutua entre las variables aleatorias asociadas. La entropía se puede obtener con la siguiente expresión:

$$e(D_i) = - \sum_{j=1}^k Pr_i(C_j) \log_2 Pr_i(C_j) \quad (3.21)$$

Dónde $Pr_i(c_j)$ es la proporción de puntos de la clase c_j ubicados en el clúster i o D_i . La entropía total de todo el agrupamiento (que considera todos los *clústers*) es:

$$e_{total}(D) = \sum_{j=1}^k \frac{|D_i|}{|D|} x e(D_i) \quad (3.22)$$

Jaccard Index (JI)

La métrica Índice de *Jaccard* mide la intersección sobre la unión de los segmentos etiquetados para cada clase e informa el promedio. El *J* toma en cuenta tanto las falsas alarmas como los valores perdidos para cada clase. Con la ayuda de la siguiente expresión se puede calcular *J*:

$$J(A, B) = \frac{A \cap B}{A \cup B} \quad (3.23)$$

Donde *A* y *B* son vectores definidos y se lleva a cabo la comparación entre la similitud que existe entre los dos vectores, siempre toma valores entre [0,1], siendo que si el valor obtenido es más cercano a 1 es tomado en cuenta como la igualdad entre ambos vectores.

3.3.6 Comentarios

En este capítulo se presentó la metodología de solución de manera esquemática, así como el marco teórico de cada una de las técnicas utilizadas en el desarrollo del proyecto, se muestran las técnicas de procesamiento digital de imágenes, de agrupamiento difuso para la segmentación, de descripción de textura para la extracción de características, de aprendizaje automático para la clasificación de la información y las métricas para evaluar el rendimiento del sistema con respecto a la segmentación.

Capítulo 4 . Análisis, diseño e implementación del sistema

4.1 Introducción

En este capítulo se presenta el análisis, diseño e implementación del sistema para la segmentación de imágenes aéreas mediante visión artificial, así como algunos detalles en el desarrollo que se llevó a cabo. El diseño y la implementación del sistema mencionado, se realizan tomando en cuenta como base la metodología de solución que se presentó en el capítulo 3.

4.2 Análisis del sistema

El diseñar la solución de un problema implica que se debe de realizar un análisis previo para verificar la viabilidad del mismo. El objetivo de esta etapa es generar un modelo para dar solución al problema de segmentar imágenes aéreas a través de herramientas empleadas para el desarrollo de inteligencia artificial en especial visión artificial y de esta manera obtener una segmentación similar al *ground truth*. Esta segmentación es elaborada por seres humanos y su proceso tarda de dos a tres días para llevarse a cabo. Por lo que se utilizan métodos y algoritmos relacionados y asociados al problema que se desea resolver.

De acuerdo a la problemática propuesta se requiere el desarrollo de un sistema de visión artificial para segmentar imágenes aéreas, por lo que se realizó un análisis del caso y de acuerdo con el esquema que proponen (Gonzalez & Woods, 2002), se propuso una metodología para llevar a cabo el desarrollo de un sistema para la segmentación de imágenes aéreas mediante visión artificial, el cual está conformado por las siguientes etapas: adquisición de imágenes, preprocesamiento, segmentación, representación y descripción, reconocimiento y resultados.

4.3 Diseño del sistema

Una vez que se llevó a cabo el análisis del problema, se realiza el diseño del sistema, en la que se define la arquitectura satisfaciendo los puntos establecidos en la fase de análisis. En el siguiente apartado se presenta la arquitectura propuesta para el desarrollo del sistema para segmentación de imágenes aéreas mediante visión artificial.

4.3.1 Arquitectura del sistema

Aquí se presenta de manera formal una descripción del problema, en la que se incluyen sus componentes y relaciones entre sí. Inicialmente se tiene una imagen de entrada o también se puede trabajar con un conjunto de imágenes que se encuentren en una carpeta, a partir de ahí se realiza la etapa de preprocesamiento, en la que se trabaja con la transformación del espacio de color *RGB* a *HSV* y posteriormente se toma en cuenta sólo la banda *H* para trabajar en base al color.

En la etapa de segmentación se determinó utilizar el algoritmo de agrupamiento *fuzzy c-means*, al cual se le especifica un valor de *K* igual 2. Este valor se definió así porque en el preprocesamiento que se realiza, se aplica la transformación de color antes mencionado y eso permite eliminar todas aquellas regiones que no tienen un tono verde, convirtiéndolas a fondo de la imagen y así realizar la segmentación de imágenes de árboles de higos con el algoritmo.

En algunas imágenes se puede encontrar vegetación ajena a la de interés, por lo que se decidió trabajar en la etapa de representación y descripción, en la que se llevó a cabo la implementación de descriptores de textura para la extracción de características y lograr obtener una segmentación con mayor detalle para la separación de vegetaciones que se encuentran en las imágenes.

Para llevar a cabo el reconocimiento se determinó trabajar con el algoritmo de clasificación Máquinas de Soporte Vectorial, el cual permite determinar qué tan eficiente es la separación de vegetaciones.

Finalmente, se muestra la etapa de resultados obtenidos del sistema que se desarrolló, mediante la aplicación de algunas de las métricas que son empleadas en la literatura para medir la segmentación de imágenes y de esta manera determinar la eficiencia del sistema. La figura 4.1 muestra de manera general las etapas que conforman el sistema para segmentación de imágenes.

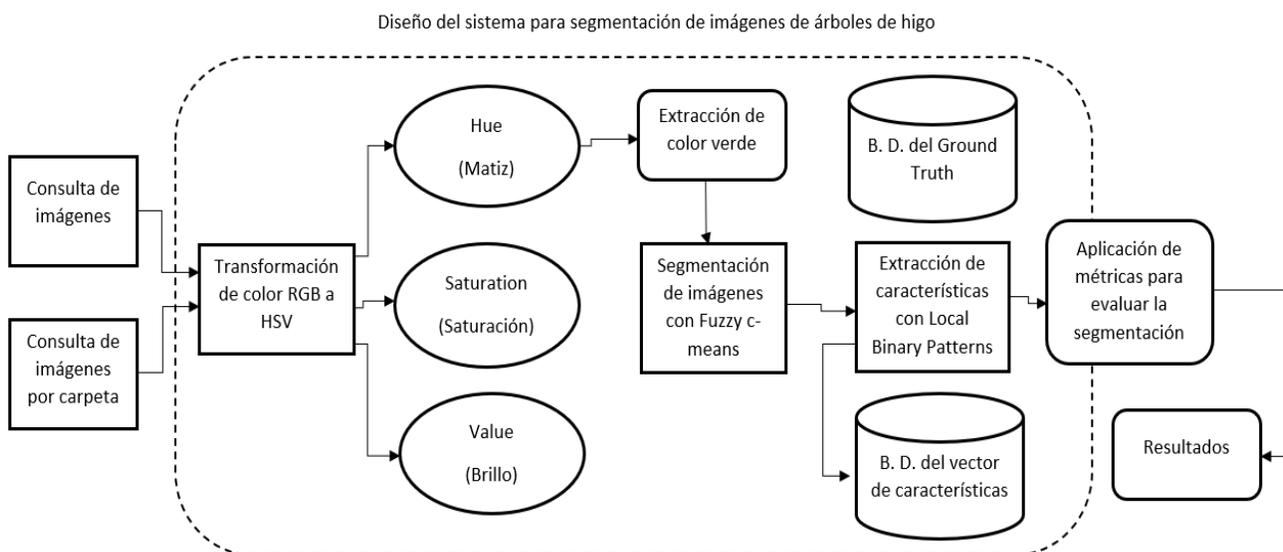


Figura 4.1 Etapas del sistema para segmentación de imágenes aéreas mediante visión artificial.

4.4 Software utilizado para desarrollo del sistema

En este apartado se menciona y de manera breve se presenta una descripción del software que se utilizó para el desarrollo e implementación del sistema de visión artificial que permite segmentar imágenes aéreas correspondientes a plantaciones de árboles de higos.

4.4.1 Python

Para llevar a cabo el desarrollo del sistema se utilizó el lenguaje de programación *Python* (Rossum, 1991) en sus versiones 2.7 y 3.7. Es un lenguaje con mucho potencial hablando del procesamiento gráfico, orientado a objetos y matemático, esto permite dividir el programa en módulos reutilizables desde otros programas Python. El intérprete se puede utilizar de modo interactivo, lo que facilita experimentar con características del lenguaje, escribir programas desechables o probar funciones durante el desarrollo del programa. Se utilizaron librerías como: *Numpy*, *Pandas*, *Matplotlib*, *Skimage*, *Scikit-Image*, *Scikit-Fuzzy*, y *Scikit-Learn*, las cuales formaron parte importante para el desarrollo del sistema.

4.4.2 OpenCV

Para el procesamiento de las imágenes aéreas, se utilizó la biblioteca de código libre *OpenCV 4.0.0* (Intel, 2000), debido a que es una herramienta que se utiliza para el desarrollo de sistemas de visión artificial como: reconocimiento de objetos, visión robótica, calibración de cámaras entre otros. Haciéndolo un proyecto altamente eficiente y fácil de utilizar. Esto se ha logrado debido a que su programación está desarrollada en código *C* y *C++* optimizados.

4.4.3 PyQT 5

Para el desarrollo de la interfaz gráfica se hizo la selección de trabajar con *PyQT 5* (Riverbank Computing, 2009), debido a que es una herramienta que está especialmente ligada al lenguaje de programación *Python* y se puede interactuar a través de la misma con la librería *OpenCV*, permitiendo la creación de la interfaz gráfica de usuario para la segmentación de imágenes aéreas.

4.5 Interfaz gráfica

La interfaz gráfica del sistema se realizó de manera que para el usuario sea sencillo e intuitivo el utilizarla. En la parte superior de la ventana se puede observar una barra de menú, en la cual se encuentra cada uno de los módulos o etapas que se desarrollaron para realizar la segmentación de imágenes, en la figura 4.2 se puede observar la ventana principal del sistema.

Segmentación de Árboles de Higos en Imágenes Aéreas, mediante Visión Artificial.



Figura 4.2 Ventana principal del sistema segmentación de imágenes aéreas mediante visión artificial.

En la figura 4.3 se puede observar el inicio del proceso, donde se hace la selección de imagen o imágenes a procesar, se puede hacer de manera individual o seleccionar una carpeta y de esta forma pasar a la etapa de preprocesamiento, como lo muestra la figura 4.3.

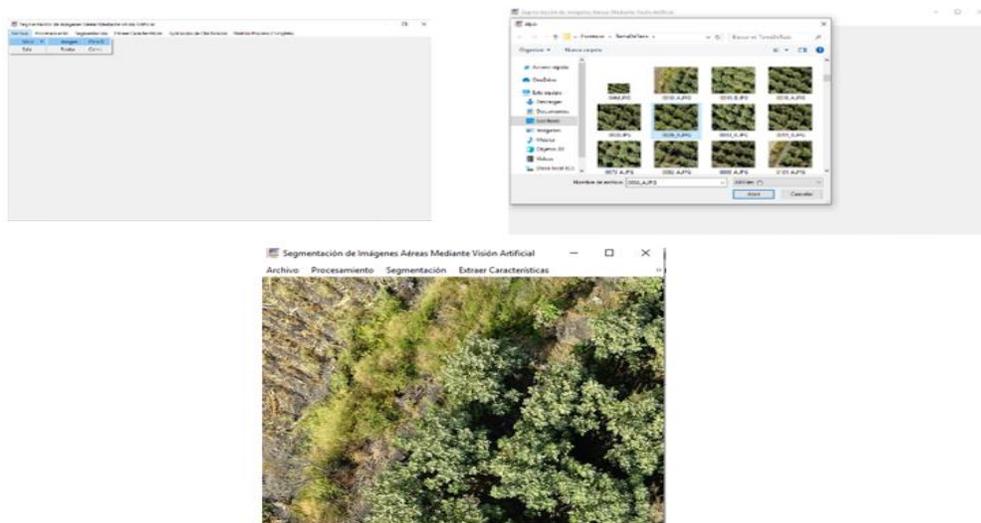


Figura 4.3 Selección de imagen o imágenes por carpeta para aplicarles el preprocesamiento.

En la figura 4.4 se muestra la etapa de preprocesamiento, en la cual se realiza la extracción del color verde a través de la transformación de color *RGB* a *HSV*, utilizando el canal *H*, en la figura 4.4 se muestra un ejemplo de la extracción de color.

Como se puede observar, se extrae el tono verde, en la banda *H* y esta imagen es restada a la original, proceso denominado como extracción de color.

Segmentación de Árboles de Higos en Imágenes Aéreas, mediante Visión Artificial.

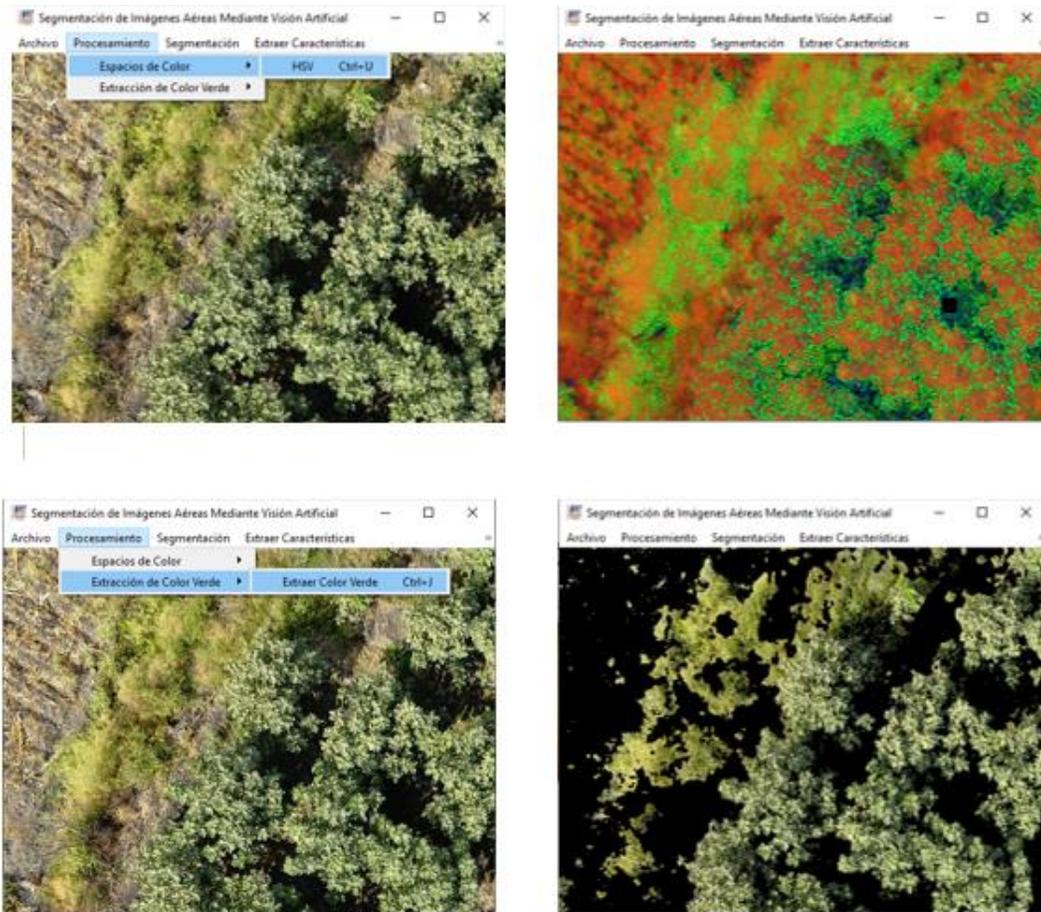


Figura 4.4 Transformación de color RGB a HSV y extracción de color verde.

En la figura 4.5, se puede observar en la ventana principal de la interfaz, el proceso de segmentación. Inicia con la imagen resultante de la etapa de preprocesamiento, en la cual, como ya se dijo se realiza la transformación de color *RGB* a *HSV* y se utilizó la banda *H*, siendo la que mejores resultados de manera independiente, debido a que se trabajó con las bandas *S* y *V*, las cuales no otorgaron buenos resultados.

Posteriormente, en el menú de segmentación, en la barra superior, hace la selección del algoritmo *fuzzy c-means*, para que se aplique a la imagen seleccionada como lo muestra la figura 4.5. Como ya se mencionó, el valor de *K* es igual a 2 en todo el proceso de segmentación.

En la imagen puede existir la presencia de otro tipo de vegetación al de interés, es por ello que, en imágenes de este tipo, donde se empalman los árboles de higos con otro tipo de vegetación se les debe de aplicar otro proceso para obtener una segmentación con mayor detalle; por lo cual se tomó la decisión de trabajar con descriptores de color y de textura, como *Local Binary Patterns*, *Medidas de Haralick* y *Filtros Gabor*.

Segmentación de Árboles de Higos en Imágenes Aéreas, mediante Visión Artificial.

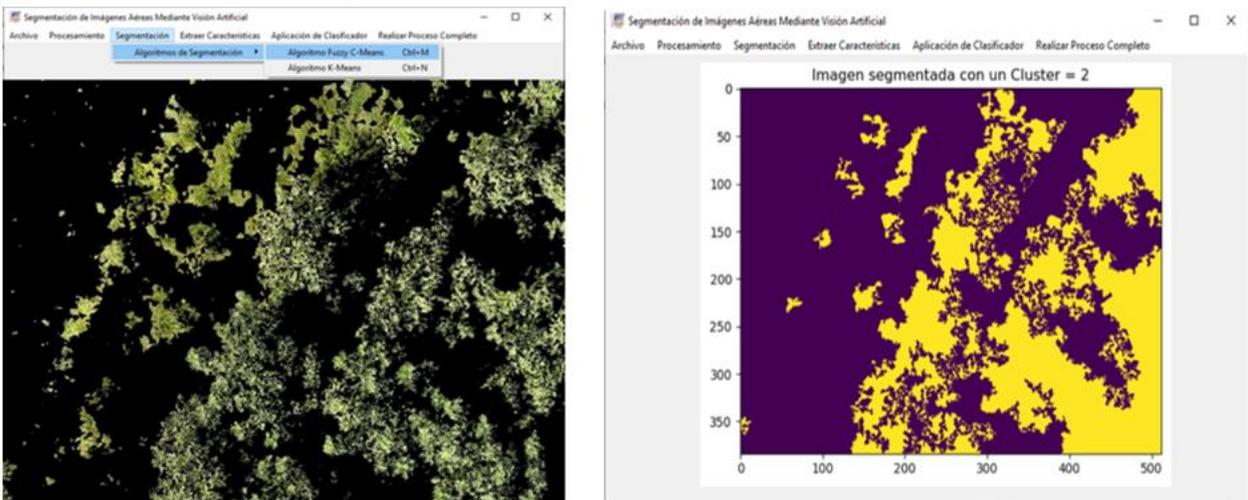


Figura 4.5 Etapa de segmentación imagen obtenida después de aplicar el algoritmo de *fuzzy c means*.

La figura 4.6 muestra el proceso para extraer las principales características de la imagen y de esta manera crear un vector de atributos por cada descriptor que se aplique. En el sistema se encuentran tres opciones: *Local Binary Patterns*, *Filtros Gabor* y *Medidas de Haralick*; los datos extraídos son almacenados en archivos de texto en los cuales están las características de cada imagen en forma de vector. Posteriormente, se pasa a la última etapa de reconocimiento automático.

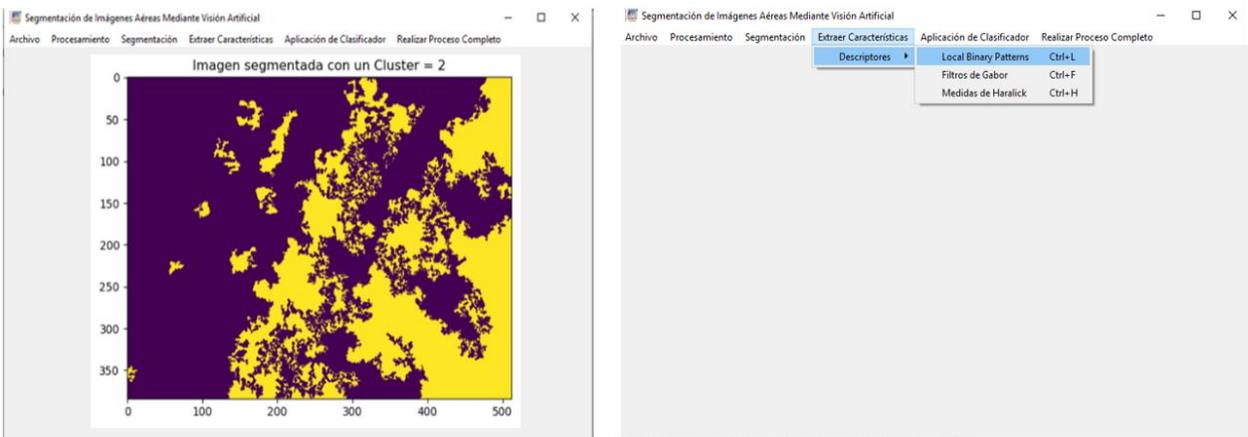


Figura 4.6 Etapa de extracción de características, a través de la aplicación de descriptores en imágenes donde se empalman los árboles de higos con otro tipo de vegetación.

En la figura 4.7 se muestra un ejemplo de la clasificación que se lleva a cabo y se pueden observar los resultados obtenidos a través de datos estadísticos. El sistema se integra de la etapa de entrenamiento del clasificador, cuyo resultado es el modelo. Posteriormente, se evalúa el rendimiento del sistema en la

Segmentación de Árboles de Higos en Imágenes Aéreas, mediante Visión Artificial.

etapa de pruebas con un conjunto de imágenes diferente al utilizado en la etapa de aprendizaje. De manera visual el resultado es lograr la separación de clases, en este caso el empalme entre vegetaciones.

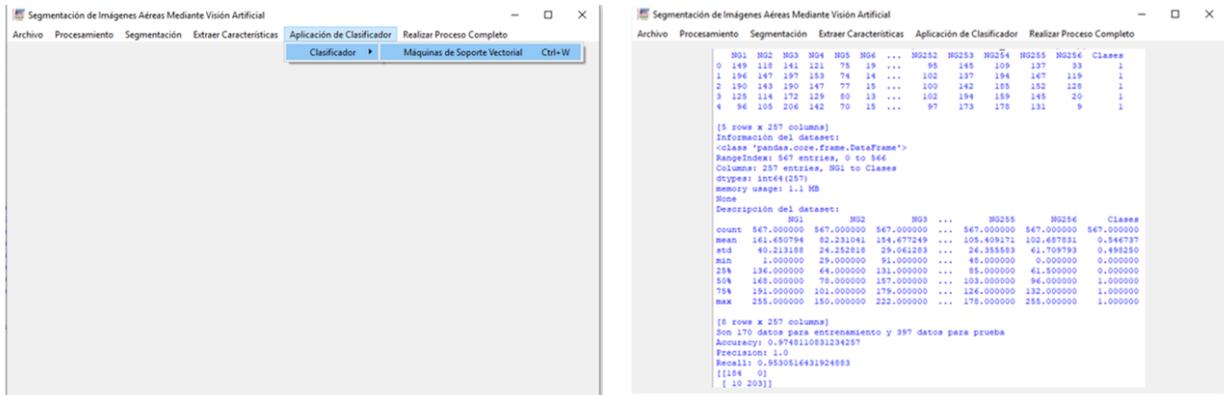


Figura 4.7 Etapa de clasificación en la que se lleva a cabo la separación de clases, a través de aprendizaje automático y aplicación de descriptores de textura.

Se evalúa la segmentación de manera cuantitativa a través de las métricas mencionadas en la sección de marco teórico, con las cuales de manera estadística se determina qué tan eficiente es la segmentación que lleva a cabo de las imágenes anteriormente procesadas en comparación objetiva con las imágenes del *ground truth*.

Los parámetros del clasificador que se utilizaron son los que se tienen por defecto y el *kernel* utilizado fue el de base radial.

Capítulo 5 . Experimentación y resultados

5.1 Introducción

En este capítulo se presenta información acerca del banco de imágenes que fue proporcionado por la Universidad Autónoma del Estado de Morelos (UAEM), se muestran los casos la experimentación que se realizaron en cada una de las etapas, anteriormente mencionadas, que integran el sistema; se muestran los resultados de las métricas utilizadas para evaluar el rendimiento del sistema y finalmente un breve análisis de los resultados obtenidos.

5.2 Banco de imágenes

En primera instancia se llevó a cabo el proceso para obtener el conjunto de imágenes aéreas que corresponden a plantaciones de árboles de higos con ubicación en el estado de Morelos. Debido a que se realizaron diversas capturas durante todo el día las imágenes cuentan con cambios en la intensidad luminosa muy grandes; se revisaron y definió que en el horario matutino entre las 9:00 y 10:00 am, las imágenes contenían una mejor definición y una menor presencia de sombras o cambios en la iluminación, para realizar la segmentación requerida. Se cuenta con un conjunto de 130 imágenes, de alta resolución con un tamaño de 1500 x 2000 píxeles en formato RGB.

En dicho conjunto hay imágenes con diferente intensidad luminosa, cambios de perspectiva y en varias se empalman los árboles de higos con otro tipo de hierba como pasto, maleza o en algunos casos puede presentarse otro tipo de árbol ajeno al de interés entre otros objetos.

También se cuenta con el conjunto de imágenes correspondiente al *ground truth*, de las cuales son 15 imágenes del conjunto original que fue proporcionado. El *ground truth* fue elaborado por un grupo de trabajo de la Universidad Autónoma del Estado de Morelos (UAEM), el cual fue realizado de forma manual y su proceso tarda de tres a cinco días. En la figura 5.1 se muestra un par de imágenes que pertenecen al conjunto que fue otorgado por la UAEM, en las que se pueden observar solamente árboles de higos.



Figura 5.1 Ejemplo de imágenes con plantaciones de árboles de higos, en las cuales no existe otro tipo de vegetación adicional a los árboles, sólo se puede ver árboles de higos, suelo y rocas.

En la figura 5.2 se muestra un par de imágenes en las que se presenta otra clase de vegetación ajena a la de interés, como pasto, hierba, suelo rocalloso o en ocasiones vegetación seca, así como otro tipo de árboles diferentes a los de higos.



Figura 5.2 Imágenes con plantaciones de árboles de higos, en las cuales, se observa otro tipo de vegetación adicional a los árboles de higos, donde se puede observar pasto, hierbas, suelo y rocas.

En la figura 5.3 se muestra un par de imágenes correspondientes al conjunto del *ground truth*, siendo este el resultado esperado al realizar la segmentación a través del método propuesto. Esta segmentación fue realizada por un grupo de trabajo de la Universidad Autónoma del Estado de Morelos y su proceso demora de 3 a 4 días para cada imagen, por lo que se espera que con el sistema se lleve a cabo la segmentación de imágenes en menos tiempo.

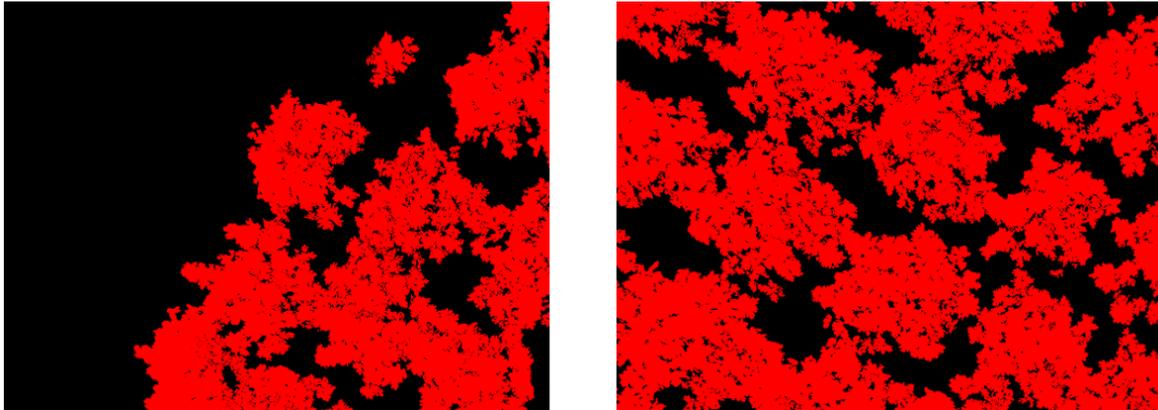


Figura 5.3 Imágenes del *Ground truth* elaboradas por el grupo de trabajo de la Universidad del Estado de Morelos.

Del conjunto de 130 imágenes proporcionadas por la Universidad Autónoma del Estado de Morelos, se realizó la experimentación con las 130 imágenes, de las cuales 45 contienen solo árboles de higos, 45 con diferente intensidad luminosa y 40 que contienen árboles de higos y otro tipo de hierba ajena al objeto de interés.

Adicionalmente se trabajó en hacer la fragmentación de imágenes originales en ventanas de 128 x 128 píxeles, formando un conjunto de 1,938 imágenes por cada una de las mismas. Éstas fueron utilizadas para trabajar la parte del entrenamiento y pruebas con el clasificador para determinar la separación entre las dos clases generadas, en este caso “árbol de higos” y “maleza”, lo cual proporcionó un total de 361 imágenes por cada imagen analizada de 128 x 128 píxeles. Este proceso se realizó para una descripción detallada, debido a que algunas imágenes donde se traslapa otro tipo de hierba o pasto se complica realizar la segmentación y la idea es hacer la mayor separación entre árbol de higos y otro tipo de hierbas.

5.3 Experimentación y resultados

En este apartado se puede observar la experimentación que se llevó a cabo durante el desarrollo de este tema de tesis, en el cual se muestran los resultados obtenidos por cada una de las etapas que se desarrollaron a lo largo de este periodo.

5.3.1 Experimentación con el modelo de color HSV

El objetivo de esta experimentación fue transformar la imagen y obtener sólo las áreas de color verde presentes en la imagen, para ello se realizaron diferentes experimentaciones con diversos espacios de color que existen en la librería *OpenCV*, de los cuales el que mejores resultados otorgó fue el espacio de color *HSV*, en cuanto a la obtención del tono verde.

Por lo que se determinó trabajar con los detalles que proporciona el canal H , siendo el canal que otorga mayor información para posteriormente realizar la obtención del color verde, debido a las características de las imágenes que se debían analizar.

En la tabla 5.1 se puede ver el resultado de, obtener el canal H y esa imagen utilizarla como referencia para obtener las zonas de color verde de la imagen original. En la tabla 3 se muestran 4 casos ejemplo, los casos A1 y B1 presentan imágenes que tienen árboles de higos y áreas con la presencia de suelo, con diferente iluminación y diferente perspectiva. En ambas imágenes, se puede ver que los resultados son buenos ya que se realiza la extracción de los árboles y el fondo es remplazado por un color negro. En general, con imágenes que cuentan con estas características se tienen buenos resultados.

Respecto a las imágenes mostradas en los casos C1 y D1, se puede observar la presencia de hierba cercana a los árboles. En este caso, la segmentación obtenida considerando el tono verde, proporciona la región perteneciente a los árboles y a la hierba, es decir, se tiene un preprocesamiento correcto. Pero en términos de segmentación no correcto por el empalme de vegetación. En las imágenes en que se empalman dos o más vegetaciones, es necesario se aplica otro proceso para la separación de las regiones, a las cuales se les aplican descriptores de color y textura.

En estos ejemplos se tomaron imágenes de entrada en formato RGB , con el apoyo de la librería *OpenCV* se les realizó la transformación de color RGB a HSV , posteriormente se utilizó el canal H , además se creó una máscara en color negro para omitir el fondo y consecuentemente se obtuvo el color verde de las imágenes, como se observa en la tabla anterior.

En imágenes como las mostradas en los casos A y B sólo hay árboles de higos, sin embargo, se puede notar de forma visual que la intensidad luminosa es variable. Al momento de realizar la transformación de color es notable que algunas zonas de árboles no son detectadas y junto con las regiones de fondo es remplazado por una máscara en color negro

En los casos C1 y D1, se puede observar que se extraen las regiones de los árboles de higos junto con otra especie de hierba porque todo ello presenta el tono verde. En este tipo imágenes se tienen conflictos por el ruido que ocasiona la aparición de hierba; y la separación de las zonas es peor en algunas de las imágenes donde se empalma la hierba con los árboles de higos. Ese problema hizo que la etapa de segmentación fuera aún más complicada. Por lo que fue necesario recurrir a la implementación de descriptores de textura y los resultados obtenidos se pueden observar en el apartado de descriptores.

Tabla 5.1 Casos A1, B1, C1 y D1, son ejemplos de la experimentación que se realizó para la obtención del tono verde, en la etapa de preprocesamiento.

Caso	Imagen original RGB	Imagen preprocesada con el espacio de color HSV utilizando el canal <i>H</i>
A1		
B1		
C1		
D1		

5.3.2 Experimentación con el algoritmo de agrupamiento fuzzy c-means

El objetivo de esta prueba fue el mejorar la segmentación obtenida mediante la agrupación de los píxeles de acuerdo a su tonalidad, para ello se aplicó el algoritmo *fuzzy c-means*, con un valor de $k=2$, ya que se considera que las imágenes sólo se tienen las regiones de color verde y fondo. La evaluación inicial se realizó a un conjunto de 85 imágenes, en las cuales solo hay árboles de higos y de fondo terreno rocalloso. Después, el algoritmo se aplicó a otro conjunto de 45 imágenes, en las que además de árboles de higos existe otro tipo de vegetación, y en algunas, se llegan a empalmar las regiones y se debe realizar una segmentación con mayor detalle, siendo necesario la extracción de descriptores de textura.

En la tabla 5.2 se muestran el caso A2 y B2, ejemplos de imágenes en las cuales sólo hay árboles de higos y la segmentación es aceptable de manera visual. El resultado también se obtuvo de manera cuantitativa a través de métricas para evaluar la segmentación que se obtuvo de la implementación del algoritmo *fuzzy c-means* (*FCM*).

Las métricas que se utilizaron para la evaluación son: *Probabilistic Rand Index (PRI)*, la cual permite hacer la comparación entre la imagen de referencia (*ground truth*) y la imagen obtenida de la segmentación. *Global Consistency Error (GCE)*, esta métrica mide el grado en que una segmentación puede verse como un refinamiento y obliga a todos los refinamientos locales a estar en la misma dirección. *Variation of Information (VOI)*, esta métrica mide aproximadamente la cantidad de aleatoriedad en una segmentación que no puede ser explicada por el otro. También se aplicó la métrica *coeficiente de jaccard (CJ)*, la cual se utiliza para evaluar la similitud entre la imagen segmentada y la imagen de referencia.

Los resultados obtenidos a través de las métricas anteriormente mencionadas se muestran en el apartado de métricas para evaluar la segmentación.

En el caso C2 y D2 se muestran ejemplos de imágenes en las cuales se empalman los árboles de higos con otro tipo de hierba, en primera instancia se encuentra la imagen preprocesada, después la imagen segmentada y finalmente el *ground truth*. En los ejemplos que se presentan, se puede percibir que la imagen resultante después de aplicar *FCM* tiene un poco de ruido a diferencia de la imagen resultante del procesamiento con la banda *H*.

Es por ello que a estas imágenes se les debe de realizar otro proceso para lograr una segmentación a mayor detalle. Después de hacer un análisis en base a la literatura y tratar de atacar este problema, se optó por trabajar con descriptores de textura. Estas técnicas permiten describir a las imágenes a mayor detalle, hablando especialmente de la extracción de características con las que cuenta cada una de ellas.

Tabla 5.2 Casos A2 y B2 en los cuales sólo hay árboles de higos.

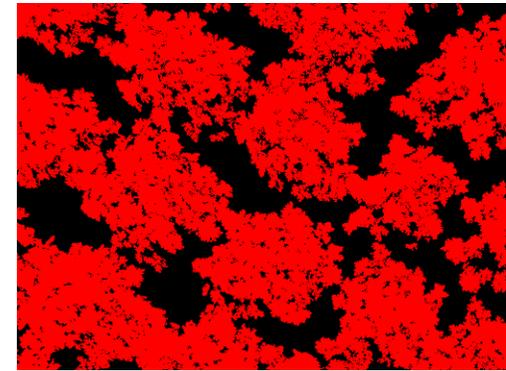
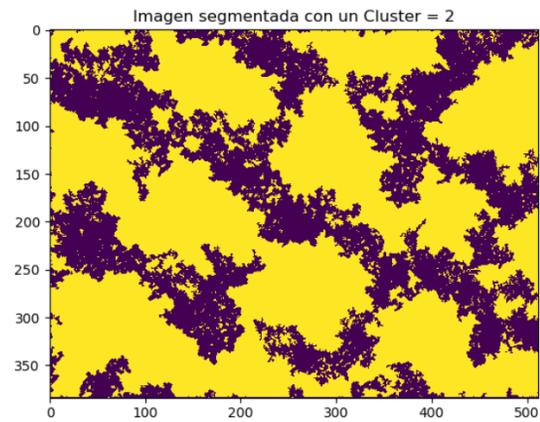
Caso

Imagen preprocesada

Imagen segmentada con fuzzy c-means

Imagen de ground truth

A2



B2

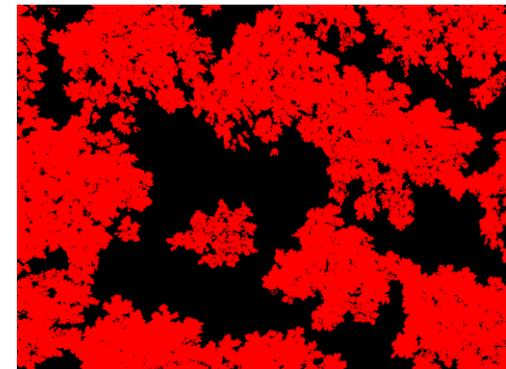
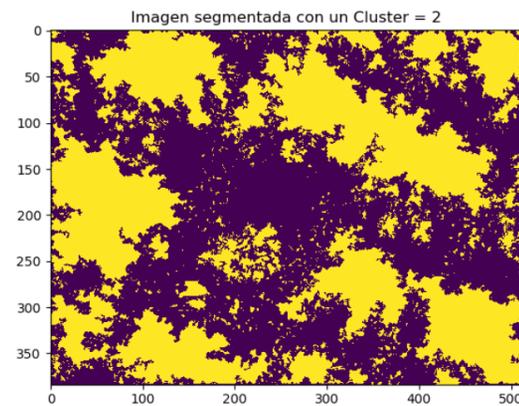
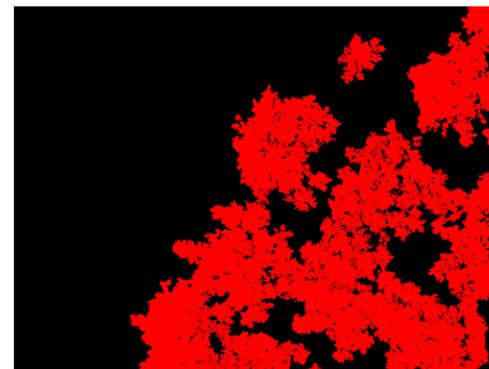
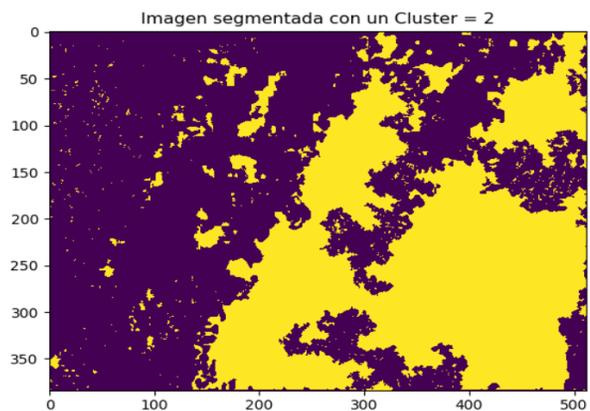
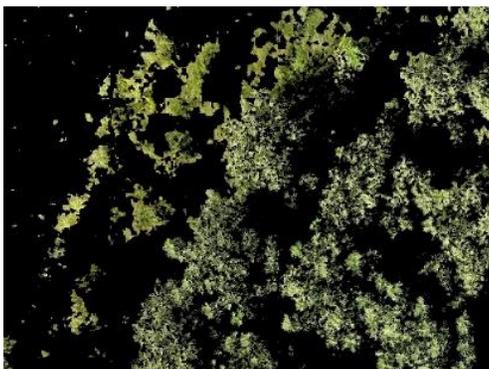
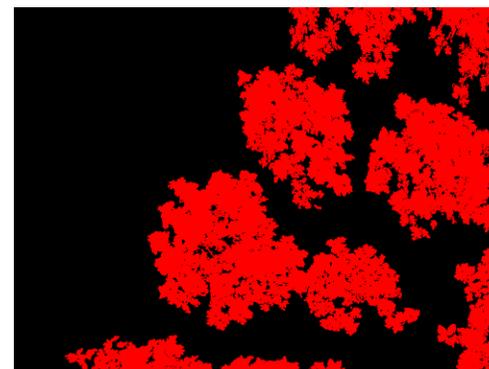
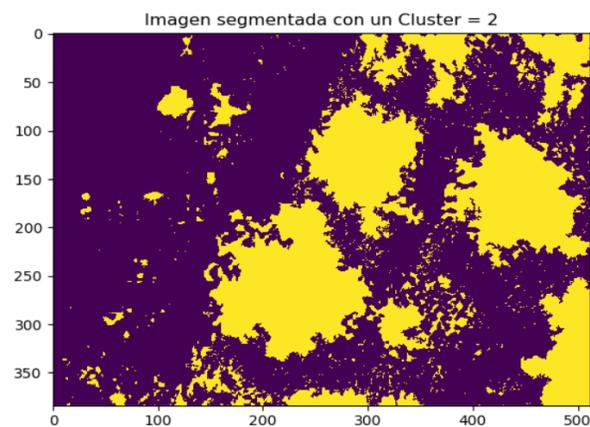


Tabla 5.3 Continuación de la tabla, casos C2 y D2 en los cuales existe traslape de vegetación.

C2



D2



Como se puede observar en la tabla 5.2, la segmentación que se realizó a imágenes con árboles de higos, de manera visual se pueden considerar que son aceptables en base al *ground truth*, y se reafirma con los resultados obtenidos a través de la aplicación de las métricas anteriormente mencionadas y de esta manera determinar la similitud entre las segmentaciones realizadas.

El resultado de esta fase, proporciona una imagen donde muestra en un tono diferente al negro (considerado fondo) las regiones pertenecientes a los árboles. Esta imagen se resta con la original y se obtiene la imagen que será la entrada para la etapa de extracción de las características.

En las imágenes en las que existe otro tipo de vegetación ajena a la de interés la segmentación que se lleva a cabo no es tan certera, debido a que existe un empalme entre vegetaciones. Para ello se llevó a cabo la aplicación de algunos de los descriptores de textura que existen en la literatura, como *Local Binary Patterns (LBP)*, las medidas de *Haralick* para la extracción de características y además se realizó una fusión entre medidas de *Haralick* y filtros de *Gabor* para mejorar la segmentación de las imágenes en que se empalman los árboles de higos con otro tipo de hierba o árboles.

En el siguiente apartado se hace la descripción a detalle de la aplicación de los diferentes descriptores de textura, así como los resultados obtenidos de cada uno de ellos.

5.3.3 Experimentación con descriptores de textura

En esta sección se pueden observar los resultados obtenidos al aplicar descriptores de textura y color, para la extracción de características de las imágenes que se tomaron para realizar el muestreo. Hay imágenes que otorgan diferentes resultados debido a los cambios en la intensidad de luminosa, diferente perspectiva o por el contenido en las mismas.

En esta etapa se presentaron complicaciones, debido a que se trabajó con las imágenes completas, y por sus dimensiones, se generaba bastante información para su procesamiento. Además, las imágenes contenían árboles y hierba y la descripción de ambas regiones se mezclaba lo que ocasiona bastante ruido y no se obtenían características representativas para llevar a cabo el entrenamiento del clasificador. A continuación, se describe la experimentación que se llevó a cabo en esta etapa.

5.3.3.1 Descriptor Local Binary Patterns (LBP)

El objetivo de este caso fue extraer descriptores discriminantes de las regiones correspondientes a los árboles de higos y de la otra vegetación presente en las imágenes.

En el caso A3 (ver tabla 5.3) se puede observar un ejemplo de implementación del descriptor *LBP* donde se trabajó con una imagen que contenía sólo árboles de higos. Al principio, se aplicó el descriptor a la imagen original, pero causaba ruido por las características que proporcionaba. Debido a que el vector de características considera todas las intensidades presentes en la imagen.

Después de realizar varias pruebas se aplicó la técnica de *LBP* en las imágenes que se habían segmentado en las cuales existe la separación de vegetación y se aplica una máscara en color negro al fondo, obteniendo como resultado un vector de características con mayor información, debido a que todo lo que corresponde al fondo queda descartado y sólo considera la vegetación, ver caso B3.

Posteriormente, después de hacer un análisis, se decidió trabajar con las imágenes fragmentadas con dimensiones de 128 x 128 píxeles, para tomar en cuenta los cortes o fragmentos que mayor información proporcionaban. Esto se tomó en cuenta para realizar una descripción más detallada, sobre las imágenes donde existe traslape de vegetación y de esta forma lograr una clasificación satisfactoria.

Para hacer los fragmentos o cortes se implementó un sistema que facilita el proceso y se queda con aquellas zonas que contienen información y a su vez se almacena el vector en un archivo de texto.

En el caso C3 se puede observar un ejemplo de la aplicación de *LBP* en una imagen con dimensiones de 128 x 128 píxeles, esta corresponde a un fragmento de árbol de higos y en el caso D3 se muestra una imagen donde hay hierbas y tierra también con las mismas dimensiones, lo cual se estuvo trabajando para crear vectores de características tomando los valores del histograma y realizar el entrenamiento y pruebas con el clasificador Máquinas de soporte vectorial, para lograr hacer la separación de clases.

5.3.3.2 Fusión entre los descriptores medidas de Haralick y filtros Gabor

En la experimentación con el descriptor de textura medidas de *Haralick* y los filtros de *Gabor*, al principio se trabajó con las imágenes originales, pero de la misma forma que con el descriptor *LBP* se tuvo problemas, debido a que como en la descripción se tomaba en cuenta todo el espacio de representación de las imágenes (árboles y vegetación) se perdía la caracterización de la textura de la zona de interés.

En la tabla 5.4, caso A4 se muestra un ejemplo, de manera visual, de cómo se ve la información en la imagen después de aplicar los filtros *Gabor*. La imagen contiene hierba, tierra y árboles de higos, visualmente se observa que existe una separación de clases hablando en base a la textura. Pero al generar el vector de características era demasiada información y no era de gran utilidad para determinar el tipo de textura. En el caso B4 se observa un ejemplo de la aplicación de filtros *Gabor* a una de las imágenes ya segmentadas.

Posteriormente, se decidió considerar la fragmentación de imágenes (de 128 x 128 píxeles en su dimensión de cada una de las imágenes preprocesada) en las regiones donde existe traslape de hierba y árboles para realizar una descripción adecuada y obtener una separación de clases aceptable. De igual manera se almacena la información en un archivo de texto para realizar la clasificación a través de máquinas de soporte vectorial. Esta estrategia permitió obtener buenos resultados al generar vectores más pequeños y más representativos de las regiones, como se muestra en el caso C4 y D4.

Tabla 5.4 Casos A3 y B3 en los cuales se aplicó el descriptor LBP a la imagen completa y los casos C3 y D3 es la aplicación del descriptor a las imágenes de 128 x 128 píxeles.

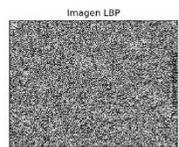
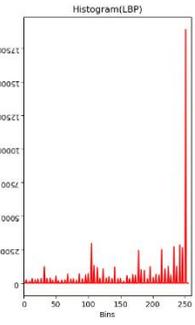
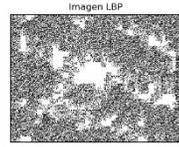
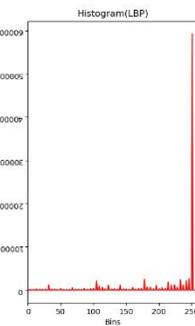
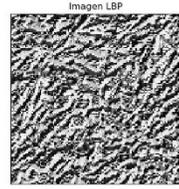
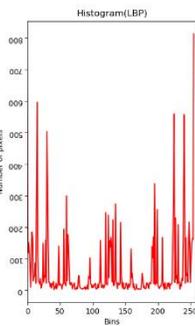
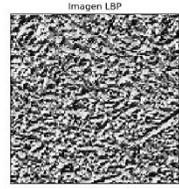
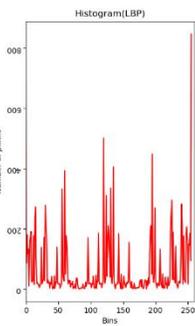
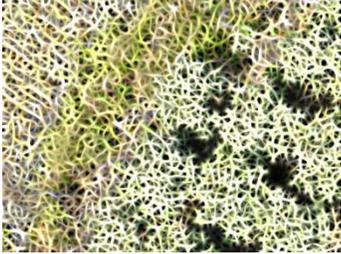
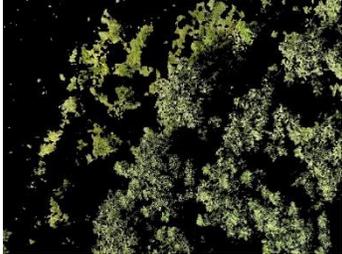
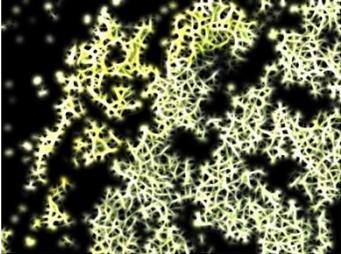
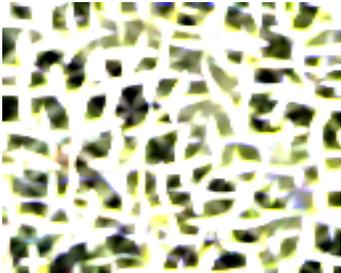
Caso	Imagen preprocesada	Aplicación de descriptor LBP		
A3				
B3				
C3				
D3				

Tabla 5.5 En los casos A4 y B4 se aplicó la combinación de los descriptores filtros de Gabor con las medidas de Haralick a toda la imagen, en los casos C4 y D4 se les aplicó a las imágenes fragmentadas de 128 x 128 píxeles.

Caso	Imagen preprocesada	Aplicación de descriptores filtros de Gabor y medidas de Haralick
A4		
B4		
C4		
D4		

Los descriptores obtenidos son almacenados en archivos de texto, que son la entrada para el algoritmo de clasificación. Se crearon archivos diferentes para las regiones correspondientes a los árboles y para las zonas de vegetación, terreno rocoso y otros objetos presentes en las imágenes.

5.3.3.3 Clasificación con Máquinas de Soporte vectorial

El objetivo de esta prueba es evaluar el rendimiento de los tres descriptores mencionados en la sección anterior. Para ello se consideró que el entrenamiento del clasificador Máquinas de Soporte Vectorial, estaría conformado por 1,938 imágenes de 128 x 128 píxeles. El conjunto de fotografías que consideran árboles de higos se integra de 1,100 y 838 son para la categoría de maleza. Para esta etapa, se consideraron imágenes que sólo se integraran de regiones disjuntas, es decir, sin empalme de las categorías, para no introducir ruido en la descripción. En la tabla 5.5 se muestran los resultados obtenidos en la etapa de entrenamiento.

Tabla 5.6 Comparación de la aplicación de los descriptores de textura aplicados en la etapa de entrenamiento.

Métrica	Medidas de Haralick	Medidas de Haralick y Filtros de Gabor	Local Binary Patterns
Accuracy	97.78%	98.54%	99.19 %
Precision	96.65%	97.89%	99.35%
Recall	96.43%	97.74%	98.66%

Como se puede apreciar en la tabla 5.5, la técnica de patrones locales binarios (*LBP*) es la que otorga los mejores resultados al momento de realizar la clasificación, alcanzando una *Accuracy* del 99.19 %, en *Precision* de 99.35% y en *Recall* 98.66. En segundo lugar, quedan, con resultados aceptables también, la descripción realizada mediante la combinación de las medidas de *Haralick* en las imágenes resultantes de los filtros Gabor. Y en tercer lugar con un buen desempeño las medidas *Haralick* obtenidas sobre las imágenes resultantes de la segmentación de *fuzzy c-means*.

Posteriormente, se evaluó el modelo obtenido, con el conjunto de evaluación conformado por 964 imágenes, de las cuales 457 pertenecen a la clase de árboles de higos y 457 a la de maleza, ver tabla 2 en el caso C2. Conjunto de datos diferente al utilizado en el entrenamiento. En esta etapa se consideró imágenes que contienen empalmes de los árboles de higos con otro tipo de vegetación. Para analizarlas, se dividieron en imágenes de 128 x 128 píxeles, para llevar a cabo un análisis con mayor detalle y poder realizar la separación de clases a través de la clasificación de información con la *MVS*. La tabla 5.6 presenta los resultados obtenidos en esta etapa de prueba.

Tabla 5.7 Comparación entre los descriptores aplicados en la etapa de prueba, con el caso de la tabla 2, C2.

Métrica	Medidas de Haralick	Medidas de Haralick y Filtros de Gabor	Local Binary Patterns
Accuracy	90.33%	91.34%	92.41 %
Precision	91.41%	92.13%	92.89%
Recall	90.13%	92.84%	92.16%

En este caso, nuevamente los patrones locales binarios otorgaron los resultados más altos al momento de realizar la clasificación, alcanzando un *Accuracy* del 92.41 % y *Precision* igual a 92.89 %. La clasificación que se realizó con la técnica de medidas de *Haralick* en combinación con filtros Gabor otorgó un *Recall* de 92.84 %. Siendo que la diferencia es mínima se puede determinar que la extracción de características es eficiente para lograr la separación de clases en las imágenes antes mencionadas.

La siguiente evaluación se llevó a cabo con las imágenes fragmentadas resultantes de las fotografías mostradas en la tabla 4 en el caso D2, las cuales son imágenes en las que aparecen árboles de higos y otro tipo de vegetación, en este caso hierba. Para este caso, se obtuvieron los siguientes resultados, en *Accuracy* un 91.41 % y en *Recall* un 91.86 %. La combinación de medidas de *Haralick* con filtros Gabor obtuvo una *Precision* del 91.89 %. Como se puede ver en la tabla 5.7, los resultados obtenidos por los otros descriptores son ligeramente menores, quedando en tercer lugar siempre las medidas de *Haralick*.

Tabla 5.8 Comparación entre los descriptores aplicados en la etapa de prueba caso D2.

Métrica	Medidas de Haralick	Medidas de Haralick y Filtros de Gabor	Local Binary Patterns
Accuracy	89.96%	90.24%	91.41 %
Precision	90.65%	91.89%	91.25%
Recall	90.33%	91.74%	91.86%

5.3.4 Evaluación de la segmentación con fuzzy c means

El objetivo de este experimento es evaluar el rendimiento del sistema en términos de la segmentación obtenida en la imagen con respecto al *ground truth* o imagen de referencia. En esta etapa se consideran ocho métricas que, en el estado del arte, se utilizan para evaluar la segmentación. En este caso, se utilizó el subconjunto de imágenes del conjunto original que cuentan con su imagen de referencia.

Las imágenes presentadas a continuación son un ejemplo de las utilizadas, cada una de ellas contiene diferentes aspectos que hacen que la etapa de segmentación sea difícil de llevar a cabo de manera correcta y completa, como lo son las diferencias en la iluminación, cambios en la escala y perspectiva, ruido, artefactos presentes y empalme con otro tipo de vegetación ajena a la de interés, etc.

En la figura 5.4 se puede ver la imagen original, su segmentación y el *ground truth*. Esta imagen es un ejemplo de aquellas con las mejores condiciones, ya que contiene solamente árboles de higos.

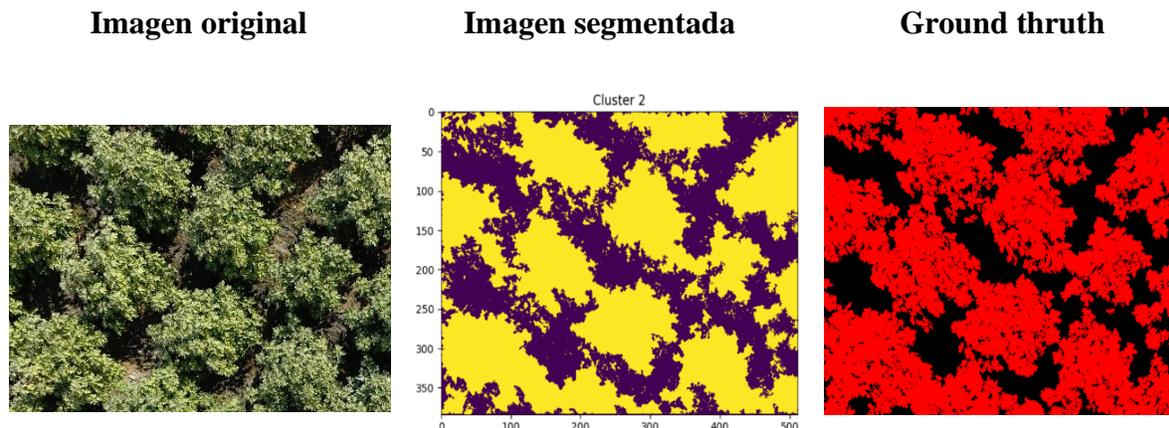


Figura 5.4 Imágenes del *Ground truth* elaboradas por el grupo de trabajo de la Universidad del Estado de Morelos.

Las métricas que se utilizaron miden la similitud entre las imágenes como lo es el coeficiente *Jaccard*, *probabilistic rand index*, *sensitivity*, *specifity*, *precision* y *accuracy*, otras miden distancia como *variation of information*, en la tabla 5.8 se observan los resultados que se obtuvieron al aplicar estas métricas entre la imagen segmentada y la de referencia.

En términos generales, los resultados obtenidos muestran que la diferencia entre ambas imágenes es mínima, la mayoría de las métricas tienen resultados mayores a un 88%, por ejemplo, en la métrica de VOI, se alcanza 0.947%, por lo que se considera que en este tipo de imágenes se logra una buena segmentación de los árboles de higos.

Tabla 5.8 Métricas aplicadas para evaluar la segmentación de la imagen 036.jpg.

Métricas	Resultado de segmentación aplicada a la imagen 036.jpg	Segmentación de referencia ground truth
Jaccard Coefficient	0.842890	1
Probabilistic Rand Index (PRI)	0.869551	1
Variation of Information (VOI)	0.947723	1
Sensitivity	0.886514	1
Specificity	0.920117	1
Precision	0.961336	1
Accuracy	0.887009	1

En la figura 5.5 se muestra una imagen que contiene árboles de higos y un poco de sombra y terreno, pero la iluminación y la perspectiva son diferentes a la imagen anterior. Estos factores complican el proceso de segmentación. En la tabla 5.9 se pueden observar los resultados obtenidos de la segmentación a través de las métricas que permiten evaluar la misma.

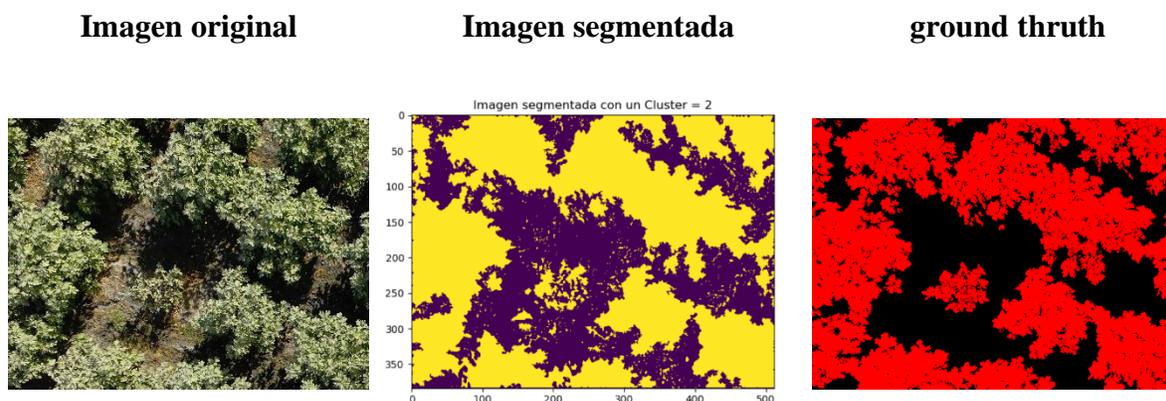


Figura 5.5 Se presenta la imagen original 083.jpg, el resultado de su segmentación con *fuzzy c-means* y el *ground truth*.

Tabla 5.9 Métricas para evaluar la segmentación de la imagen 083.jpg.

Métricas	Resultado de segmentación aplicada a la imagen 083.jpg	Segmentación de referencia ground truth
Jaccard Coefficient	0.859065	1
Probabilistic Rand Index (PRI)	0.847236	1
Variation of Information (VOI)	0.932610	1
Sensitivity	0.888026	1
Specificity	0.954956	1
Precision	0.963426	1
Accuracy	0.916675	1

Como se puede observar en los valores resultantes, la segmentación obtenida fue buena, incluso con valores más altos que la lograda con la imagen 036. Con un *Global Consistency Error* de 0.157 y una *Variation of Information* de 0.93%, superando las expectativas iniciales.

En la figura 5.6 se presenta el resultado de la segmentación de otro tipo de imagen (denominada 0101.jpg) que incluye otro tipo de vegetación al de interés, pero no se empalma con los árboles de higos. Sin embargo, la separación del tono verde a través del algoritmo *fuzzy c means* no se logra al 100%, por lo que se obtiene ruido.

Para este tipo de imágenes es necesario el identificar las regiones a través de los descriptores de textura y contemplar el resultado que más sea conveniente para el usuario. Para esta prueba, se realiza la comparación resultante de la clasificación de las regiones de 128 x 128 que conforman la imagen original.

En la tabla 5.10 se observan los resultados arrojados al aplicar las métricas de evaluación y el descriptor LBP.

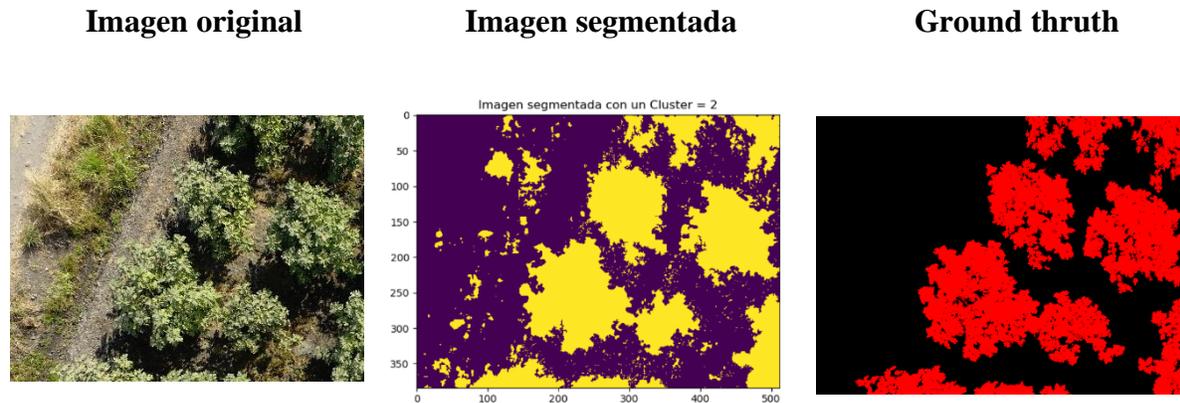


Figura 5.6 Se presenta la imagen original 0101.jpg, el resultado de su segmentación con fuzzy c-means y el *ground truth*.

Tabla 5.10 Métricas para evaluar la segmentación de la imagen 0101.jpg.

Métricas	Resultado de segmentación aplicada a la imagen 0101.jpg	Segmentación de referencia ground truth
Jaccard Coefficient	0.809119	1
Probabilistic Rand Index (PRI)	0.843823	1
Variation of Information (VOI)	0.851834	1
Sensitivity	0.901623	1
Specificity	0.921142	1
Precision	0.881506	1
Accuracy	0.914623	1

Como puede observarse, los resultados son buenos, pero con valores menores a los alcanzados en las imágenes anteriores. En este caso, el error no es alto, obteniendo una *Variation of Information* de 85%. Con estos resultados ligeramente más bajos se puede concluir que el traslape que existe entre las regiones presentes en la imagen se logra eliminar, identificando las zonas en un 91% (de acuerdo con el *accuracy*).

En la figura 5.7 se puede observar otro tipo de imagen la cual se integra de vegetación que se empalma con los árboles de higos, así como terreno rocalloso. Los factores mencionados anteriormente perjudican la segmentación que se lleva a cabo, haciéndola aún más difícil de obtener de manera correcta. En este

tipo de imágenes se realiza una segmentación con mayor detalle, realizándose en ventanas de 128x128 píxeles. En la tabla 5.11 se muestran los resultados al calcular las métricas para evaluar la segmentación.

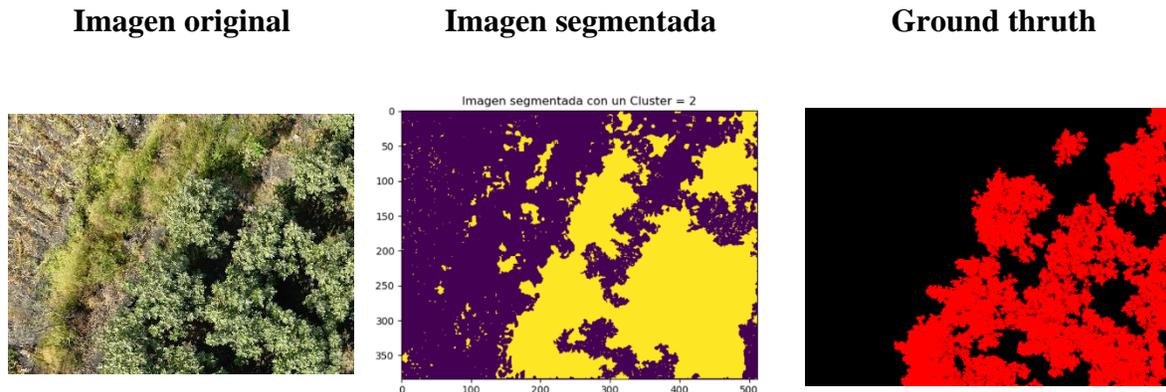


Figura 5.7 Se presenta la imagen original 010.jpg, el resultado de su segmentación con *fuzzy c-means* y el *ground thruth*.

Como se puede observar, la captura de las imágenes en un ambiente no controlado afecta notablemente la obtención de una buena aproximación hacia la segmentación de referencia, que en este caso es el *ground truth*. Para este ejemplo no se logra una separación completa entre la región traslapada. En la tabla 5.11 se puede ver que los valores alcanzados por las métricas son menores a los antes obtenidos. Esto permite realizar una comparación en detalle de los resultados obtenidos.

Finalmente, se puede concluir que en aquellas imágenes en las cuales sólo hay árboles de higos, la segmentación lograda por el sistema es aceptable de acuerdo con las métricas de segmentación y con la imagen de referencia. Sin embargo, cuando las imágenes contienen cambios en la perspectiva, iluminación o hay presencia de sombras y terreno la segmentación es más difícil. Pero la segmentación más compleja es aquella en donde los árboles se empalman con otro tipo de vegetación, En este caso, el utilizar descriptores de textura es una buena opción. No obstante, se cree conveniente realizar un análisis más a detalle en las zonas de borde entre las regiones, con ventanas más pequeñas de 128, para tener una mayor precisión en la clasificación y con ello en la segmentación.

También se puede concluir que de la técnica *LBP* es la que mejor describe la textura de los árboles, seguido por la combinación de filtros *Gabor* y las medidas de *Haralick*, confirmando su extenso uso en la literatura del área. Y como se desconoce las características presentes en la imagen, el sistema desarrollado lleva a cabo todas las etapas mostradas de manera automática.

Tabla 5.11 Métricas para evaluar la segmentación de la imagen 010.jpg.

Métricas	Resultado de segmentación aplicada a la imagen 010.jpg	Segmentación de referencia ground truth
Jaccard Coefficient	0.782650	1
Probabilistic Rand Index (PRI)	0.834198	1
Variation of Information (VOI)	0.839393	1
Sensitivity	0.905153	1
Specificity	0.869626	1
Precision	0.817092	1
Accuracy	0.883535	1

Capítulo 6 . Conclusiones

5.1 Introducción

De acuerdo al desarrollo del trabajo que se llevó a cabo en este tema de tesis, en este capítulo se revisa el cumplimiento de los objetivos: general y específicos, planteados al inicio de esta investigación. Además, se muestran las conclusiones sobre los resultados obtenidos en la experimentación, así como las aportaciones y los trabajos futuros en base a este proyecto de tesis.

5.2 Objetivos alcanzados

El objetivo principal planteado en la propuesta de tesis y que se pueden observar en el capítulo 1, es el siguiente:

“Desarrollar e implementar un sistema de visión artificial que realice la detección automática de la zona correspondiente a árboles de higos, a partir del análisis de imágenes aéreas adquiridas con drones.”

El objetivo de esta tesis fue cumplido, debido a que se llevó a cabo el diseño y desarrollo del sistema de visión artificial, que realiza la segmentación para realizar la detección de zonas en las que existen árboles de higos en un análisis de imágenes aéreas correspondientes a plantaciones de higos, las cuales fueron adquiridas con un *dron*. Para ello, se revisó el estado del arte y se implementaron diferentes técnicas encontrando que la mejor opción para el preprocesamiento es la transformación de color *RGB-HSV* y en especial se trabajó con el canal *H* y el agrupamiento de las regiones presentes en la imagen mediante el algoritmo *fuzzy c-means* para realizar la segmentación. Además, se implementaron y utilizaron tres de los diferentes descriptores de textura para llevar a cabo la identificación de las regiones empalmadas y poder lograr una segmentación más precisa en los bordes de los árboles y la vegetación. La implementación de estas técnicas permitió el desarrollo del sistema de visión artificial para la segmentación de imágenes aéreas.

En la tabla 6.1 se pueden observar los objetivos específicos planteados para este tema de tesis, así como el cumplimiento de los mismos. En la tabla 6.2 se muestran los alcances propuestos y los reales.

Tabla 6.1 Descripción de objetivos específicos y la solución que se implementó para cada uno.

Objetivo Específico	Solución del Objetivo
<p>Estudiar y analizar diferentes algoritmos de segmentación de imágenes.</p>	<p>Se estudió y analizó un conjunto de 40 artículos, los cuales fueron de gran utilidad para seleccionar e implementar algoritmos aplicados para realizar la segmentación de imágenes. Algunos de los algoritmos que se analizaron fueron:</p> <ul style="list-style-type: none"> • Mean shift • K-Means • SLIC • Graph Cut • Fuzzy C-Means <p>Al realizar el análisis del comportamiento de cada uno de los algoritmos, se optó por trabajar con algoritmos de agrupamiento, debido a que en ellos todo depende de las características que se presentan en las imágenes que se desean segmentar y fueron los que mejor se comportaban al hacer la segmentación en el sistema.</p>
<p>Implementar un algoritmo de segmentación de imágenes que permita segmentar la zona correspondiente a árboles de higos en imágenes aéreas.</p>	<p>En la implementación del algoritmo para realizar la segmentación, en un inicio se estuvo trabajando con k-means, pero debido a que no se logró la robustez deseada y a su gran consumo computacional quedó descartado. Después de hacer un análisis e investigación se implementó el algoritmo Fuzzy C-Means siendo el que mejor segmentación proporcione.</p>
<p>Adquisición de imágenes</p>	<p>Fue proporcionado un conjunto de 130 imágenes aéreas de árboles de higos, cuyas dimensiones son 1500 x 2000 píxeles en formato RGB. En dicho conjunto hay imágenes con diferente intensidad luminosa, cambios de perspectiva, escala y, en varias, se empalman los árboles de higos con otro tipo de vegetación.</p> <p>También fue proporcionado un conjunto de imágenes pertenecientes al <i>ground truth</i>, las cuales fueron elaboradas por expertos de la Universidad Autónoma del Estado de Morelos (UAEM).</p>
<p>Estudiar y analizar diferentes descriptores de textura y color basados en imágenes.</p>	<p>En esta etapa se hizo un estudio de diversos descriptores de color y de textura, para hacer la selección e implementación de los descriptores. Posteriormente, se realizó una comparación de los resultados obtenidos por cada descriptor.</p> <p>Los descriptores seleccionados e implementados son:</p> <ul style="list-style-type: none"> • Filtros de Gabor • Medidas de Haralick • Local Binary Patterns <p>Después de la experimentación se puede concluir que el descriptor Local Binary Patterns, proporciona un buen conjunto de características descriptivas para realizar la clasificación de las regiones presentes en las imágenes y de esta manera obtener resultados aceptables.</p>

<p>Definir las características que permitan la descripción e identificación de la región correspondiente a árboles de higos.</p>	<p>En la etapa de representación y descripción, se realizó un análisis e investigación de los diferentes descriptores basados en color y textura, para abordar el problema que surgió con imágenes donde existe aparte de los árboles de higos otro tipo de vegetación. En primera instancia se hizo un análisis de la imagen; posteriormente se realizó una partición de la imagen original en segmentos de 128 x 128 píxeles formando un conjunto de 1,938 imágenes por cada una de las mismas para realizar la descripción y clasificación de la información generada a través del clasificador Máquinas de Soporte Vectorial.</p>
---	---

Tabla 6.2 Alcances propuestos y reales.

Alcances propuestos	Alcances reales
<p>Se realiza la segmentación automática de áreas correspondientes a árboles de higos, independientemente de la edad del árbol.</p>	<p>Se realiza la segmentación de manera automática al aplicar en la etapa de segmentación el algoritmo de agrupamiento <i>Fuzzy c-means</i>, la descripción de las regiones mediante descriptores de textura que ayudan a identificar las regiones correspondientes al objeto de interés.</p>
<p>El sistema es capaz de segmentar las zonas correspondientes a árboles de higos, descartando áreas correspondientes a pasto, tierra, sombras y otros objetos presentes en la imagen.</p>	<p>El sistema de visión artificial cuenta con la capacidad de localizar la zona correspondiente a árboles de higos, lo cual hace que se forme una zona homogénea y de esta manera se descarten áreas correspondientes a tierra, pasto, sombras u otros objetos presentes en las imágenes analizadas.</p>
<p>El sistema de visión artificial es capaz de trabajar con imágenes adquiridas con diferentes intensidades luminosas.</p>	<p>Como se presenta en la etapa de experimentación, se puede observar que el sistema cuenta con la capacidad de trabajar con imágenes que cuentan con diversas intensidades luminosas, así como diferentes cambios en la perspectiva.</p>
<p>El desarrollo del sistema se realizará en C/C++ usando Eclipse y las bibliotecas de desarrollo OpenCV.</p>	<p>El desarrollo del sistema de visión artificial se llevó a cabo con la implementación de las herramientas de software como <i>Python</i> en su versión 2.7 y 3.7, así como todo su kit de herramientas, la librería de visión artificial <i>OpenCV</i> y <i>PyQt</i> para la parte de la interfaz gráfica.</p>

5.3 Aportaciones

A continuación, presentan las aportaciones que se generaron a través del desarrollo de este tema de investigación.

- Una de las aportaciones es la metodología que se propuso para dar solución a este tema de tesis, la cual permitió identificar para cada etapa los métodos adecuados para solucionar el problema propuesto.
- Se presenta una evaluación de tres de los algoritmos de descripción de textura con mejores resultados de acuerdo a la literatura, así como la combinación de dos de ellos para trabajar con vegetación y de esta forma mejorar el sistema de visión artificial desarrollado.
- La metodología propuesta permite la segmentación de manera automática de imágenes aéreas de árboles, aun cuando existen cambios en la perspectiva, iluminación y escala; obteniendo resultados favorables, como se puede ver en la experimentación.

5.4 Conclusiones

Como se ha podido observar se ha mostrado que la combinación de diferentes técnicas ha permitido lograr una segmentación de imágenes adecuada para imágenes en color de alta resolución capturadas por un dron. Los resultados muestran que es posible localizar las regiones pertenecientes a los árboles de higos a pesar de que existan cambios en la intensidad luminosa, además una variabilidad de escala y la presencia objetos u otro tipo de vegetación ajena a la de interés.

De acuerdo con los resultados obtenidos, se ha establecido que la segmentación es buena en imágenes donde sólo hay presencia de árboles de higos, dando como resultado 0.869551 utilizando la métrica de evaluación *Probalilistic Rand Index (PRI)*, con *Variation of Information (VOI)* se obtiene 0.947723 y al aplicar *Jaccard Coefficient* se pudo obtener 0.842890.

En aquellas imágenes donde existe otro tipo de vegetación, se realiza un análisis de la imagen y se utiliza el descriptor de textura *LBP* para extraer un vector de características y posteriormente realizar la clasificación a través de ayuda del clasificador *MVS*, obteniendo como resultado una exactitud del 92.41% al hacer la clasificación en el proceso de prueba y de esta manera realizar la separación de clases.

En aquellas imágenes donde se empalman los árboles con otro tipo de vegetación, los resultados de comparar la localización de regiones respecto al *ground truth* son los siguientes: *Probalilistic Rand Index (PRI)* es 0.834198, con *Variation of Information (VOI)* es 0.839393 y al aplicar *Jaccard Coefficient* 0.782650. Se consideran aceptables los valores obtenidos para este caso, ligeramente menores a los anteriores. Sin embargo, se sigue teniendo problema en los bordes donde se mezclan las regiones, se cree conveniente el hacer un análisis más detallado en esa zona, con ventanas pequeñas.

No obstante, es necesario seguir investigando sobre el tema, debido a que existen imágenes donde hay otro tipo de vegetación, la segmentación no es adecuada por el empalme que existe entre los árboles de higos y cualquier otra clase de hierba.

5.5 Trabajos futuros

Durante el proceso de la investigación y el desarrollo del sistema de visión artificial para la segmentación de imágenes aéreas se detectaron algunos puntos de interés que se enlistan a continuación, los cuales se pueden tomar en cuenta para trabajos futuros:

- Adicionar o implementar un sistema de visión artificial que a través de la segmentación realizada se pueda realizar el conteo de los árboles presentes en las imágenes analizadas y la conservación de los mismos.
- Llevar a cabo el monitoreo de estas plantaciones y verificar el estado de salud en que se encuentran los árboles de higos, así como la falta de algún fertilizante o la parte de fertirrigación.
- Adicionar un sistema de visión que permita determinar la edad de los árboles de higos y la etapa de maduración.

5.5 Productos adicionales académicos

- Participación en el 1er coloquio “Artificial Intelligence” como ponente de la conferencia denominada: “Segmentación de Árboles de Higos en imágenes Aéreas, mediante Visión Artificial”, el cual se llevó a cabo en el Instituto Tecnológico de Iguala en mayo 2019, así mismo se hizo la presentación del póster que fue requerido para el evento.
- Participación en “2019 IEEE Summer School on Computational Intelligence and Robotics” con el artículo que lleva por título “Segmentación de Árboles de Higos en imágenes Aéreas, mediante Visión Artificial”, el evento se llevó a cabo en la Universidad Tecnológica de Emiliano Zapata (UTEZ), ubicada en Cuernavaca Morelos, en octubre de 2019.
- Participación en la escuela de Inteligencia Artificial (IA) los días 25 y 26 de octubre de 2018, con la presentación del poster que lleva por título “Segmentación de Árboles de Higos en imágenes Aéreas, mediante Visión Artificial”, la cual se llevó a cabo en el centro de convenciones ubicado en el hotel Holiday Inn Cuernavaca Morelos.
- Participación en la 1er Jornada de Ciencia y Tecnología Aplicada, los días 15 y 16 de noviembre de 2018, con la presentación del poster que lleva por título “Segmentación de Árboles de Higos en imágenes Aéreas, mediante Visión Artificial”, la cual se llevó a cabo en el Centro Nacional de Investigación y Desarrollo Tecnológico, ubicado en Cuernavaca Morelos.

Segmentación de Árboles de Higos en Imágenes Aéreas, mediante Visión Artificial.

- Participación en el Concurso de Proyectos de Innovación los días 28 y 29 de noviembre de 2018, con la presentación del proyecto de investigación que lleva por título “Segmentación de Árboles de Higos en imágenes Aéreas, mediante Visión Artificial”, la cual se llevó acabo en el centro de convenciones ubicado en el hotel Holiday Inn Cuernavaca Morelos.

Referencias

- Arif, M. S. M., Gülch, E., Tuhtan, J. A., Thumser, P., & Haas, C. (2017). An investigation of image processing techniques for substrate classification based on dominant grain size using RGB images from UAV. *International Journal of Remote Sensing*, 38(8–10), 2639–2661. <https://doi.org/10.1080/01431161.2016.1249309>
- Ariza, A., Salas, J., & Javiersalasuahes, D. H. M. E. (2005). ANÁLISIS COMPARATIVO ENTRE LOS NIVELES DE SEVERIDAD EN INCENDIOS FORESTALES Y LAS MEDIDAS DE TEXTURA DE IMÁGENES DE SATÉLITE ALEXANDER ARIZA* y FRANCISCO JAVIER SALAS REY** Departamento de Geografía. Universidad de Alcalá. 1–26.
- Bezdek, J. C., Ehrlich, R., & Full, W. (1984). FCM: The fuzzy c-means clustering algorithm. *Computers and Geosciences*, 10(2–3), 191–203. [https://doi.org/10.1016/0098-3004\(84\)90020-7](https://doi.org/10.1016/0098-3004(84)90020-7)
- Bai, X., Cao, Z., Wang, Y., Yu, Z., Hu, Z., Zhang, X., & Li, C. (2014). Vegetation segmentation robust to illumination variations based on clustering and morphology modelling. *Biosystems Engineering*, 125(October 2017), 80–97. <https://doi.org/10.1016/j.biosystemseng.2014.06.015>
- Bustince, H., Barrenechea, E., Pagola, M., Fernandez, J., Xu, Z., Bedregal, B., ... De Baets, B. (2016). A historical account of types of fuzzy sets and their relationships. *IEEE Transactions on Fuzzy Systems*, 24(1), 179–194. <https://doi.org/10.1109/TFUZZ.2015.2451692>
- Bosilj, P., Duckett, T., & Cielniak, G. (2018). Connected attribute morphology for unified vegetation segmentation and classification in precision agriculture. *Computers in Industry*, 98, 226–240. <https://doi.org/10.1016/j.compind.2018.02.003>
- Caballero, R., Berbey, A., & Cogley, A. (2018). Segmentación de Imágenes Basada en Entropía de Pixel (Vol. 2018, pp. 523–531). <https://doi.org/10.18502/keg.v3i1.1456>
- Campos, Yerania, Humberto Sossa, and Gonzalo Pajares. 2017. “Comparative Analysis of Texture Descriptors in Maize Fields with Plants, Soil and Object Discrimination.” *Precision Agriculture* 18(5): 717–35.
- Capitaine, H. Le, & Frélicot, C. (2011). A Fast-Fuzzy C-means Algorithm for Color Image Segmentation. *Eusflat-Lfa*, (July).
- Cerón-Esparza, J., París, S., Nakano-Miyatake, M., & Robles-Camarillo, D. (2016). Segmentación de Imágenes por Intensidad de Color Mediante Método Iterativo Basado en Superpíxeles y Fuzzy C-Means. *Simposio Iberoamericano Multidisciplinario de Ciencias e Ingenierías*, (October).
- Chaira, T. (2011). A novel intuitionistic fuzzy C means clustering algorithm and its application to medical images. *Applied Soft Computing Journal*, 11(2), 1711–1717. <https://doi.org/10.1016/j.asoc.2010.05.005>
- Chen, C., Zhou, L., Guo, J., Li, W., Su, H., & Guo, F. (2015). Gabor-Filtering-Based Completed Local Binary Patterns for Land-Use Scene Classification. *Proceedings - 2015 IEEE International Conference on Multimedia Big Data, BigMM 2015*, 324–329. <https://doi.org/10.1109/BigMM.2015.23>
- Colmenares, G. (2012). *Inteligencia Artificial Máquinas de Vectores de Soporte* Capítulo IV Gerardo Colmenares. 1–11.
- Chromaticity Features of Colors.” *Pattern Analysis and Applications* (0123456789). <https://doi.org/10.1007/s10044-018-0729-9>

Dornaika, F., Moujahid, A., Merabet, Y. El, & Ruichek, Y. (2017). Chapter 32 - A Comparative Study of Image Segmentation Algorithms and Descriptors for Building Detection. In Handbook of Neural Computation (1st ed.). <https://doi.org/10.1016/B978-0-12-811318-9.00032-6>

Dubey, S. R., Singh, S. K., & Singh, R. K. (2016). Multichannel decoded local binary patterns for content-based image retrieval. IEEE Transactions on Image Processing, 25(9), 4018–4032. <https://doi.org/10.1109/TIP.2016.2577887>

Felipe, V. (2014). Descriptores visuales de MPEG-7 empleando la GPU, segunda conferencia de computación y sistemas, (October), recuperado de https://www.researchgate.net/publication/266387924_Descriptores_Visuales_de_MPEG-7_empleando_la_GPU

García-Lamont, Farid, Jair Cervantes, Asdrúbal López-Chau, and Arturo Yee-Rendón. 2018. "Automatic Computing of Number of Clusters for Color Image Segmentation Employing Fuzzy C-Means by Extracting.

Garcia-Lamont, F., Cervantes, J., López, A., & Rodriguez, L. (2018). Segmentation of images by color features: A survey. Neurocomputing, 292, 1–27. <https://doi.org/10.1016/j.neucom.2018.01.091>

Guido Van Rossum. (1991). Python software Foundation. Recuperado de <https://www.python.org/downloads/>

Herrera-Aguilar, I., Sandoval-González, O. O., Malagón González, F., Águila-Rodríguez, G., González-Sánchez, B. E., & Flores-Cuautle, J. J. A. (2017). SISTEMA AUTOMÁTICO DE SELECCIÓN DE LIMÓN (Citrus Latifolia Tanaka) BASADO EN DISCRIMINACIÓN POR COLOR. AUTOMATIC SYSTEM FOR LIME SELECTION (Citrus Latifolia Tanaka) BASED ON COLOR DISCRIMINATION., 10(10), 73–78. Retrieved from <http://search.ebscohost.com/login.aspx?direct=true&db=fap&AN=126549195&site=ehost-live>

Hoang, V. T., Porebski, A., Vandenbroucke, N., & Hamad, D. (2017). LBP Histogram Selection based on Sparse Representation for Color Texture Classification. Proceedings of the 12th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications, (Visigrapp), 476–483. <https://doi.org/10.5220/0006128204760483>

Intel. (2000). OpenCV Team 2019. Recuperado de https://sourceforge.net/projects/opencvlib/rary/files/4.2.0/opencv-4.2.0-vc14_vc15.exe/download

Issn, P. (2005). LAS MÁQUINAS DE SOPORTE VECTORIAL (SVMs). (27), 67–72.

Jia, S., Member, S., Deng, B., Zhu, J., Jia, X., Member, S., & Li, Q. (2018). Local Binary Pattern-Based Hyperspectral Image Classification with Superpixel Guidance, 56(2), 749–759.

Mújica-Vargas, D., Gallegos-Funes, F. J., & Rosales-Silva, A. J. (2013). A fuzzy clustering algorithm with spatial robust estimation constraint for noisy color image segmentation. Pattern Recognition Letters, 34(4), 400–413. <https://doi.org/10.1016/j.patrec.2012.10.004>

Lan, R., Zhou, Y., & Tang, Y. Y. (2015). Quaternionic Local Ranking Binary Pattern: A Local Descriptor of Color Images. IEEE Transactions on Image Processing: A Publication of the IEEE Signal Processing Society, 25(2), 566–579. <https://doi.org/10.1109/TIP.2015.2507404>

Latifi, H., Fassnacht, F. E., Müller, J., Tharani, A., Dech, S., & Heurich, M. (2015). Forest inventories by LiDAR data: A comparison of single tree segmentation and metric-based methods for inventories of a heterogeneous temperate forest. International Journal of Applied Earth Observation and Geoinformation, 42, 162–174. <https://doi.org/10.1016/j.jag.2015.06.008>

Segmentación de Árboles de Higos en Imágenes Aéreas, mediante Visión Artificial.

- LEAL, A. C. P. (2006). Segmentación de imágenes por textura. Universidad de Concepción Facultad de Ingeniería Departamento de Ingeniería Eléctrica.
- Ledoux, A., Losson, O., & Macaire, L. (2016). Color local binary patterns: compact descriptors for texture classification. *Journal of Electronic Imaging*, 25(6), 061404. <https://doi.org/10.1117/1.JEI.25.6.061404>
- Li, W., Chen, C., Su, H., & Du, Q. (2015). Local Binary Patterns and Extreme Learning Machine for Hyperspectral Imagery Classification. *IEEE Transactions on Geoscience and Remote Sensing*, 53(7), 3681–3693. <https://doi.org/10.1109/TGRS.2014.2381602>
- Peyret, R., Bouridane, A., Khelifi, F., Tahir, M. A., & Al-Maadeed, S. (2018). Automatic classification of colorectal and prostatic histologic tumor images using multiscale multispectral local binary pattern texture features and stacked generalization. *Neurocomputing*, 275, 83–93. <https://doi.org/10.1016/j.neucom.2017.05.010>
- Presutti, M. (2004). LA MATRIZ DE CO-OCURRENCIA EN LA CLASIFICACIÓN MULTIESPECTRAL: TUTORIAL PARA LA ENSEÑANZA DE MEDIDAS TEXTURALES EN CURSOS DE GRADO UNIVERSITARIO. Miriam Presutti In this work a tutorial to teach textural measures in satellite imagery.
- Rosebrock A. (2015). PyImageSearch, Local Binary Patterns with Python & OpenCV. Recuperado de: <https://www.pyimagesearch.com/2015/12/07/local-binary-patterns-with-python-opencv/>
- Rasti, P., Daneshmand, M., & Anbarjafari, G. (2017). Statistical approach-based iris recognition using local binary pattern. *Dyna (Spain)*, 92(1), 76–81. <https://doi.org/10.6036/7997>
- Rafael, E., & Dom, O. (2015). Nuevo Esquema para la Clasificación Automática de Expresiones Faciales Empleando Métodos de Representación Dispersa Eloy Rafael Oliveros Domínguez Trabajo de diploma.
- Ren, M., & Zemel, R. S. (2016). End-to-End Instance Segmentation with Recurrent Attention, 6656–6664.
- Riomoros, M. I. (2016). Tesis doctoral “Segmentación automática de texturas en imágenes agrícolas.” UNIVERSIDAD COMPLUTENSE DE MADRID.
- Riverbank Computing. (2009) Riverbank Computing Limited. Recuperado de <https://www.riverbankcomputing.com/software/pyqt/download5>
- SALGADO ESCOBAR, G. (2009). Segmentación de imágenes degradadas con ruido utilizando algoritmos difusos. Instituto Politécnico Nacional Escuela Superior De Comercio Y Administración Sección De Estudios De Posgrado E Investigación Unidad Santo Tomás.
- Sucar, L. E., & Gómez, G. (2011). *Vision Computacional*. Instituto Nacional de Astrofísica, Óptica y Electrónica, 185. Retrieved from <http://ccc.inaoep.mx/~esucar/Libros/vision-sucar-gomez.pdf>
- Singh, C., Walia, E., & Kaur, K. P. (2018). Color texture description with novel local binary patterns for effective image retrieval. *Pattern Recognition*, 76, 50–68. <https://doi.org/10.1016/j.patcog.2017.10.021>
- Tadic, V., Popovic, M., & Odry, P. (2016). Engineering Applications of Artificial Intelligence Fuzzy Filter for license plate detection. 48, 40–58. <https://doi.org/10.1016/j.engappai.2015.09.009>
- Urdal, J., Engan, K., Kvikstad, V., & Jansseny, E. A. M. (2017). Prognostic prediction of histopathological images by local binary patterns and RUSBoost. 25th European Signal Processing Conference, EUSIPCO 2017, 2017–January, 2349–2353. <https://doi.org/10.23919/EUSIPCO.2017.8081630>

Segmentación de Árboles de Higos en Imágenes Aéreas, mediante Visión Artificial.

Verma, M., Raman, B., & Murala, S. (2015). Local extrema co-occurrence pattern for color and texture image retrieval. *Neurocomputing*, 165, 255–269. <https://doi.org/10.1016/j.bandl.2015.08.004>

Wang, X., Tang, Y., Masnou, S., & Chen, L. (2015). A Global/Local Affinity Graph for Image Segmentation. *IEEE Transactions on Image Processing*, 24(4), 1399–1411. <https://doi.org/10.1109/TIP.2015.2397313>

Xess, M., & Agnes, S. A. (2014). Analysis of Image Segmentation Methods Based on Performance Evaluation Parameters. 68–75.

Xu, Z. (2012). Intuitionistic fuzzy aggregation and clustering. *Studies in Fuzziness and Soft Computing* (Vol. 279). https://doi.org/10.1007/978-3-642-28406-9_1

Yao, W., Krzystek, P., & Heurich, M. (2012). Tree species classification and estimation of stem volume and DBH based on single tree extraction by exploiting airborne full-waveform LiDAR data. *Remote Sensing of Environment*, 123, 368–380. <https://doi.org/10.1016/j.rse.2012.03.027>

Zhang, H., Fritts, J. E., & Goldman, S. A. (2008). Image Segmentation Evaluation: A Survey of Unsupervised Methods.

Anexos

Anexo A. Participación en el 1er coloquio “Artificial Intelligence”, 2019



SEP
SECRETARÍA DE
EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

EL TECNOLÓGICO NACIONAL DE MÉXICO A TRAVÉS DEL INSTITUTO TECNOLÓGICO DE IGUALA

OTORGA EL PRESENTE

RECONOCIMIENTO

A

EDUARDO GONZÁLEZ SÁNCHEZ

POR SU DESTACADA PARTICIPACIÓN COMO **PONENTE** DE LA CONFERENCIA DENOMINADA: **“SEGMENTACIÓN DE ÁRBOLES DE HIGOS EN IMÁGENES AÉREAS, MEDIANTE VISIÓN ARTIFICIAL”** EN EL MARCO DEL **1er COLOQUIO “ARTIFICIAL INTELLIGENCE”**, REALIZADO EN EL INSTITUTO TECNOLÓGICO DE IGUALA.

IGUALA, GRO., A 9 DE MAYO DE 2019 .



“TECNOLOGÍA COMO SÍNÓNIMO DE INDEPENDENCIA”

SECRETARÍA DE
EDUCACIÓN PÚBLICA
INSTITUTO
TECNOLÓGICO DE
IGUALA
DIRECCIÓN

M.D.I.S. ARELI BARCENAS NAVA
DIRECTORA



Anexo B. Participación en “2019 IEEE Summer School on Computational Intelligence and Robotics”



ICMEAE
INTERNATIONAL CONFERENCE ON MECHATRONICS, ELECTRONICS AND AUTOMOTIVE ENGINEERING

El Centro de Investigación en Ingeniería y Ciencias Aplicadas de la Universidad Autónoma del Estado de Morelos y El Instituto de Ingenieros Electrónicos y Eléctricos de Morelos A.C.

otorgan el presente

RECONOCIMIENTO

A: **Eduardo González Sánchez**

Por su destacada participación como: **Concursante:**

En la categoría Innovación en el Advanced Robotics and Drone Competition.

En el marco del Congreso Internacional de Ingeniería Mecatrónica, Electrónica y Automotriz realizado del 27 al 30 de Noviembre del 2018 en la ciudad de Cuernavaca, Morelos, México.



Ing. Leoncio Aguilar Negrete
Presidente del Instituto de Ingenieros Electrónicos y Eléctricos de Morelos A.C.



Dra. Elsa Carmina Menchaca Campos
Directora Interina del Centro de Investigación en Ingeniería y Ciencias Aplicadas.



Anexo C. Participación en la escuela de Inteligencia Artificial (IA), octubre de 2018

UNIVERSIDAD TECNOLÓGICA
EMILIANO ZAPATA DEL ESTADO DE MORELOS
ORGANISMO PÚBLICO DESCENTRALIZADO DEL GOBIERNO DEL ESTADO DE MORELOS

otorga el presente

RECONOCIMIENTO

A: Eduardo González Sánchez

Por su participación como ponente de la conferencia
"Segmentación de árboles de higos en imágenes aéreas,
mediante Visión Artificial"

en el marco del evento: Escuela de Inteligencia Artificial y Robótica 2018,
llevado a cabo en las instalaciones de esta Universidad Tecnológica,
del 25 al 27 de octubre del presente año.

Emiliano Zapata, Mor, octubre de 2018



M. en C. Jaime Vázquez Colín
Director de la División Académica de
Mecánica Industrial



Anexo D. Participación 1er Jornada de Ciencia y Tecnología Aplicada, noviembre de 2018



EL TECNOLÓGICO NACIONAL DE MÉXICO
OTORGA LA PRESENTE

CONSTANCIA

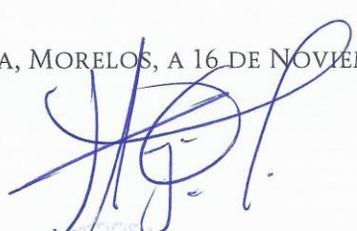
A

EDUARDO GONZÁLEZ SÁNCHEZ, ANDREA MAGADÁN SALAZAR

POR SU PARTICIPACIÓN CON EL PÓSTER:

**SEGMENTACIÓN DE ÁRBOLES DE HIGO EN IMÁGENES AÉREAS,
MEDIANTE VISIÓN ARTIFICIAL,**
PRESENTADO EN LA 1ª JORNADA DE CIENCIA Y TECNOLOGÍA APLICADA, QUE
SE LLEVÓ A CABO LOS DÍAS 15 Y 16 DE NOVIEMBRE DE 2018,
EN LA CIUDAD DE CUERNAVACA, MORELOS; MÉXICO

CUERNAVACA, MORELOS, A 16 DE NOVIEMBRE DE 2018.


DR. VÍCTOR HUGO OLIVARES PEREGRINO
DIRECTOR DEL CENIDET



S.E.P.
CENTRO NACIONAL DE INVESTIGACION
Y DESARROLLO TECNOLÓGICO



Anexo E. Participación en el Concurso de Proyectos de Innovación, noviembre de 2018



ICMEAE
INTERNATIONAL CONFERENCE ON MECHATRONICS, ELECTRONICS AND AUTOMOTIVE ENGINEERING

El Centro de Investigación en Ingeniería y Ciencias Aplicadas de la Universidad Autónoma del Estado de Morelos y El Instituto de Ingenieros Electrónicos y Eléctricos de Morelos A.C.

otorgan el presente

RECONOCIMIENTO

A: **Eduardo González Sánchez**

Por su destacada participación como: **Concursante:**

En la categoría Innovación en el Advanced Robotics and Drone Competition.

En el marco del Congreso Internacional de Ingeniería Mecatrónica, Electrónica y Automotriz realizado del 27 al 30 de Noviembre del 2018 en la ciudad de Cuernavaca, Morelos, México.



Ing. Leoncio Aguilar Negrete
Presidente del Instituto de Ingenieros Electrónicos y Eléctricos de Morelos A.C.



Dra. Elsa Carmina Menchaca Campos
Directora Interina del Centro de Investigación en Ingeniería y Ciencias Aplicadas.





**TECNOLÓGICO
NACIONAL DE MÉXICO**

cenidet[®]
*Centro Nacional de Investigación
y Desarrollo Tecnológico*