



EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO®

Instituto Tecnológico de Ciudad Guzmán



INSTITUTO TECNOLÓGICO DE CD. GUZMÁN

TESIS

MAESTRÍA EN CIENCIAS DE LA COMPUTACIÓN

TEMA:

**ALGORITMO PARA EL CONTEO DE AGAVES
USANDO IMÁGENES AÉREAS TOMADAS DESDE UN
VEHÍCULO AÉREO NO TRIPULADO.**

QUE PARA OBTENER EL TÍTULO DE:
MAESTRO EN CIENCIAS DE LA COMPUTACIÓN

PRESENTA:

JESÚS ENRIQUE PONCE CORONA

DIRECTORES:

**DRA. MARÍA GUADALUPE SÁNCHEZ CERVANTES
DR. HIMER ÁVILA GEORGE**

CD. GUZMÁN JALISCO, MÉXICO, AGOSTO DE 2020

Resumen

El agave tequilana o agave azul, es una planta perteneciente a la familia agavaceas que ha sido utilizada por los habitantes Mesoamericanos desde hace aproximadamente 9000 años. El cultivo del agave hoy en día, forma parte de uno de los principales productos económicos en México, donde su siembra y cosecha se lleva a cabo principalmente en el estado Jalisco. Siendo esta planta la materia prima para la producción de Tequila, que es considerado como una bebida alcohólica regional mexicana y tanto la planta como el producto derivado son considerados como símbolos nacionales representativos. Por tal razón, el cultivo del agave requiere de estrictas normas que dictaminen desde la siembra, el cuidado, monitoreo y cosecha, estas normas son supervisadas por el Consejo Regulador del Tequila.

En los últimos años, la demanda del cultivo de agave se ha incrementado significativamente, dando como resultado el incremento en las áreas de siembra y aumento en el cuidado y monitoreo de la planta. Además, en los terrenos de agave el conteo e inventariado son llevados a cabo de manera manual, lo que implica un esfuerzo humano desgastante que requiere de un tiempo considerable para llevarse a cabo, tomando en cuenta que los terrenos de agaves pueden extenderse a decenas y centenares de hectáreas. La importancia de contar con información precisa sobre la cantidad de agaves que se encuentran en un terreno determinado es un factor que puede influir en la aprobación de la parcela para que su cultivo sea destinado a la elaboración del tequila aprobación es emitida por el Consejo Regulador del Tequila de acuerdo al cumplimiento de sus normas en cuestión a los monitoreos y cuidados de la planta.

Gracias a la implementación de nuevas tecnologías en la toma de imágenes aéreas y al avance en el desarrollo de vehículos aéreos no tripulados y sensores de medición, se establece como propuesta un método de conteo de plantas de agave basado en la captura de imágenes aéreas por medio de un vehículo aérea no tripulado, posteriormente estas imágenes obtenidas son preprocesadas y segmentadas para resaltar aquellos los elementos de interés, en este caso las plantas de agave. Finalmente, por medio de un algoritmo no supervisado de clustering se identifican las plantas de agaves y se lleva a cabo un conteo de las mismas.

Agradecimientos

Al equipo de docentes que conforman la Maestría en Ciencias de la Computación del Instituto Tecnológico de Ciudad Guzmán, en especial a la Dra. María Guadalupe Sánchez Cervantes por su apoyo y dedicación como directora de tesis. Asimismo, a los miembros de mi comité revisor, el Dr. Daniel Fajardo Delgado y la Mtra. María Eugenia Puga Nathal por el tiempo que se tomaron en revisar mi trabajo y sus comentarios acertados que ayudaron a mejorarlo.

Al Dr. Himer Avila George que además de su valioso apoyo como director de tesis, me alienta y anima en continuar con mis estudios en el campo de la investigación.

Al Mtro. Leobardo Padilla Miranda, propietario de los predios La Tinaja y el Llano Chico, por permitirnos tomar fotografías de sus parcelas de agave y hablarnos del cultivo. A las doctoras Teresa Efigenia Alarcón Martínez y Gabriela Calvario Sánchez por compartir su trabajo sobre el procesamiento de imágenes usando técnicas de aprendizaje máquina y percepción remota, a la misma vez que compartieron sus ortomosaicos los cuales me ayudaron a hacer las pruebas preliminares del presente trabajo de investigación.

A los doctores Jorge Alejandro Sánchez Garcés de la Universidad Peruana Unión, Wilson Castro Silupu de la Universidad Nacional de Frontera y Miguel Ángel de la Torre Gómora de la Universidad de Guadalajara, por su tiempo y apoyo en el procesamiento y análisis de las imágenes.

Al Consejo Nacional de Ciencia y Tecnología por otorgarme la beca 688350 para el desarrollo de mis estudios de maestría.

Y por su puesto, a mi esposa Claudia Monserrat por apoyarme y estar a mi lado en todo momento.

Índice general

Resumen	I
Agradecimientos	II
Índice de figuras	VI
Índice de tablas	VII
Lista de siglas y acrónimos	VIII
1. Introducción	1
1.1. Antecedentes	2
1.2. Planteamiento del problema	2
1.3. Justificación	3
1.4. Objetivos	3
1.4.1. General	3
1.4.2. Objetivos Específicos	3
2. Marco teórico	4
2.1. Percepción remota	4
2.2. Vehículos aéreos no tripulados	5
2.3. Fotogrametría usando vehículos aéreos no tripulados	6
2.4. Procesamiento de imágenes	9
2.4.1. Espacios de color	9
2.4.2. Segmentación	10
2.4.3. Operaciones Morfológicas	12
2.4.4. Binarización	12
2.4.5. Filtros	13
2.4.6. Filtros espaciales	16
2.4.7. Filtros de frecuencia	17
2.5. Aprendizaje máquina	18
2.5.1. Aprendizaje no supervisado	19
2.5.2. Aprendizaje supervisado	22
2.5.3. Aprendizaje por refuerzo	22
2.6. BIRCH	23
2.7. Validación de modelos no supervisados	24

3. Revisión sistemática de la literatura	27
3.0.1. Planificación de la revisión	27
3.0.2. Desarrollo de la revisión	28
3.1. Análisis de los resultados	30
3.2. Conclusiones de la revisión sistemática	33
4. Materiales y métodos	35
4.1. Equipo	35
4.2. Metodología propuesta	38
4.2.1. Planeación de vuelo y adquisición de imágenes	38
4.2.2. Preprocesamiento	39
4.3. Método propuesto para el conteo de agaves	43
4.3.1. Validación del modelo	44
5. Resultados	45
5.1. Zona de estudio	45
5.2. Plan de vuelo y adquisición de imágenes	46
5.3. Preprocesamiento	46
5.4. Segmentación	47
5.4.1. Segmentación por bandas	47
5.4.2. Aplicación de filtros	48
5.4.3. Extracción del suelo y mala hierba	48
5.5. Clasificación y conteo de agaves	49
5.5.1. Matriz de puntos	49
5.5.2. Clasificación y conteo	50
5.5.3. Casos	51
5.6. Resultados	53
5.7. Validación de los datos	55
6. Conclusiones y trabajos futuros	59
6.1. Conclusiones	59
6.2. Trabajos futuros	60
Referencias	60
Anexo A. Publicaciones derivadas de este trabajo de tesis	65
A.1. Artículo de revista	65
A.2. Memorias de congreso	65
Anexo B. Conjunto de datos	66
Anexo C. Estudios primarios	79

Índice de figuras

2.1. Espectro electromagnético. Fuente: Quirós Rosado (2015)	5
2.2. Tipos de drones: a) dron con ala fija, b) dron con multirroto.	5
2.3. Imagen Estereoscópica. Fuente: Quirós Rosado (2015)	7
2.4. Ejemplo de Paralaje desde la perspectiva de un avión. Fuente: Quirós Rosado (2015)	8
2.5. Espacios de color. (a) RGB, fuente: Gonzalez and Woods (2018); HSI, Fuente: Gonzalez and Woods (2018); $CIEL^*a^*b^*$, fuente: Westland et al. (2012)	10
2.6. Ejemplo de binarización de una imagen de agave, a) Imagen original, b) Imagen binarizada.	13
2.7. Ejemplo de <i>Thresholding</i> en una imagen de agave, a) Imagen original, b) Imagen con umbral.	13
2.8. Ejemplo del Filtro de Difuminación en una imagen de agave, a) Imagen original, b) Imagen difuminada.	14
2.9. Ejemplo del Filtro Bilateral en una imagen de agave, a) Imagen original, b) Imagen filtrada.	15
2.10. Ejemplo de imagen de agave con extracción de fondo, a) Imagen original, b) Imagen con extracción de fondo.	16
2.11. Ejemplo de imagen de agave con ajuste de Color/Contraste, a) Imagen original, b) Imagen con ajuste de contraste.	16
2.12. Ejemplo de imagen de agave con detección de Bordes, a) Imagen original, b) Imagen con detección de bordes.	17
2.13. Kernel o matriz de tamaño 3x3.	17
2.14. Filtro de paso bajo. Fuente: Gonzalez and Woods (2018)	18
2.15. Filtro de paso alto. Fuente: Gonzalez and Woods (2018)	18
2.16. Filtro de paso de banda. Fuente: Gonzalez and Woods (2018)	18
2.17. Valor de distancia de $a(x)$ y $b(x)$.	26
3.1. Publicaciones por año	31
3.2. Plantas estudiadas	33
3.3. Tipos de imágenes o datos utilizados	34
4.1. Equipo Parrot BlueGrass en vuelo.	35
4.2. Sensor de luz solar.	36
4.3. Cámara RGB.	37
4.4. Cámara Multiespectral.	37
4.5. Metodología utilizada en el presente trabajo.	38
4.6. Traslape.	38
4.7. Dialogo de progreso en el proceso de alineación en el software Metashape.	40
4.8. Parámetros de nube de puntos en el software Metashap.	40

4.9. Menú Ortomosaico. Fuente: Agisoft Software.	41
4.10. Opción: Recortar ortomosaico usando un polígono para seleccionar la región de interés con el software QGIS.	42
5.1. Zona de estudio, predios (a) La Tinaja y (b) El Llano chico, ubicados en el municipio del <i>El Arenal</i> del estado de Jalisco, México	45
5.2. Plan de vuelo usando el software Pix4DCapture	46
5.3. Crear un ortomosaico	47
5.4. Ortomosaico	48
5.5. Seleccionar la banda b^*	49
5.6. Aplicación de filtros Bilateral y Gaussiano.	50
5.7. Extracción del suelo y mala hierba.	50
5.8. Etiquetado segmentos de agave	51
5.9. Etiquetado segmentos de agave	52
5.10. Cultivo con agaves de tamaño uniforme con escasa maleza.	53
5.11. Cultivo con agaves de diferentes tamaños y maleza moderada.	54
5.12. Cultivo de agave con maleza abundante.	54
5.13. Conteo de agaves por cada segmento de la ortofoto.	55
5.14. Ortomosaico: conteo de agaves.	56
5.15. Ortomosaico: oportunidades de mejora.	57
5.16. Validación del modelo propuesto usando el coeficiente Silhouette.	58
B.1. Segmento: ID-0-2	66
B.2. Segmento: ID-0-3	67
B.3. Segmento: ID-1-1	67
B.4. Segmento: ID-1-2	68
B.5. Segmento: ID-1-3	68
B.6. Segmento: ID-1-4	69
B.7. Segmento: ID-2-0	69
B.8. Segmento: ID-2-1	70
B.9. Segmento: ID-2-2	70
B.10. Segmento: ID-2-3	71
B.11. Segmento: ID-2-4	71
B.12. Segmento: ID-3-0	72
B.13. Segmento: ID-3-1	72
B.14. Segmento: ID-3-2	73
B.15. Segmento: ID-3-3	73
B.16. Segmento: ID-3-4	74
B.17. Segmento: ID-4-0	74
B.18. Segmento: ID-4-1	75
B.19. Segmento: ID-4-2	75
B.20. Segmento: ID-4-3	76
B.21. Segmento: ID-5-0	76
B.22. Segmento: ID-5-1	77
B.23. Segmento: ID-5-2	77
B.24. Segmento: ID-6-0	78
B.25. Segmento: ID-6-1	78

Índice de tablas

3.1. Número de investigaciones publicadas y estudios primarios	29
3.2. Revistas en las cuales se ha publicado alguno de los estudios primarios	31
3.3. Tipos de problemas abordados	32

Lista de siglas y acrónimos

CIE

Commission internationale de l'éclairage por sus siglas en francés.

CNN

Convolutional Neural Network por sus siglas en inglés.

CRT

Consejo Regulador del Tequila.

DFOV

Campo de visión de pantalla.

DOF

Diario Oficial de la Federación.

GPS

Global Position System por sus siglas en inglés.

HFOV

Campo de visión horizontal.

HSI

Hue, Saturation, Intensity por sus siglas en inglés.

IMU

Inertial Measure Unit por sus siglas en inglés.

INS

Inertial Navegate System por sus siglas en inglés.

MDPI

Multidisciplinary Digital Publishing Institute por sus siglas en inglés.

MP

Megapíxeles (un millón de píxeles).

MRF

Markoff, Random, Field por sus siglas en inglés.

NM

Nanómetros (equivale a una mil millonésima parte de un metro).

PDE

Partial Differential Equations por sus siglas en inglés.

RGB

Red, Green, Blue por sus siglas en inglés.

RPAS

Sistemas de Aeronaves Pilotadas a Distancia.

SD

Secure Digital por sus siglas en inglés.

VANT

Vehículos Aéreos no Tripulados.

VFOV

Campo vertical de visión.

Capítulo 1

Introducción

El cultivo de agave (*agave tequilana weber* variedad azul) es uno de los principales productos económicos en México, siendo ésta planta la materia prima para la elaboración y producción de tequila. Dicha producción se lleva a cabo principalmente en Jalisco, seguido de algunas regiones de los estados de Guanajuato, Michoacán, Nayarit y Tamaulipas. De acuerdo con la norma mexicana NOM-006-SCFI-2012, publicada en el Diario Oficial de la Federación (DOF), se considera una bebida alcohólica regional mexicana obtenida por la destilación de mostos, derivados de los núcleos o *corazones* de agaves (DOF, 2012).

De acuerdo con informes del Consejo Regulador del Tequila (CRT), el consumo de agave para la producción de tequila ha incrementado en los últimos años (CRT, 2019). En el año 2017, se produjo 956.1 toneladas de agaves, en el 2018 incrementó a 1,138.8 toneladas y en el año 2019 se produjo cerca de 1,265 toneladas (CRT, 2019). En consecuencia, el cultivo de los agaves ha incrementado y esto ha requerido un aumento de cuidados y control para los cultivos, desde la siembra hasta la jima o cosecha. Debido a esta creciente producción e incremento en el número de plantíos, se ha dado como resultado una mayor demanda en el control de los cultivos, tanto para su monitoreo como para su inventariado. De acuerdo a los requerimientos solicitados por el CRT, el control del cultivo requiere de datos e información actualizada y constante, tales como censos de producción y materia prima; cantidad de agaves plantados, mantenidos y cosechados por cada terreno reportado; así como reportes sobre el estado de salud de los cultivos.

Goluvod (2007) menciona que en caso de haber alguna afectación donde el agave se vea involucrado, debe nuevamente realizarse un conteo e inventariado del mismo. Como respuesta, se han implementado nuevas tecnologías que ayudan a la solución de estas necesidades, una de ellas son los Vehículos Aéreos no Tripulados (VANT) o Drones que permiten el monitoreo y reconocimiento de terrenos amplios, así como la captura de imágenes aéreas, obteniendo datos e indicadores que puedan ayudar a una mejor planeación y toma de decisiones en la industria agavera.

El presente proyecto tiene como objetivo desarrollar un algoritmo que contabilice agaves por medio de imágenes tipo RGB (Rojo, Verde y Azul por sus siglas en inglés) tomadas desde un VANT, mejorando la eficacia en el conteo e inventariado de la materia prima.

1.1. Antecedentes

Los productos derivados del agave son reconocidos mundialmente, por ello el proceso de siembra, cultivo y jima o cosecha deben hacerse bajo una supervisión y aprobación de un organismo autorizado. Para el cultivo del agave, el Gobierno Mexicano ha establecido una serie de normas y procedimientos estrictos para formar parte de un cultivo certificado, algunos destacan que se debe garantizar la protección del cultivo, tener una bitácora de manejo de plantaciones y registros sobre información relevante acerca del cultivo, su desarrollo y su cosecha CRT (2019).

Para cumplir con dichas normas, las empresas agrícolas agaveras llevan a cabo un control del cultivo de manera manual, donde el conteo de agaves, monitoreo y supervisión se realizan con inspecciones de manera presencial y en pequeños fragmentos de cultivos. En caso de haber alguna alerta o anomalía en el conteo, se realiza una inspección detallada y en mayor extensión pero no de forma completa o total.

Algunas empresas privadas ofrecen servicios de monitoreo de los plantíos, sin embargo las herramientas de monitoreo e inventariado requieren de una cercanía al área y frecuentemente se realiza de manera presencial. Dichos servicios solo se llevan a cabo reportando un incidente en el plantío en general o específicamente en alguna planta o agave. Las herramientas utilizadas por las empresas son dispositivos de captura de información como tabletas electrónicas o computadoras portátiles y cámaras fotográficas para toma de muestras y trabajos de reportes. Algunas empresas emplean vehículos tipo VANT para tomar fotografía del terreno en general como evidencia de trabajo. Sin embargo, no se encontraron trabajos previos reportados en la literatura con relación al conteo de agaves mediante tomas de imágenes aéreas por medios de vehículos aéreos no tripulados. El trabajo más aproximado es de Calvario Sánchez (2019) llamado *Paradigmas de Aprendizaje Automático Aplicados a la Teledetección: Imágenes RGB e Imágenes Multiespectrales* donde se ha logrado detectar los surcos de agaves.

1.2. Planteamiento del problema

Debido al aumento en los cultivos o siembra de agave, se ha incrementado también el número de plantíos o terrenos, esto ha dado como resultado una mayor demanda en el control de los mismos, tanto para su monitoreo como para su inventariado. El control del cultivo requiere de datos e información actualizada y constante de acuerdo a los requerimientos solicitados por el CRT, algunos importantes son:

- Censos de producción y materia prima.
- Cantidad de agaves plantados, mantenidos y cosechados por cada terreno reportado.
- Reportes sobre el estado de salud de los cultivos.

Lo anterior resulta ser un problema debido a que no se cuenta con un recurso humano suficiente para cumplir con dichas tareas en terrenos muy extensos y en el crecimiento en su producción,

recurriendo a dar información con base en estimaciones y aproximaciones donde estas actividades se realizan de manera esporádica. De acuerdo a la investigación realizada por Golubov et al. (2007), en caso de haber alguna afectación donde el agave se vea involucrado, debe realizarse nuevamente un conteo e inventariado del mismo.

En la industria del cultivo de agaves existe la necesidad de tener información actualizada, confiable y constante con respecto al inventariado de su materia prima, sin importar la extensión del terreno.

1.3. Justificación

El uso de herramientas tecnológicas en la agricultura agavera en los últimos años, ha impulsado el desarrollo del mismo y en consecuencia se ha mejorado la calidad del producto (Grenzdörffer et al., 2008). Sin embargo, son pocas las investigaciones actuales dedicadas al procesamiento de imágenes enfocados al inventario y monitoreo del agave en particular.

El desarrollo de un algoritmo que pueda particularmente contabilizar los agaves de un cultivo a partir de imágenes tomadas desde un VANT, puede agilizar el proceso de inventariado con información y datos actuales y precisos, mejorando los tiempos de respuesta en la recolección de datos y tener así indicadores más confiables que puedan ser factores importantes en la toma de decisiones tanto en el cuidado y monitoreo, así como en la jima o cosecha. Los vehículos aéreos no tripulados son un medio eficaz y de bajo costo que pueden ser una opción viable en cuestión a practicidad (a diferencia de un monitoreo vía satelital) ya que pueden mapear los terrenos de manera cercana, mejorando la resolución espacial y eliminando el problema del factor de nubes y obstrucción de vista (Puliti et al., 2015).

Este algoritmo aportará mayor conocimiento científico y puede abrir nuevas investigaciones en el área a partir de ésta.

1.4. Objetivos

1.4.1. General

Desarrollar un algoritmo que contabilice plantas de agave en un terreno determinado utilizando imágenes aéreas tomadas desde un vehículo aéreo no tripulado.

1.4.2. Objetivos Específicos

- Establecer un protocolo de vuelo para un vehículo aéreo no tripulado que capture imágenes de agave en un terreno determinado.
- Realizar la captura de imágenes en cultivos de agaves.
- Extraer las características de las imágenes tomadas del cultivo de agave.
- Desarrollar un algoritmo para contabilizar las plantas de agave.

Capítulo 2

Marco teórico

2.1. Percepción remota

La percepción remota también conocida como teledetección, es un conjunto de técnicas que permite medir o registrar la energía electromagnética reflejada o emitida por la superficie de la tierra (Khorram et al., 2012). La teledetección ha ido evolucionando constantemente gracias a los avances tecnológicos en el desarrollo y mejoras de satélites y sensores, lo que ha permitido crear nuevos instrumentos de recolección de datos y monitoreo para distintas áreas como forestal, climática, espacial, agrícola, etc.

De acuerdo a Khorram (2012), la percepción remota se define como la adquisición y medición de información sobre ciertas propiedades de fenómenos, objetos o materiales por un dispositivo o sensor que no se encuentra en contacto físico con los objetivos monitoreados. Los sensores recopilan la información adquirida mediante la emisión de ondas electromagnéticas que emiten y rebotan con el objeto de interés. Estas ondas electromagnéticas se distribuyen a lo largo del espectro, dependiendo su longitud de onda y su frecuencia. Una onda es la distancia que existe en un punto o posición del ciclo hacia el mismo punto o posición del siguiente ciclo; la frecuencia se refiere al número de ondas que pasan en un determinado periodo de tiempo. La medida de un ciclo de onda se define por Hertz (o Hz) donde un ciclo equivale a 1 Hz (Khorram et al., 2012). La Figura 2.1 muestra los rangos de longitud de ondas electromagnéticas así como el número de frecuencia y la temperatura de los objetos expuestos a dichas ondas (Khorram et al., 2012).

Todos los objetos monitoreados por los sensores, son irradiados por las ondas emitidas de dichos dispositivos, estas ondas al chocar con los objetos, ya sean árboles, piedras, estructuras, plantas o cualquier tipo de materia, reaccionan a distintos fenómenos como la absorción, reflexión y dispersión. Si fueran graficadas las ondas en el eje X y la reflectividad en el eje Y, se obtendría como resultado un valor único y singular denominado *Firma espectral* de la cual se puede extraer información importante para su estudio.

La formación de una firma espectral, es dada por una serie de detectores fotoeléctricos que transforman los niveles de radiancia procedentes de la superficie terrestre (Muñoz, 2006), lo que da como resultado valores numéricos denominados niveles digitales. El valor de un nivel digital

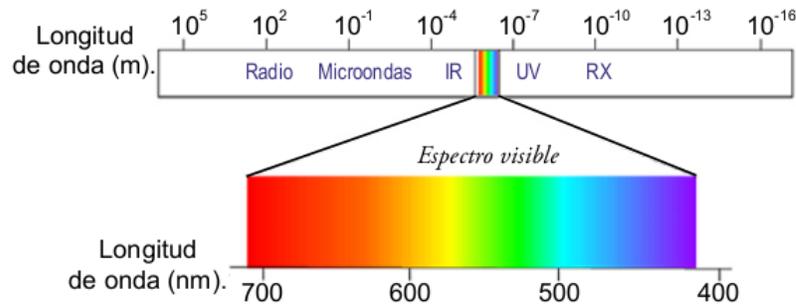


Figura 2.1: Espectro electromagnético.
Fuente: Quirós Rosado (2015)

corresponde a un píxel. Es decir, que este valor es proporcional a la intensidad de radiancia procedente de la superficie terrestre. Esta información ayuda a identificar el objeto de interés frente al resto de objetos alrededor del mismo, con los valores obtenidos puede incluso filtrar el objeto de los demás en función a su tamaño, a esto se le denomina *resolución espacial*.

2.2. Vehículos aéreos no tripulados

Los vehículos aéreos no tripulados (VANT) son aeronaves que vuelan autónomamente usando un sistema de piloto automático el cual es monitoreado desde un centro de control en tierra. De acuerdo con Escalante Torrado et al. (2016), fue el ejército estadounidense, en la década de los cincuenta, el primero en utilizar los VANT en aplicaciones militares relacionadas con tareas de reconocimiento, vigilancia, y mapeo.

Actualmente, existe una gran cantidad de plataformas aéreas consideradas como VANT, como consecuencia, hay diversas maneras de clasificarlas, una de las más comunes es según el tipo de plataforma ya sea de ala fija o multirrotor; véase la Figura 2.2.



(a) Ala fija



(b) Multirrotor

Figura 2.2: Tipos de drones: a) dron con ala fija, b) dron con multirrotor.

En los últimos años se ha popularizado el uso de VANT para el desarrollo de aplicaciones civiles

en el área de percepción remota. Lo anterior se ha debido a los recientes avances tecnológicos en el desarrollo de sistemas de control de vuelo y navegación, así como en las mejoras en las propiedades de las cámaras. En este contexto, las imágenes tomadas desde un VANT se han incluido en varios estudios de percepción remota, principalmente en aplicaciones agrícolas y forestales (Koc-San et al., 2018).

Entre las principales aplicaciones en la agricultura se encuentran la detección, identificación y conteo de cultivos, árboles, bosques, hierbas y coníferas. El conteo de árboles, plantas o cultivos es una actividad importante para los agricultores en la toma de decisiones. Esta actividad por lo regular se realiza de manera manual y debido al tiempo consumido que esto conlleva, los productores prefieren realizarlo sobre una parte de la cosecha, dando lugar a recuentos de plantas, árboles o cultivos poco frecuentes e inexactos (She et al., 2014). Además, no se tiene acceso a un inventario en tiempo real. Esta problemática puede ser resuelta a través del análisis de imágenes de alta resolución. Sin embargo, las imágenes de alta resolución temporal son difíciles y costosas de obtener, ya sea por imágenes satelitales o por aire convencional (Grenzdörffer et al., 2008).

Según She et al. (2014), la aparición de sistemas VANT cambió en gran medida el modo de trabajo de los sistemas convencionales y proporcionó a los productores de cultivos una plataforma aérea estable y de bajo costo para la teledetección. Además, los sensores con los que cuenta los VANT pueden proporcionar imágenes aéreas que resuelven las principales deficiencias que actualmente tienen los sistemas de adquisición de imágenes (Hunt et al., 2010). Los VANT pueden usarse para observar las estructuras pequeñas, específicas y detalladas de los cultivos, a diferencia de otros sistemas.

2.3. Fotogrametría usando vehículos aéreos no tripulados

La fotogrametría es la ciencia de obtener mediciones espaciales confiables de objetos a partir de sus fotografías aéreas (Khorram et al., 2012). La fotogrametría se deriva de tres palabras griegas traducidas a *escritura de luz y medición*. Las mediciones que pueden obtenerse son la distancia entre las propiedades de un área de interés, la extensión de un área en específico, o la altura de objetos particulares. Por otro lado, la fotogrametría surge a partir de la necesidad de poder obtener información a partir de dos dimensiones, por lo tanto se basa en la obtención de dos o más fotografías sucesivas que toman un punto en común del terreno, esto para poder reconstruir de manera geométrica el plano tridimensional, requiriendo los siguientes puntos:

- Orientación interna: con respecto a las propiedades del *haz* tanto su forma como la distancia focal.
- Orientación relativa: la posición relativa de un *haz* con respecto a otro, para estudiar sus intersecciones de rayos homólogos y conocer los puntos del objeto de interés.
- Orientación absoluta: establecer el sistema de coordenadas del terreno y escalarlo de ser necesario.
- Restitución: determinar e identificar los pares de rayos homólogos y los puntos del objeto o

terreno.

Se considera que la parte fundamental de la fotogrametría es la cámara métrica, este tipo de cámara posee características especiales como una alta precisión geométrica, campos amplios de captura con mínimas distorsiones, etc., brindando así una alta estabilidad y precisión en tomas fotográficas, que además contiene marcas fiduciales que ayudan a establecer una mejor posición en los puntos principales de la imagen fotográfica. La imagen obtenida (comúnmente digital) representa una matriz bidimensional en la que la unidad mínima de información es llamada *píxel*. Estas imágenes digitales se obtienen gracias a distintos sensores que producen imágenes matriciales parciales para después combinarlas.

En caso de requerir una vista tridimensional de algún plano o superficie, es necesario contar con dos imágenes de la misma escena o imagen pero tomada desde perspectivas diferentes, a esta técnica se le conoce como visión estereoscópica Figura 2.3. Esta técnica está basada en el funcionamiento del ojo humano con respecto a la percepción de las cosas en tres dimensiones o con relieve, formando parte de la fotogrametría.

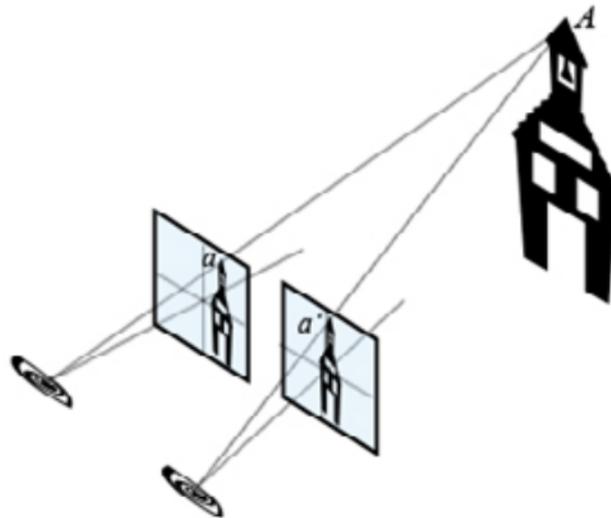


Figura 2.3: Imagen Estereoscópica.
Fuente: Quirós Rosado (2015)

Con la visión estereoscópica se busca apreciar de mejor manera un relieve a partir de dos fotogramas y de esta manera se puedan realizar mediciones en altimetría y planimetría. Para ello, la estereoscopía debe cumplir con las siguientes condiciones:

- Las dos cámaras debe ver la perspectiva que les corresponde.
- Los fotogramas de las cámaras deben tener zonas en común o *recubrimiento estereoscópico*

Sin embargo, existen factores que pueden alterar la fiabilidad de una imagen resultante de los fotogramas, estos pueden ser originados a partir de la captura de dos fotografías con escalas diferentes o bien que las fotografías sean tomadas en zonas muy inclinadas. Ejemplo de ello es el *Paralaje*

(Figura 2.4), se refiere al cambio en la posición de los objetos debido al cambio de posición de la cámara en el momento de la toma, un ejemplo típico es la perspectiva desde un avión donde los objetos cambian de posición mientras se desplaza el avión de un punto a otro, el objeto más alejado visto desde el avión se desplaza más lento que aquellos objetos más cercanos.

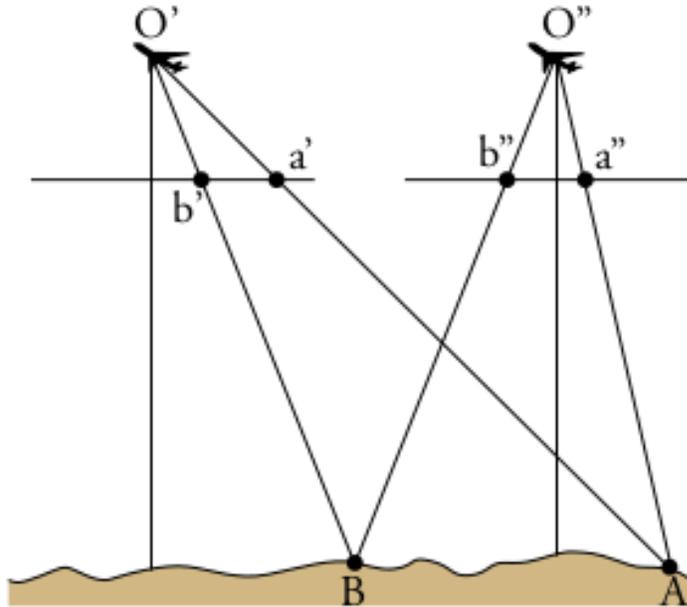


Figura 2.4: Ejemplo de Paralaje desde la perspectiva de un avión.
Fuente: Quirós Rosado (2015)

Para el vuelo del vehículo aéreo no tripulado o dron, se requiere primero saber las condiciones y normas establecidas por las autoridades correspondientes. De manera general, se toman las siguientes consideraciones:

- Analizar el objetivo principal de llevar a cabo un vuelo, de esta manera se sabrá con mayor certeza el tipo de equipos y sensores que se requiere.
- Altura máxima permitida de 120 metros en áreas que no exista tránsito aéreo.
- En caso que requiera tomas fotográficas, el vuelo debe hacerse en un entorno libre de nubes, humo o neblina.
- La velocidad del viento deberá ser mínima para evitar turbulencias.
- En caso de implementar una fotointerpretación se debe evitar suelos cubiertos de nieve.
- El momento del día es un factor importante, debido a que el sol proyectará las sombras ya sea de una manera que facilite la lectura o bien la dificulte.
- Tipo de cámaras que se van a utilizar. Ya sea digital o analógica.
- Características del dron de vuelo, modelo del dron, accesorios equipados, sensores y otros aditamentos.
- Forma y geometría del vuelo, de qué manera se trazará la ruta de vuelo y la cantidad de

imágenes tomadas para cubrir todo el espacio u objetivo.

- Condiciones del vuelo, se refiere a la hora del vuelo con respecto a la altura del sol, esto para determinar la cantidad de sombras presentadas.
- Formato de entrega de archivos digitales.

2.4. Procesamiento de imágenes

En 1666, Isaac Newton descubrió que la luz solar se descompone en un espectro continuo de colores al atravesar un prisma de vidrio, este espectro de colores va desde el violeta hasta el rojo. Posteriormente, el espectro de colores se dividió en seis amplias regiones: violeta, azul, verde, amarillo, naranja y rojo. La luz está compuesta por una banda relativamente estrecha de frecuencias en el espectro electromagnético, por lo tanto un cuerpo que refleja la luz y que logra equilibrar todas sus ondas visibles, parecerá de color blanco para aquella persona que la observe, pero si el cuerpo logra reflejar en algún rango de frecuencias del espectro, éste adquiere cierta tonalidad de color (Khorram et al., 2012).

2.4.1. Espacios de color

Modelo de color RGB (Rojo, Verde y Azul)

En 1931, la Comisión Internacional de Iluminación (CIE) designó los siguientes valores específicos de longitud de onda para los tres colores primarios: azul = 435.8 nm, verde = 546.1 nm, y rojo = 700 nm. Estos colores son perceptibles para el ojo humano y se conocen como Red, Green, Blue por sus siglas en inglés (RGB). Para facilitar la especificación de colores de manera estándar, se han creado los modelos de color o espacio de color, donde este espacio define un sistema de coordenada, de modo que cada color en el modelo, está representado por un único punto contenido en dicho espacio.

Basado en los colores primarios y un sistema de coordenadas cartesianas. De acuerdo a la Figura 2.5a los valores primarios se encuentran en las esquinas, mientras que los colores secundarios cian, magenta y amarillo están en otras tres esquinas, el color negro en el origen y el color blanco en la esquina más alejada del origen. Las escalas de grises se deben a que los valores de los colores primarios son iguales y se extienden de negro a blanco a lo largo de la línea que une estos dos puntos.

Modelo HSI (Matiz, Saturación, Intensidad)

Cuando los humanos ven un objeto de color, usualmente se describe por su tono, saturación y brillo. El tono es un atributo de color que describe un color puro mientras que la saturación da una medida del grado en que un color puro se diluye con luz blanca y la intensidad se refiere al nivel de gris. El modelo de color Hue, Saturation, Intensity por sus siglas en inglés (HSI), descompone el componente de intensidad de la información que transporta el color (matiz y saturación) en una imagen en color (Gonzalez and Woods, 2018). El modelo HSI es una herramienta útil para desarrollar algoritmos de

procesamiento de imágenes basados en descripciones de color porque resultan más intuitivas para el ojo humano. La Figura 2.5b muestra el esquema y orden del espectro de colores en el espacio HSI.

Modelo $CIE L^*a^*b^*$

Creado por la Comisión Internacional de Iluminación, define tres valores numéricos: L para la luminiscencia, a^* para los componentes verde y rojo, b^* para los componentes azul y amarillo.

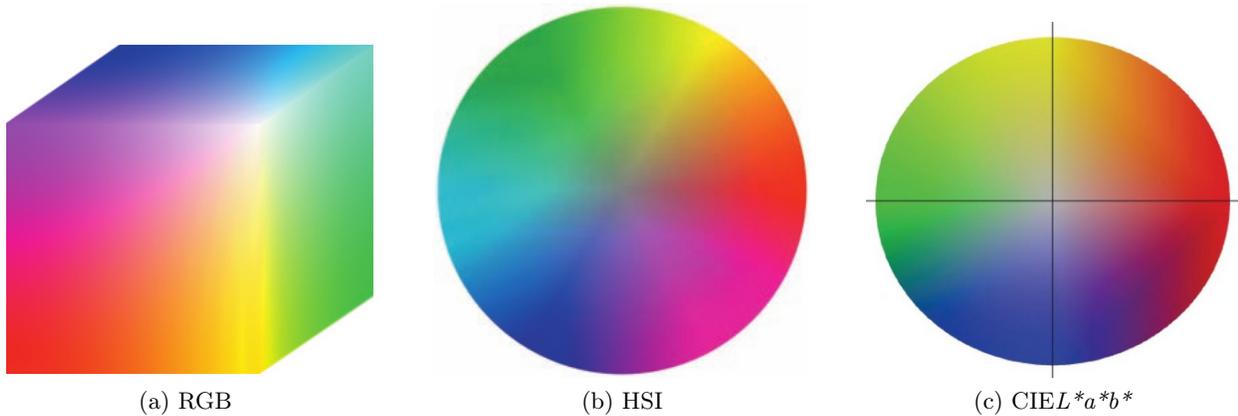


Figura 2.5: Espacios de color. (a) RGB, fuente: Gonzalez and Woods (2018); HSI, Fuente: Gonzalez and Woods (2018); $CIE L^*a^*b^*$, fuente: Westland et al. (2012)

Este espacio de color fue diseñado para ser uniforme en la percepción visual humana, lo que significa que la misma cantidad de cambio de numeración de dichos valores corresponde a aproximadamente la misma cantidad de cambio percibido visualmente (ver Figura 2.5c).

Comparado con el RGB, es más rápido hacer correcciones eficientes de color en $CIE L^*a^*b^*$, esto se debe a que la luminosidad es completamente ignorada en los canales A y B por lo tanto la presencia de errores es mínima. Además que es posible referenciar una cantidad superior de colores en comparación con RGB.

2.4.2. Segmentación

De acuerdo a Fortsyth (2015), la segmentación es un proceso que divide una imagen en regiones para poder simplificar su representación, de esta manera resulta más sencillo su análisis e interpretación de la imagen porque se enfatizan las propiedades de la imagen. Algunos algoritmos de segmentación se basan en una de las dos propiedades básicas de los valores de intensidad de imagen: discontinuidad y similitud. La primera consiste en dividir una imagen en regiones basadas en cambios bruscos de intensidad, como los bordes. La segunda consiste en la partición de una imagen en regiones que son similares de acuerdo con un conjunto de criterios predefinidos señala Fortsyth (2015).

Si se desea segmentar una imagen basada en el color y además, se quiere llevar a cabo el proceso en planos individuales, se puede optar primero por el espacio HSI porque el color está convenientemente representado en la imagen del tono. Típicamente, la saturación se usa como una imagen de

enmascaramiento para aislar otras regiones de interés en la imagen del tono. La imagen de intensidad se usa con menos frecuencia para la segmentación de imágenes en color porque no contiene información de color. Por otra parte, trabajar en el espacio HSI es más intuitivo en el sentido de que los colores se representan en un formato más familiar, la segmentación es un área en la que generalmente se obtienen mejores resultados mediante el uso de vectores de color RGB. El enfoque es sencillo. Si el objetivo es segmentar objetos de un rango de color específico en una imagen RGB, dado un conjunto de puntos de color de muestra representativos de los colores de interés, se obtiene entonces una estimación del color *promedio* que se desea segmentar. El objetivo de la segmentación es clasificar cada píxel RGB en una imagen dada con un color en el rango especificado o no. Para realizar esta comparación, es necesario tener una medida de similitud. Una de las medidas más simples es la distancia euclidiana (Gonzalez and Woods, 2018).

Las segmentaciones pueden ser agrupadas de acuerdo a su método y características, a continuación se mencionan algunos métodos más utilizados (Gonzalez and Woods, 2018):

- Segmentación basada en región. Este método va de la mano con las técnicas de detección de borde, debido a que un objeto es agrupado en un área (que cierra). Y esta área termina representando un valor dado por la agrupación de sus píxeles de acuerdo al umbral o *thresholding*.
- Segmentación basada en contornos. Se puede llevar a cabo una segmentación basándose en los contornos de una figura, siempre y cuando la imagen tenga ciertas propiedades y características que faciliten. Todos los contornos son definidos de acuerdo al valor del píxel y comparándolo con sus vecinos. No es necesario que los bordes se cierren.
- Segmentación basada en agrupación o clustering. Las técnicas basadas en la agrupación son las técnicas que segmentan la imagen en agrupaciones que tienen píxeles con características similares. Hay dos categorías básicas de métodos de agrupamiento: método jerárquico (árboles) y método basado en particiones (iterativa).
- Segmentación basada en modelado. La segmentación basada en el campo aleatorio llamado Markoff, Random, Field por sus siglas en inglés (MRF). Una restricción de suavidad de región incorporada se presenta en MRF, que se utiliza para la segmentación del color. Los componentes de las tuplas de píxeles de color se consideran variables aleatorias independientes para su posterior procesamiento. MRF se combina con la detección de bordes para identificar los bordes con precisión.
- Segmentación basada en Cuencas. A esta segmentación se le conoce como *Watershed*, donde los valores de los píxeles son representados como alturas, donde la concentración de los valores más altos forman una superficie más profunda que aquellos píxeles con valores más bajos. Este método es eficaz cuando las imágenes presentan cierta limpieza y ausencia de ruido.
- Segmentación basada en ecuaciones diferenciales parciales, también llamada Partial Differential Equations por sus siglas en inglés (PDE). Los métodos basados en ecuaciones diferenciales parciales son los métodos rápidos de segmentación. Existen dos métodos básicos de PDE: filtro de difusión isotrópico no lineal (utilizado para mejorar los bordes) y restauración convexa de variación no cuadrática (utilizada para eliminar el ruido). Los resultados del método PDE son

bordes y límites borrosos que se pueden cambiar utilizando operadores cercanos.

- Segmentación basada en redes neuronales artificiales. Los métodos de segmentación basados en redes neuronales artificiales simulan las estrategias de aprendizaje del cerebro humano para la toma de decisiones. Se utiliza para separar la imagen requerida del fondo, tiene dos pasos básicos: extracción de características y segmentación por red neuronal. Con este método la imagen no requiere de un preprocesamiento.

2.4.3. Operaciones Morfológicas

La morfología es un método que sirve como herramienta para extraer componentes de imagen que son útiles en la representación y descripción de la forma de la región, como límites, esqueletos, procesamiento previo o posterior, filtrado, adelgazamiento, etc. En una operación morfológica, el valor de cada píxel de salida es el resultado de la comparación de un píxel con sus vecinos en una imagen de entrada (Gonzalez and Woods, 2018). Sus principales operaciones son:

- Dilatación. La dilatación morfológica hace que los objetos sean más visibles y rellena pequeños agujeros en los objetos.
- Erosión. La erosión morfológica elimina las islas y los objetos pequeños para que sólo queden objetos sustantivos.
- Abertura. Elimina objetos pequeños de una imagen conservando la forma y el tamaño de los objetos más grandes de la imagen.
- Cierre. Rellena pequeños agujeros de una imagen conservando la forma y el tamaño de los objetos de la imagen.
- Esqueleto. Erosiona todos los objetos a las líneas constructivas sin cambiar la estructura esencial de los objetos, como los agujeros de la existencia y las ramas.
- Perimetral. Encuentra el perímetro de los objetos en una imagen binaria. Un píxel es parte del perímetro si es distinto de cero y está conectado al menos a un píxel de valor cero.

2.4.4. Binarización

La binarización consiste en establecer el color de cada píxel en un valor binario, es decir 1 o 0. Esta técnica es útil para separar los objetos o regiones que puedan ser de interés, separando el fondo de la imagen y apreciando mejor los objetos. El proceso de la binarización calcula el umbral de la escala de grises, es decir que la tonalidad de color gris es calculada de acuerdo a la tonalidad del color original. En la Figura. 2.6 se muestra una imagen que requiere de un realce en sus características. Después, se ha llevado a cabo la binarización, el fondo ha sido eliminado y las características de la imagen han sido resaltadas.

Umbralización ó *Thresholding*

Considerado la base de la segmentación debido a sus propiedades intuitivas (Gonzalez and Woods, 2018), la simplicidad de implementación y la velocidad computacional, el umbral de imagen goza de

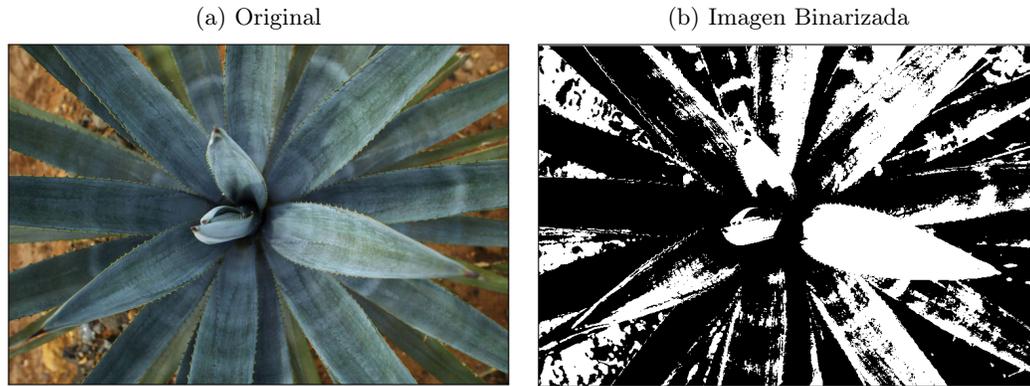


Figura 2.6: Ejemplo de binarización de una imagen de agave, a) Imagen original, b) Imagen binarizada.

una posición central en las aplicaciones de segmentación de imágenes.

Separar regiones de una imagen correspondientes a los objetos de interés, basándose en la variación de la intensidad entre los píxeles de interés y los píxeles de fondo, realizando una comparación de cada valor de intensidad de los píxeles con respecto a un umbral. El valor de éste será determinado de acuerdo a la problemática que se busca resolver.

Una vez realizada la separación de los objetos de interés, se establece un valor a los píxeles para poder identificarlos, posteriormente estos valores pueden automatizarse para otras imágenes que se buscan los mismos objetos de interés. En la Figura 2.7 se implementa una umbralización o *Thresholding* para muestra de la variación en los píxeles de una imagen binarizada.

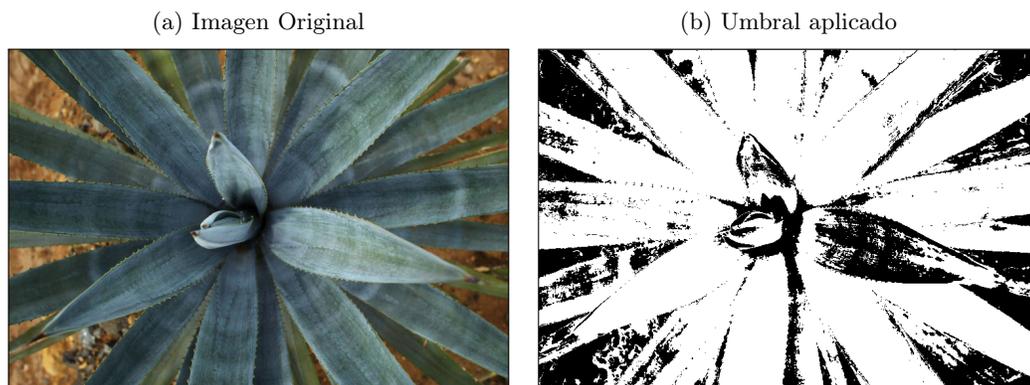


Figura 2.7: Ejemplo de *Thresholding* en una imagen de agave, a) Imagen original, b) Imagen con umbral.

2.4.5. Filtros

De acuerdo a Quirós Rosado (2015), un filtro es un proceso matemático que consiste en aislar componentes de interés, reforzando o suavizando los contrastes espaciales de nivel de gris que integran una imagen. Es decir, se trata de transformar los niveles digitales originales de cada píxel para que se asemejen o diferencien más de sus vecinos.

Implementar filtros en una imagen digital es uno de los trabajos más comunes en el procesamiento de señales, el resultado de cada filtro dependerá del valor de cada píxel y de sus vecinos. Se puede trabajar un filtro de acuerdo a su dominio del espacio (trabajando sobre los píxeles) o bien en su dominio de frecuencia (efectuando una transformada de Fourier en la imagen procesada).

Existen también los llamados Filtro de suavizado y de paso bajo. Se refiere a las atenuaciones en frecuencias altas y en frecuencias bajas, la característica común es que disminuye las diferencias de los valores de los píxeles respecto a sus vecinos. La aplicación de este filtro produce la degradación de la imagen, dando como efecto un cierto desenfoque y difuminación (Grau, 2011). Los principales filtros son de media, gaussiano y la mediana.

Los llamados filtros de realce de bordes o de paso alto, produce un efecto contrario a la eliminación de ruido (Jose Jaime Esqueda Elizondo, 2005), lo anterior consiste en enfatizar o resaltar aquellos píxeles que tienen un valor de gris diferente al de sus vecinos. Se debe previamente eliminar el ruido antes de aplicar un realce de bordes de lo contrario el ruido será multiplicado. Esta técnica busca en una imagen aquellos vecinos de un píxel que tengan cambios muy abruptos en su intensidad, primero se buscará grandes picos y en segundo cambios de signos.

Difuminación

El preprocesamiento consta primero en aplicar un filtro para la difuminación, una operación morfológica fundamental que tiene como objeto suavizar zonas en las que los bordes son demasiado marcados o el contraste es muy alto. El proceso de este filtro consta en la operación de conjunto de píxeles, donde el conjunto se encuentra definido y es comparado con un píxel de anclaje, de esta manera, reemplaza el píxel actual (anclaje) con el valor mínimo de píxel encontrado en el conjunto de píxeles definido. Creando un efecto de desenfoque y suavidad. Figura 2.8. Aplicar este filtro tiene como objetivo eliminar el ruido y facilitar la extracción de fondo. En este caso se utiliza el filtro Gaussiano.

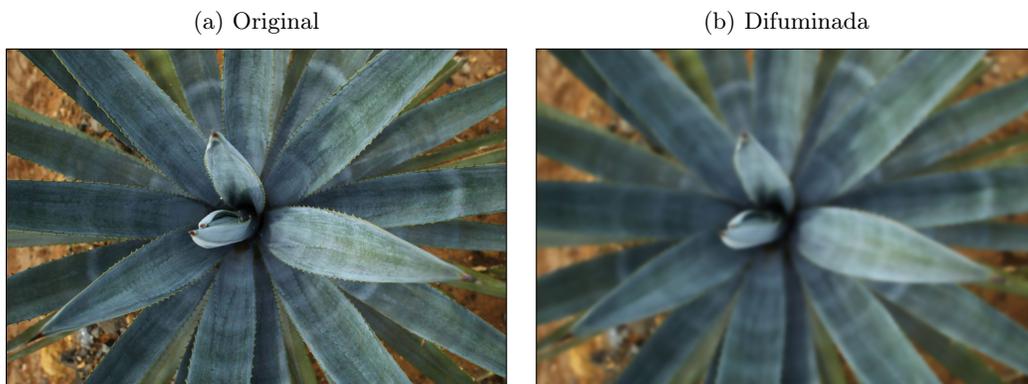


Figura 2.8: Ejemplo del Filtro de Difuminación en una imagen de agave, a) Imagen original, b) Imagen difuminada.

Filtro Bilateral

Este es un tipo de filtro no lineal, busca preservar los bordes pero reducir el ruido para el suavizado de la imagen. El valor de intensidad en cada píxel de la imagen es reemplazado por una media ponderada de los valores de intensidad de los píxeles cercanos. La Ec. 2.1, define el filtro bilateral, donde $I^{filtered}$ representa la imagen filtrada, W es el peso obtenido mediante la cercanía espacial y la diferencia de intensidad, x son las coordenadas del píxel a filtrar, I es la imagen original, Ω se centra en la ventana x , f_r representa el núcleo para suavizar las diferencias de intensidades, g_s representa el núcleo espacial para suavizar las diferencias de coordenadas.

$$I^{filtered}(x) = \frac{1}{W} \sum_{x_i \in \Omega} I(x_i) f_r(\|I(x_i) - I(x)\|) g_s(\|x_i - x\|) \quad (2.1)$$

Este filtro suele complementarse con un suavizado Gaussiano para dar mejores resultados, Figura 2.9

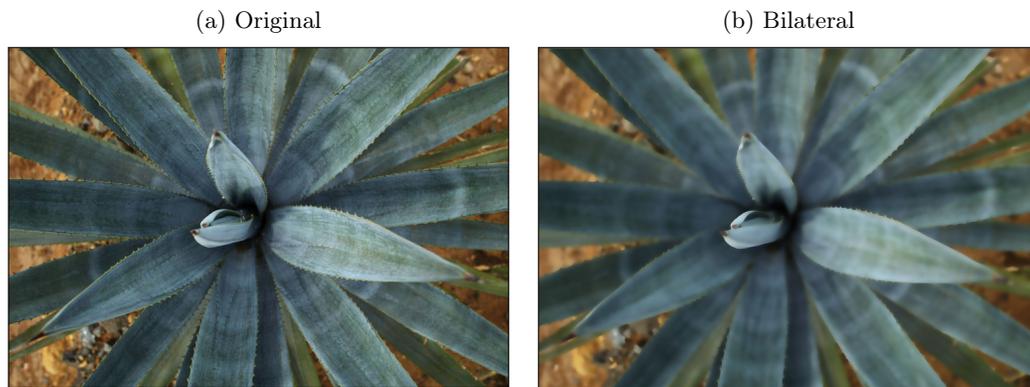


Figura 2.9: Ejemplo del Filtro Bilateral en una imagen de agave, a) Imagen original, b) Imagen filtrada.

Extracción de fondo

Para la extracción de fondo se utiliza la técnica *rolling ball* donde se definen los objetos en tamaños de píxel que no pertenecen al fondo (Figura 2.10).

Ajuste de color y contraste

Por último se realiza un ajuste en el color y contraste, buscando obtener una mejor apreciación de los objetos de interés. Tomando en cuenta que las plantas de agave son de color azul, en una imagen RGB se puede hacer los ajustes necesarios para resaltar el color de las plantas frente al resto de los objetos (Figura 2.11).

En algunas muestras extraídas de la imagen del cultivo, se tienen agaves con características maduras y distancias cortas o nulas entre ellas, para estos casos se requiere añadir una binarización

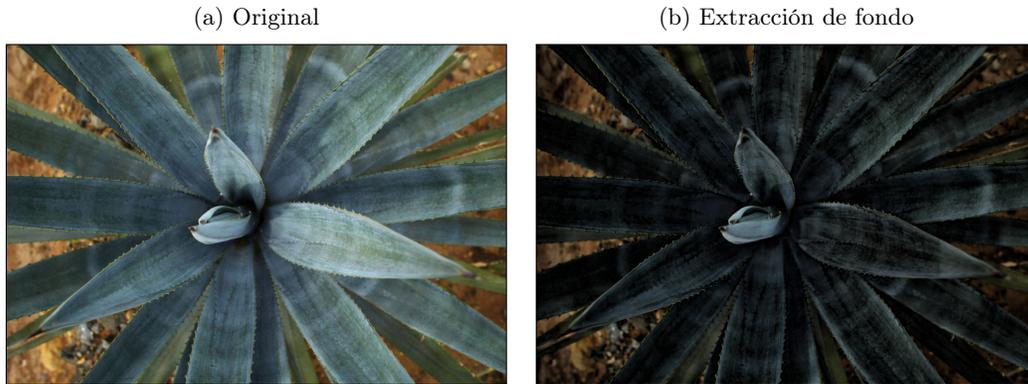


Figura 2.10: Ejemplo de imagen de agave con extracción de fondo, a) Imagen original, b) Imagen con extracción de fondo.

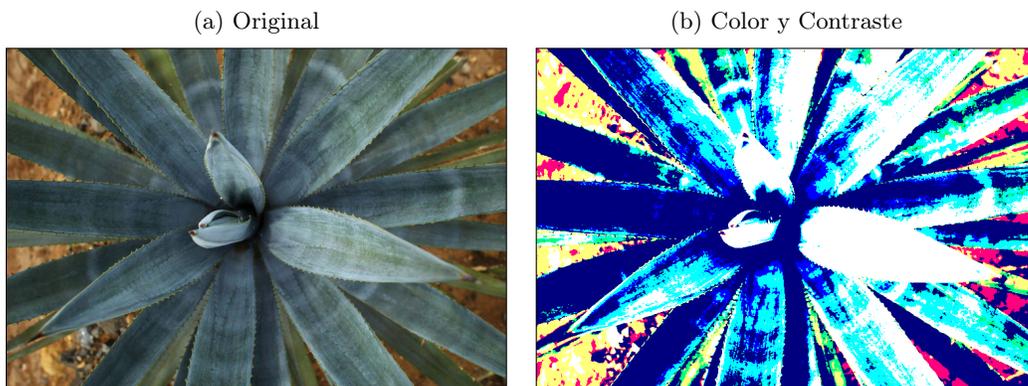


Figura 2.11: Ejemplo de imagen de agave con ajuste de Color/Contraste, a) Imagen original, b) Imagen con ajuste de contraste.

y segmentación basado en la detección de bordes, esto ayuda a mejorar la separación y apreciación de cada planta. En la detección de bordes se implemento el filtro Sobel (Figura 2.12).

2.4.6. Filtros espaciales

El filtro o filtrado espacial es ampliamente utilizado en el procesamiento de imágenes, modifica una imagen reemplazando el valor de cada píxel por una función de los valores del píxel y sus vecinos Gonzalez and Woods (2018). Si la operación realizada en los píxeles de la imagen es lineal, se considera entonces un filtro espacial lineal, de lo contrario será un filtro espacial no lineal.

Un filtro espacial lineal normalmente realiza una suma de productos entre una imagen y un núcleo o kernel de filtro. El Kernel es una matriz, definido su tamaño mediante la vecindad de la operación, otros términos adjudicados son máscara o plantilla. La Figura 2.13 muestra un kernel 3x3, donde la respuesta a éste será siempre la suma de sus productos de los coeficientes del kernel y los píxeles de la imagen que abarca el kernel.

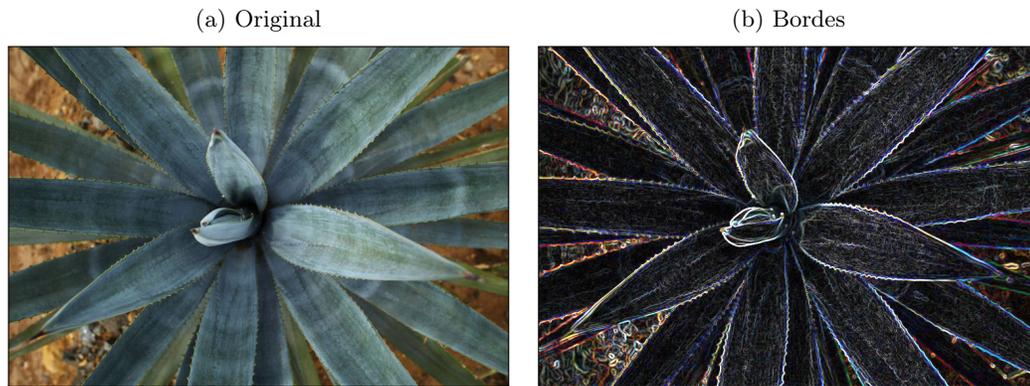


Figura 2.12: Ejemplo de imagen de agave con detección de Bordes, a)Imagen original, b) Imagen con detección de bordes.

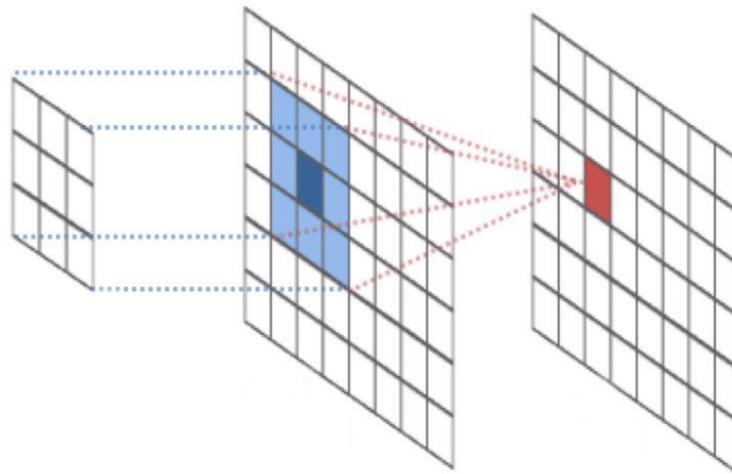


Figura 2.13: Kernel o matriz de tamaño 3x3.

2.4.7. Filtros de frecuencia

Los filtros en el dominio de frecuencia son utilizados para eliminar altas o bajas frecuencias de una imagen, es decir al suavizado del mismo o resaltar bordes. Esto se logra mediante una transformación discreta de Fourier y realizando varias operaciones de productos. Los tipos de filtros de frecuencias más comunes son:

- Filtros de paso bajo: deja inalterable las bajas frecuencias y atenúa o elimina las altas frecuencias. Véase la Figura 2.14.
- Filtros de paso alto: deja inalterables las altas frecuencias y atenúa o elimina las bajas frecuencias, realizando de los cambios bruscos de niveles de grises. Es decir, resalta los bordes. Véase la Figura 2.15.
- Filtros de banda: atenúa las altas y bajas frecuencias, pero mantiene intactas las frecuencias que se encuentren en una banda determinada. Esto se logra multiplicando uno de paso bajo

por uno de paso alto, en el que la frecuencia de corte de paso bajo sea superior a la de paso alto. Véase la Figura 2.16.



Figura 2.14: Filtro de paso bajo.
Fuente: Gonzalez and Woods (2018)



Figura 2.15: Filtro de paso alto.
Fuente: Gonzalez and Woods (2018)



Figura 2.16: Filtro de paso de banda.
Fuente: Gonzalez and Woods (2018)

2.5. Aprendizaje máquina

El aprendizaje máquina (o *machine learning*), es un área de la inteligencia artificial que se dedica al estudio y desarrollo de algoritmos con la capacidad de mejorar su desempeño con la experiencia, por ejemplo algoritmos que aprenden. En la literatura, están reportadas varias maneras de clasificar los algoritmos de aprendizaje máquina (Morales Manzanares et al., 2019). Sin embargo, una de las más aceptadas es: (1) aprendizaje no supervisado; (2) aprendizaje supervisado; y (3) aprendizaje con refuerzo.

2.5.1. Aprendizaje no supervisado

Los algoritmos de aprendizaje no supervisado son aquellos que segmentan automáticamente los datos, éstos algoritmos también son conocidos como de agrupamiento o *clustering*. Los algoritmos de agrupamiento se pueden clasificar como:

- Agrupamiento por particiones: Construyen una partición del conjunto de datos D de n objetos en un conjunto de k clústers. Dado un k , intentan encontrar una partición de k clústers que optimiza el criterio de particionamiento. Un algoritmo representativo de éste tipo de clustering es K-Means.
- Agrupamiento basado en densidad: en este tipo de clustering un clúster es una región densa de objetos rodeados por una región de baja densidad. Suele usarse cuando hay ruido y outliers presentes en los datos. Un algoritmo representativo de éste tipo de clustering es *Density-based spatial clustering of applications with noise* (DBSCAN).
- Agrupamiento jerárquico: consiste en permitir que los clústers puedan anidarse, organizado en forma de árbol. Los métodos jerárquicos se clasifican en aglomerativos o divisivos. El primero considera cada punto un clúster y en cada paso fusiona los pares más cercanos como un clúster; ésta técnica requiere de una forma de medir la proximidad entre dos clústers. El segundo comienza con todos los datos como un solo clúster y subdivide hasta quedarse con puntos individuales como clústers. Un algoritmo representativo de éste tipo de clustering es *Balanced Iterative Reducing and Clustering using Hierarchies* (BIRCH).

En el aprendizaje no-supervisado, no hay una respuesta correcta. Esto hace que la evaluación de los grupos identificados sea un tanto subjetiva. Por lo tanto, es necesario el uso de algunas métricas que evalúen la forma en como los datos fueron agrupados.

Agrupación *Clustering* y conteo

El problema del clustering o agrupamiento de datos ha sido ampliamente estudiado en la literatura de minería de datos y aprendizaje automático debido a sus numerosas aplicaciones para el resumen, el aprendizaje, la segmentación y el marketing objetivo. De acuerdo a Aggarwal and Reddy (2013), el problema básico de la agrupación se puede establecer de la siguiente manera: Dado un conjunto de puntos de datos, dividirlos en un conjunto de grupos que sean lo más similares posible.

Algunos dominios de aplicación comunes en los que surge el problema de agrupamiento son los siguientes (Aggarwal and Reddy, 2013):

- Paso intermedio para otros problemas fundamentales de minería de datos: dado que una agrupación puede considerarse una forma de resumen de datos, a menudo sirve como un paso intermedio clave para muchos problemas fundamentales de minería de datos, como la clasificación o el análisis atípico.
- Filtrado colaborativo: en los métodos de filtrado colaborativo, el agrupamiento proporciona

un resumen de usuarios de ideas afines.

- Segmentación del cliente: esta aplicación es bastante similar al filtrado colaborativo, ya que crea grupos de clientes similares en los datos pero se pueden usar atributos arbitrarios sobre los objetos para fines de agrupamiento.
- Resumen de datos: muchos métodos de agrupamiento están estrechamente relacionados con los métodos de reducción de dimensionalidad. Dichos métodos pueden considerarse una forma de resumen de datos. El resumen de datos puede ser útil para crear representaciones de datos compactas, que son más fáciles de procesar e interpretar en una amplia variedad de aplicaciones.
- Detección dinámica de tendencias: se pueden usar muchas formas de algoritmos dinámicos y de transmisión para realizar la detección de tendencias en una amplia variedad de aplicaciones de redes sociales. En tales aplicaciones, los datos se agrupan dinámicamente de manera continua y se pueden utilizar para determinar patrones importantes de cambios.
- Análisis de datos multimedia: una variedad de diferentes tipos de documentos, como imágenes, audio o video, entran en la categoría general de datos multimedia. La determinación de segmentos similares tiene numerosas aplicaciones, como la determinación de fragmentos similares de música o fotografías similares. En muchos casos, los datos pueden ser multimodales y pueden contener diferentes tipos. En tales casos, el problema se vuelve aún más desafiante.
- Análisis de datos biológicos: los datos biológicos generalmente se estructuran como secuencias o como redes. Los algoritmos de agrupamiento proporcionan buenas ideas de las tendencias clave en los datos, así como las secuencias inusuales.

Métodos de selección de funciones

La fase de selección de características es un paso importante de preprocesamiento que se necesita para mejorar la calidad de la agrupación subyacente. No todas las características son igualmente relevantes para encontrar los clústeres, ya que algunas pueden ser más ruidosas que otras. Por lo tanto, a menudo es útil utilizar una fase de preprocesamiento en la que las características ruidosas e irrelevantes se eliminan de la contienda.

Cabe señalar que la selección de características también se puede integrar directamente en el algoritmo de agrupamiento para obtener mejores conocimientos específicos de la localidad. Esto es particularmente útil cuando diferentes características son relevantes para diferentes localidades de los datos.

Algoritmos basados en distancia

Los métodos basados en la distancia son a menudo deseables debido a su simplicidad y facilidad de implementación en una amplia variedad de escenarios. Los algoritmos basados en la distancia generalmente se pueden dividir en dos tipos:

- Plano: en este caso, los datos se dividen en varios grupos de una sola vez, generalmente con el uso de representantes de partición. La elección del representante de partición y la función de

distancia es crucial y regula el comportamiento del algoritmo subyacente. En cada iteración, los puntos de datos se asignan a sus representantes de partición más cercanos, y luego el representante se ajusta de acuerdo con los puntos de datos asignados al grupo.

- Jerárquico: en estos métodos, los grupos se representan jerárquicamente a través de un dendograma, en diferentes niveles de granularidad. Dependiendo de si esta representación jerárquica se crea de arriba hacia abajo o de abajo hacia arriba, estas representaciones pueden considerarse aglomerativas o divisivas.

Los métodos basados en la distancia son muy populares, porque pueden usarse con casi cualquier tipo de datos, siempre que se cree una función de distancia apropiada para ese tipo de datos. Por lo tanto, el problema de la agrupación puede reducirse al problema de encontrar una función de distancia para ese tipo de datos. Por lo tanto, el diseño de la función de distancia se ha convertido en un área importante de investigación para la minería de datos.

Agrupación con datos de imagen

Los algoritmos de agrupamiento se han adaptado a los datos de imagen para diversos fines. Estos algoritmos se aplican en diferentes niveles de datos de imagen, desde el nivel de característica visual hasta el nivel de imagen e incluso el nivel de colección de imágenes.

Segmentación de imagen

Segmentar se refiere a un proceso que divide una imagen en regiones para poder simplificar su representación y de esta manera resulta más sencillo su análisis e interpretación. La finalidad de llevar a cabo una segmentación es enfatizar aquellas propiedades que son de interés.

La segmentación puede ser llevada a cabo mediante el espacio de color y sus respectivas bandas. Las imágenes son resaltadas de acuerdo a tres o cuatro valores establecido por un modelo o espacio de color. Por ejemplo se puede efectuar una segmentación de una Imagen RGB resaltando solo las bandas Rojo y Azul, o bien segmentar una imagen en un espacio de color $CIE L^*a^*b^*$ con la banda $*b$ para resaltar un rango de color azul. A este método se le conoce como *Segmentación por Bandas*.

Una vez que la segmentación fue llevada a cabo, es posible que la imagen requiera aplicar uno o varios filtros. Un filtro se refiere a aplicar técnicas de procesamiento en una imagen para modificar los valores de uno o varios píxeles, con el fin de obtener un valor deseado y adquirir cambios en la imagen que puedan beneficiar la apreciación o la detección de regiones u objetos en particular, existen muchos tipos de filtros que pueden ser usados aunque el resultado de cada filtro dependerá del valor de cada píxel y de sus vecinos. Por ejemplo, un filtro de suavizado reducirá los valores de los píxeles respecto a sus vecinos, esto se logra aplicando una función Gaussiana sobre los mismos.

También una práctica común en el procesamiento de imágenes es la extracción de un fondo para un realce en la zona de interés, el método usado para esto es mediante el manejo de umbrales o umbralización, que se refiere a reemplazar cada píxel de la imagen con un píxel de menor o mayor valor en intensidad, dependiendo de un parámetro previamente establecido. Este valor de umbral

dependerá de la imagen con la región u objeto a resaltar. Normalmente las imágenes son convertida a escala de grises o adquieren un valor binario (dos valores de píxel, negro o blanco). Por ejemplo se puede extraer un fondo agrupando dos clases de píxeles, de primer plano y de fondo. En este caso el umbral será aquel valor que separa las dos clases. De esta manera la imagen adquiere un valor binario en el que el fondo es separado de los objetos de primer plano.

2.5.2. Aprendizaje supervisado

Los algoritmos de aprendizaje supervisado crean automáticamente modelos para predecir salidas, ya sea para tareas de clasificación (salidas discretas) o de regresión (salidas continuas). La información de entrada dada a estos algoritmos son ejemplos, descritos generalmente con atributos o variables, asociados con una etiqueta. Cuando la etiqueta es nominal se conocen como algoritmos de clasificación, cuando es numérica se conoce como regresión o estimación (Aggarwal and Reddy, 2013)..

La meta de los algoritmos de clasificación es inducir automáticamente un modelo a partir de los datos para que dada la descripción de un nuevo ejemplo produzca una etiqueta de salida. En la tarea de clasificación existe una gran cantidad de algoritmos como árboles de decisión y máquinas de soporte vectorial.

La meta de los algoritmos de estimación o regresión es inducir automáticamente, a partir de los datos, un modelo que dada la descripción de un ejemplo produzca un valor continuo de salida. Algunos de los algoritmos más usados son las redes neuronales y la regresión lineal (Aggarwal and Reddy, 2013).

2.5.3. Aprendizaje por refuerzo

Un algoritmo de aprendizaje por refuerzo busca optimizar el resultado de un problema por medio de prueba y error. Todo problema de aprendizaje por refuerzo está compuesto por un agente y un entorno.

El agente se puede definir como una entidad con capacidades de memoria y deducción. Su misión es entrenarse en el entorno hasta alcanzar un desempeño óptimo. Desde el punto de vista técnico representa al algoritmo. Por otro lado, el entorno representa al problema a resolver; el contexto con el que interactúa el agente, es decir, su fuente de información. Siempre está estructurado como una secuencia de alternativas. En cada alternativa el agente realiza una acción, recibiendo a cambio una recompensa. Su conocimiento sobre el entorno se va completando a medida que acumula recompensas. El aprendizaje finaliza una vez el agente es capaz de encontrar la secuencia de acciones, de entre todas las posibles, que le reporta la mayor recompensa acumulada.

Uno de los algoritmos más conocidos es el de Q-learning, el cual ajusta gradualmente el valor de la recompensa total esperada de cada par estado-acción. El valor de cada par estado-acción se ajusta incrementalmente calculando la diferencia entre dicho valor y la suma de la recompensa recibida al tomar la acción y el máximo valor esperado de todos los siguientes pares estado-acción.

Algunos de los retos de esta área son cómo lidiar con espacios de estados y acciones continuos, cómo aprender con muchas variables, qué hacer en ambientes no estacionarios y cómo reducir la velocidad de aprendizaje (Morales Manzanares et al., 2019).

2.6. BIRCH

BIRCH es un algoritmo no supervisado que se utiliza para realizar agrupamientos jerárquicos en conjuntos de datos particularmente grandes. Una ventaja de BIRCH es su capacidad para agrupar puntos de datos métricos multidimensionales entrantes de forma incremental y dinámica en un intento de producir la agrupación de la mejor calidad para un conjunto dado de recursos (limitaciones de memoria y tiempo). En la mayoría de los casos, BIRCH solo requiere un solo escaneo de la base de datos (Aggarwal and Reddy, 2013).

Es local en el sentido de que cada decisión de agrupación se toma sin escanear todos los puntos de datos y agrupaciones existentes actualmente. Explora la observación de que el espacio de datos no suele estar ocupado de manera uniforme y que no todos los puntos de datos son igualmente importantes. Aprovecha al máximo la memoria disponible para obtener los mejores sub-clústeres posibles mientras minimiza los costos de entrada/salida. También es un método incremental que no requiere todo el conjunto de datos por adelantado.

Se basa en una estructura de datos jerárquica llamada CF Tree (Clustering Feature Tree). El algoritmo BIRCH toma como entrada un conjunto de N puntos de datos, representados como vectores con valores reales, y un número deseado de grupos K ; ver Algoritmo 1.

Variables asignadas:

- Clustering feature $CF = (N, LS, SS)$
- N : número de puntos de datos.
- LS : suma lineal de N puntos.
- SS : suma cuadrada de N puntos.

Dado un conjunto de N puntos de datos dimensionales, la función de agrupación CF del conjunto se define como el triple de $CF = (N, \overrightarrow{LS}, SS)$.

Donde se expresa la función: $\overrightarrow{LS} = \sum_{i=1}^N \overrightarrow{X_i}$

Siendo lo anterior la suma lineal, de manera que: $SS = \sum_{i=1}^N \overrightarrow{(X_i)^2}$ es el cuadrado de la suma de los puntos de datos.

- El árbol CF es un árbol balanceado en el que los nodos internos almacenan las sumas de los CF de sus descendientes.
- Un árbol CF tiene dos parámetros: el número máximo de hijos de un nodo y el diámetro máximo de los subclusters almacenados en las hojas del árbol.

Para cada punto, se encuentra la hoja más cercana, se añade a su cluster y se actualiza su CF .

Si el diámetro del subcluster es mayor que el diámetro máximo admitido, se divide la hoja. La principales ventajas y desventajas del BIRCH son:

- Escalabilidad lineal $O(n)$: se construye un buen conjunto de clusters con un simple recorrido del conjunto de datos y se puede mejorar su calidad con unos pocos recorridos adicionales.

Desventajas:

- Sólo es válido para datos de tipo numérico.
- Sensible al orden de presentación de los datos.

Algoritmo 1: Algoritmo Birch.

```

input :  $D = \{t_1, t_2, \dots, t_n\}$  ;                               /* Grupos de elementos. */
           $T$  ;                                           /* Umbral o Threshold para el árbol CF */
output:  $K$  ;                                           /* Conjunto de clústers */
begin
  foreach  $t_i \in D$  do
    Determinar el nodo correcto para la inserción de  $t_i$ ;
    if las condiciones del umbral se cumplen then
      | añadir  $t_i$  al clúster y actualizar CF;
    else
      | if hay espacio para agregar  $t_i$  then
        | Insertar  $t_i$  como solo un clúster y actualizar CF;
      | else
        | Dividir la hoja o nodo y distribuir las propiedades de CF;
      | end
    end
  end
end

```

2.7. Validación de modelos no supervisados

Es de suma importancia tener los resultados de un algoritmo de clustering correctamente validados, sin embargo el principal problema es identificar una agrupación viable o aceptable. Por ello, existen técnicas para poder llevar a cabo validaciones en agrupamientos o clustering.

Existen dos tipos de validaciones (Aggarwal and Reddy, 2013):

- Validación interna: basado únicamente en validar el clustering con la información de los datos.
- Validación externa: basado en validar la efectividad del agrupamiento con información ajena al propio algoritmo.

Para la validación interna, Aggarwal and Reddy (2013) menciona que se puede implementar varias técnicas dependiendo los campos a donde se quiera aplicar, como minería de datos, recuperación de

información, aprendizaje automático y estadísticas. Las propiedades de estas medidas de validación se investigan en seis aspectos diferentes: monotonicidad, ruido, densidad, subgrupos, distribución sesgada y datos de formas arbitrarias. Sin embargo, para el procesamiento de imágenes se han utilizado dos:

- **Cohesión:** esto mide cuán estrechamente relacionados están los objetos en un clúster. Un grupo de medidas evalúa la compactación del clúster en función de la varianza. Una varianza más baja indica una mejor compatibilidad. Además, numerosas medidas estiman la compactación del clúster en función de la distancia, como la distancia máxima o promedio por pares, y la distancia máxima o promedio basada en el centro.
- **Separación.** Esto mide cuán distinto o bien separado está un clúster de otros clústeres. Por ejemplo, las distancias por pares entre los centros de los grupos y las distancias mínimas por pares entre los objetos en diferentes grupos se usan ampliamente como medidas de separación. Además, las medidas basadas en la densidad se utilizan en algunos índices.

El procedimiento general para determinar la mejor partición y el número de clúster óptimo de un conjunto de objetos mediante el uso de medidas de validación interna es el siguiente Aggarwal and Reddy (2013).

- Inicialice una lista de algoritmos de agrupación que se aplicarán al conjunto de datos.
- Para cada algoritmo de agrupación, use diferentes combinaciones de parámetros para obtener diferentes resultados de agrupación.
- Calcule el índice de validación interna correspondiente de cada partición que se obtuvo en el punto anterior.
- Elija la mejor partición y el número de clúster óptimo según los criterios.

Las métricas de validación interna pueden usarse para escoger el mejor algoritmo de clustering, así como el número de clúster óptimo sin ningún tipo de información adicional. En la práctica, la información externa, como las etiquetas de las clases, por lo general no se encuentra disponible en muchos escenarios de aplicación Aggarwal and Reddy (2013).

Se propone la evaluación de resultados mediante en el coeficiente de Silhouette, debido a sus características internas o de cohesión en el mismo cluster y externas o de separación en el cluster más cercano, donde el coeficiente para un punto o píxel está definido como: $s(x) = \frac{b(x)-a(x)}{\max\{a(x),b(x)\}}$ (Aggarwal and Reddy, 2013) ver Figura 2.17. Los valores expresados representan:

- El valor $a(x)$ es la cohesión, donde la distancia promedio de x es a todos los demás puntos en el mismo cluster.
- El valor de $b(x)$ es la separación, donde la distancia promedio de x es a todos los demás puntos en el cluster más cercano.
- El valor de $s(x)$ puede variar entre -1 y 1.
- El valor -1 significa mal agrupamiento.

- El valor 0 se refiere a que no hay valor.
- El valor 1 es buen agrupamiento.

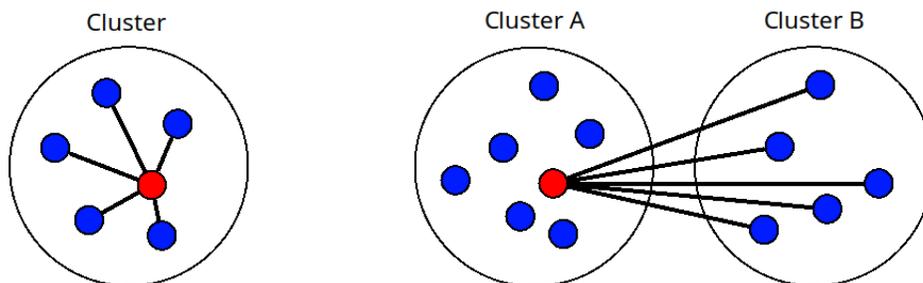


Figura 2.17: Valor de distancia de $a(x)$ y $b(x)$.

Capítulo 3

Revisión sistemática de la literatura

En este capítulo se ilustra el método que se siguió para realizar la presente revisión sistemática de la literatura. El método utilizado se basa en las recomendaciones hechas en Keele (2007), el cual consta de tres fases principales: planificación de la revisión, desarrollo de la revisión y reporte de resultados.

3.0.1. Planificación de la revisión

La planificación es la primera etapa de la revisión sistemática, en esta etapa se desarrolla el protocolo que guiará la revisión. En este trabajo se consideraron las siguientes actividades: (1) identificación de la necesidad de la revisión, (2) formulación de las preguntas de investigación, (3) definición de la cadena de búsqueda y (4) selección de las fuentes de datos. Las cuales se describen brevemente a continuación.

(1) Identificación de la necesidad para realizar la revisión sistemática

Con el abaratamiento de los VANT y los avances tecnológicos en sistemas de control de vuelo y navegación así como en el diseño de sensores más potentes, se ha popularizado el desarrollo de aplicaciones civiles basadas en el procesamiento de imágenes adquiridas desde VANT, principalmente en áreas relacionadas con el monitoreo de cultivos o áreas forestales. En este tipo de aplicaciones, la extracción de información a partir de las imágenes juega un rol fundamental, por lo tanto, en este trabajo se busca revisar qué técnicas de procesamiento de imágenes y extracción de objetos se han utilizado en las áreas de detección de vegetación, conteo de plantas e inventario de árboles.

(2) Establecimiento de las preguntas de investigación

PI01: ¿Cómo ha evolucionado el interés por usar VANT en la detección, identificación y conteo de plantas?

PI02: ¿Cuáles son las principales fuentes de información en el tema de conteo de plantas usando VANT?

- PI03: ¿Cuáles son los principales problemas abordados con la detección de la vegetación usando imágenes tomadas desde VANT?
- PI04: ¿Qué plantas han sido las más estudiadas usando imágenes adquiridas desde VANT?
- PI05: ¿Qué técnicas son las más utilizadas para el conteo de plantas usando imágenes tomadas desde VANT?
- PI06: ¿Qué tipos de imágenes se usan en estudios relacionados con la detección de plantas usando imágenes VANT?

(3) Creación de la cadena de búsqueda

Para la creación de la cadena de búsqueda, se identificaron las palabras clave; las cuales fueron extraídas de las preguntas de investigación. Las palabras clave fueron las siguientes: *Forest, Tree, Plant, Crop, Inventory, Detection, Counting, Identification*, and “*Unmanned Aerial Vehicle*”. La cadena de búsqueda se obtuvo a partir del agrupamiento de las palabras clave y el uso de los operadores lógicos AND y OR; como resultado, se obtuvo la siguiente cadena:

(Forest OR Plant OR Tree OR Crop) AND (Inventory OR Detection OR Counting OR Identification) AND (UAV OR “Unmanned Aerial Vehicle”)

(4) Identificación de las fuentes de datos

Atendiendo las recomendaciones propuestas por Keele (2007), sobre sus lecciones aprendidas para los procedimientos de búsqueda de datos; para este estudio, se decidió utilizar las siguientes fuentes de datos: (1) ACM Digital Library, (2) IEEE Xplore Digital Library, (3) ScienceDirect, Wiley y SCOPUS. Además, se decidió consultar la base de datos Multidisciplinary Digital Publishing Institute por sus siglas en inglés (MDPI) debido a su amplio contenido de acceso abierto en áreas relacionadas directamente con el presente estudio (percepción remota, sensores, y medioambiente).

3.0.2. Desarrollo de la revisión

El objetivo de esta segunda fase del método de revisión sistemática es identificar tantos estudios primarios como sea posible usando una estrategia de búsqueda imparcial; dichos estudios primarios permitirán responder a las preguntas de investigación. Para llevar a cabo el desarrollo de la presente revisión sistemática se deben realizar las siguientes dos actividades: (1) seleccionar los estudios primarios y (2) extraer y sintetizar la información.

(1) Seleccionar los estudios primarios

Para garantizar que la estrategia de búsqueda de los estudios primarios sea imparcial, se definieron algunos criterios de inclusión y exclusión, y se siguió un procedimiento bien definido.

Criterios de inclusión.

- a) (CI01) estudios en idioma inglés.

Tabla 3.1: Número de investigaciones publicadas y estudios primarios

Fuentes de datos	Búsqueda	Estudios primarios
ScienceDirect	84	18
IEEEExplore Digital Library	40	14
ACM Digital Library	2	1
Wiley	16	1
Scopus	71	12
MDPI	82	17
Total	295	63

- b) (CI02) estudios publicados desde el año 2010 hasta mayo de 2019.
- c) (CI03) estudios que contengan al menos dos palabras clave en el título.
- d) (CI04) estudios relacionados con la detección de plantas (inventario, conteo, identificación y detección).

Criterios de exclusión.

- a) (CE01) estudios duplicados.
- b) (CE02) estudios que no se basen en el uso de imágenes tomadas desde vehículos aéreos no tripulados.

Procedimiento. Para seleccionar los estudios primarios se realizaron los siguientes pasos:

- a) Adaptar la cadena de búsqueda al motor de la fuente de datos seleccionada.
- b) Aplicar los criterios de inclusión CI01 y CI02.
- c) Aplicar el criterio de inclusión CI03.
- d) Leer resumen, introducción y conclusiones, y aplicar el criterio de inclusión CI04 y los criterios de exclusión.

Según Wohlin (2014), el proceso de revisión sistemática puede ser ampliado usando un enfoque de búsqueda conocido como *snowballing*. El *snowballing* se refiere al uso de la lista de referencias de un documento para identificar documentos adicionales.

En la Tabla 3.1, se resume el número de trabajos de investigación publicados durante el periodo definido para el presente estudio (véase la columna 2), así como la selección de los estudios primarios (véase la columna 3). Durante el proceso de búsqueda, indexación, y clasificación varios estudios aparecieron duplicados. Para gestionar las referencias y eliminar los duplicados se utilizó la herramienta Mendeley®. Tras aplicar el procedimiento definido para la selección de los estudios primarios se seleccionaron 63 estudios.

Finalmente, se llevó a cabo una etapa de *snowballing* y se verificaron las referencias de los estudios seleccionados para no perder ningún documento relevante; como resultado, se agregaron 2 artículos más. Por lo tanto, se seleccionaron en total 65 artículos para responder a las preguntas de investigación. El Anexo C muestra el listado de los estudios primarios.

(2) Extracción y síntesis de la información

Antes de realizar la extracción de la información, los estudios primarios fueron organizados por medio de la herramienta de gestión de archivos PDF Mendeley®. Para llevar a cabo la presente actividad se diseñó una hoja de cálculo donde se recopilaron los siguientes datos de cada estudio primario: título, autor, año, objetivo, tipo de vegetación, técnicas utilizadas, tipo de imagen, tipo de manuscrito, título de la fuente. Para extraer y analizar la información de todos los artículos, se siguieron los siguientes pasos: (1) La información fue extraída por el primer autor, y (2) por separado se verificó la información por los otros autores.

3.1. Análisis de los resultados

En esta sección se muestran los resultados obtenidos de la revisión sistemática de la literatura, los cuales permiten conocer el panorama general de la detección de plantas usando imágenes adquiridas desde VANT. Los resultados se organizan por pregunta de investigación.

PI01: ¿Cómo ha evolucionado el interés por usar VANT en la detección, identificación y conteo de plantas?

Los estudios identificados se analizaron durante la última década para conocer la frecuencia y la evolución del número de publicaciones. En la Figura 3.1, se muestran los resultados de este proceso de análisis, allí se puede observar que recientemente se han incrementado notablemente la cantidad de estudios relacionados con la detección de vegetación utilizando imágenes VANT; cabe mencionar que la presente revisión sistemática se concluyó en junio de 2019, lo cual pudiera estar influyendo en la caída del número de estudios reportados con respecto al 2018.

PI02: ¿Cuáles son las principales fuentes de información en el tema de conteo de plantas usando VANT?

De los 65 estudios que componen el conjunto de estudios primarios de la presente revisión sistemática, 52 fueron publicados en revistas y 13 en conferencias. En la Tabla 3.2, se muestran las revistas más activas en el área de detección de plantas usando imágenes VANT. Destaca la revista *Remote Sensing* de la editorial MDPI, en dicha revista se han publicado 13 de los estudios primarios seleccionados en esta revisión.

PI03: ¿Cuáles son los principales problemas abordados con la detección de la vegetación usando imágenes tomadas desde VANT?

La Tabla 3.3, muestra los tipos de problemas abordados mediante el procesamiento de imágenes adquiridas desde un VANT. Son 7 los estudios relacionados con problemas de conteo, 48 estudios

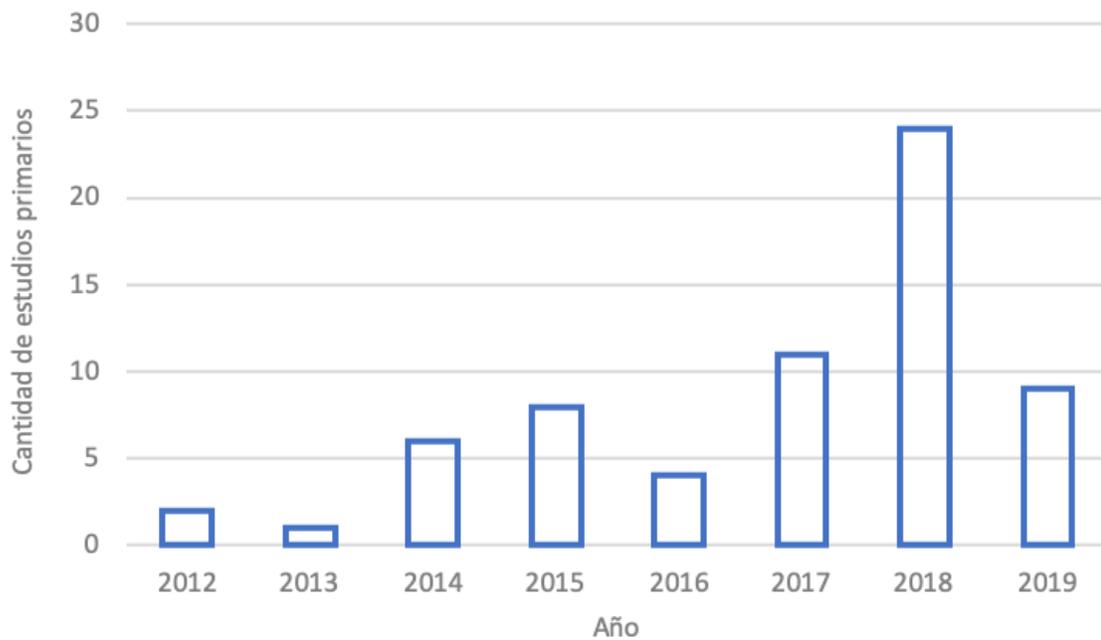


Figura 3.1: Publicaciones por año

se enfocan en la detección de plantas a nivel de bosques, plantaciones, surcos, árboles, arbustos, e incluso frutos, 7 estudios se centran en la identificación de plantaciones, hierba y árboles; finalmente, 3 estudios se centran en realizar inventarios de árboles.

Tabla 3.2: Revistas en las cuales se ha publicado alguno de los estudios primarios

Revistas	No. de estudios
Otras	16
Remote Sensing	13
Computers and Electronics in Agriculture	6
IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing	3
Remote Sensing of Environment	3
Sensors	3
IEEE Geoscience and Remote Sensing Letters	2
IFAC-PapersOnLine	2
Journal of the Indian Society of Remote Sensing	2
Urban Forestry & Urban Greening	2
Total	52

Tabla 3.3: Tipos de problemas abordados

Problema	Objeto	Cantidad de estudios primarios
Conteo	Árboles	4
	Cultivos	1
	Hierba	2
Detección	Árboles	21
	Arbustos	7
	Bosque	3
Cultivos	Fruta	1
	Hierba	9
	Manglares	1
	Surcos	3
Identificación	Árboles	2
	Cultivos	3
	Hierba	2
Inventario	Bosque	3
Total		65

PI04: ¿Qué plantas han sido las más estudiadas usando imágenes adquiridas desde VANT?

En la Figura 3.2, se muestra un gráfico de pastel el cual proporciona la información referente al tipo de planta que se han estudiado, se observa que la detección de maleza es lo que se ha estudiado más usando imágenes VANT; los árboles de cítricos, palmeras y la vid también han sido ampliamente estudiados.

PI05: ¿Qué técnicas son las más utilizadas para el conteo de plantas usando imágenes tomadas desde VANT?

Para atender el problema de conteo de plantas, se observó que la técnica más usada son las redes neuronales convolucionales, Convolutional Neural Network por sus siglas en inglés (CNN), en total 11 estudios utilizaron dicha técnica, véase el Anexo C. Es de resaltar que el primer estudio que se encontró fue publicado en 2017, ver EP08. Otra técnica muy utilizada, son las máquinas de soporte vectorial (SVM, por sus siglas en inglés), dicha técnica fue utilizada en 7 estudios primarios. Las SVM, son una técnica madura de aprendizaje máquina y ampliamente utilizada en problemas de clasificación y regresión, por lo cual no es extraño que el primer estudio primario date del año 2012, véase el EP33; en dicho estudio se propone una SVM para detectar coronas de árboles.

Cabe mencionar que el software utilizado para procesar las imágenes es muy variado, desde lenguajes de programación de propósito general `Matlab`, `Python` y `C++`, hasta software especializado como `TerraScan`, `Agisoft PhotoScan` y `Pix4D`.

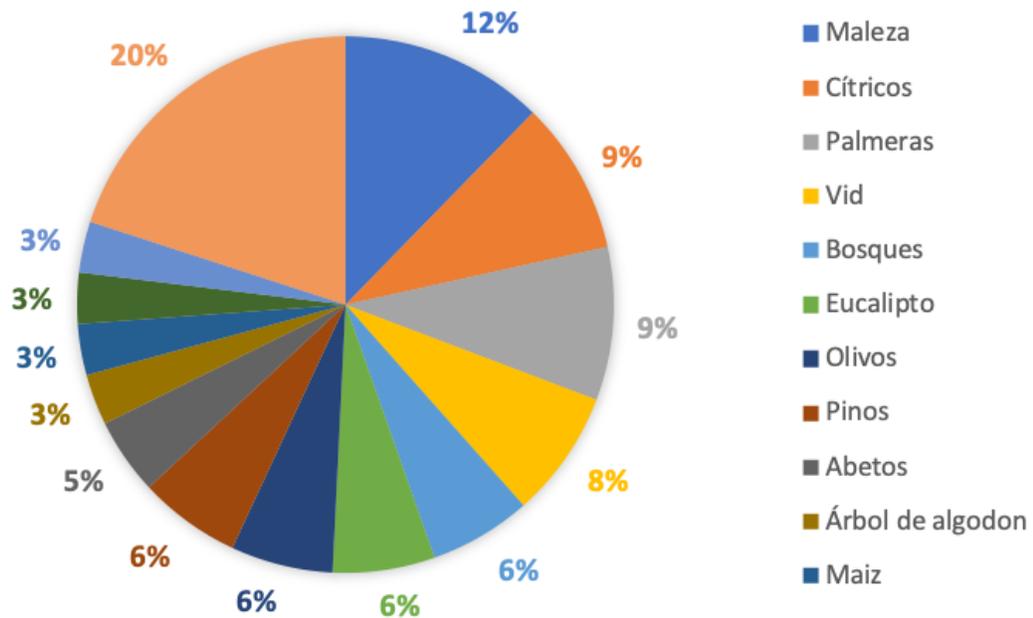


Figura 3.2: Plantas estudiadas

PI06: ¿Qué tipos de imágenes se usan en estudios relacionados con la detección de plantas usando imágenes VANT?

Castro et al. (2019) reportaron que los espacios de color juegan un papel fundamental en los estudios relacionados con el procesamiento de datos obtenidos desde sensores montados en VANT. Entre los principales espacios de color se encuentran: RGB (por sus siglas en inglés Red, Green, Blue), HSV (por sus siglas en inglés Hue, Saturation, Value), y Commission internationale de l'éclairage por sus siglas en francés (CIE) (también conocido como CIE L*a*b*) el cual fue definido por la Comisión Internacional de Iluminación (CIE). En la Figura 3.3, se muestra que el espacio de color más utilizado en los estudios primarios es el RGB, de hecho, más del 50% de las investigaciones lo han utilizado; sin embargo, se observan algunos trabajos que utilizan los espacios de color tribanda CIE Lab y HSV. Por otra parte, se encontró que un 18.5% de los estudios primarios utilizó imágenes multiespectrales y el 6.2% datos LiDAR. Cabe mencionar que los estudios que basados en imágenes multiespectrales utilizaron principalmente las cámaras Canon S110 NIR, Tetracam mini-MCA-6 y Parrot Sequoia.

Las imágenes hiperespectrales, a pesar de tener la ventaja de la gran cantidad de datos que contienen se han utilizado muy poco (1.5%), tal vez debido al alto coste de los sensores de este tipo.

3.2. Conclusiones de la revisión sistemática

En este trabajo, se realizó una revisión sistemática de la literatura referente al uso de VANT en aplicaciones agrícolas y forestales, en específico se abordó el tema de la detección de plantas usando

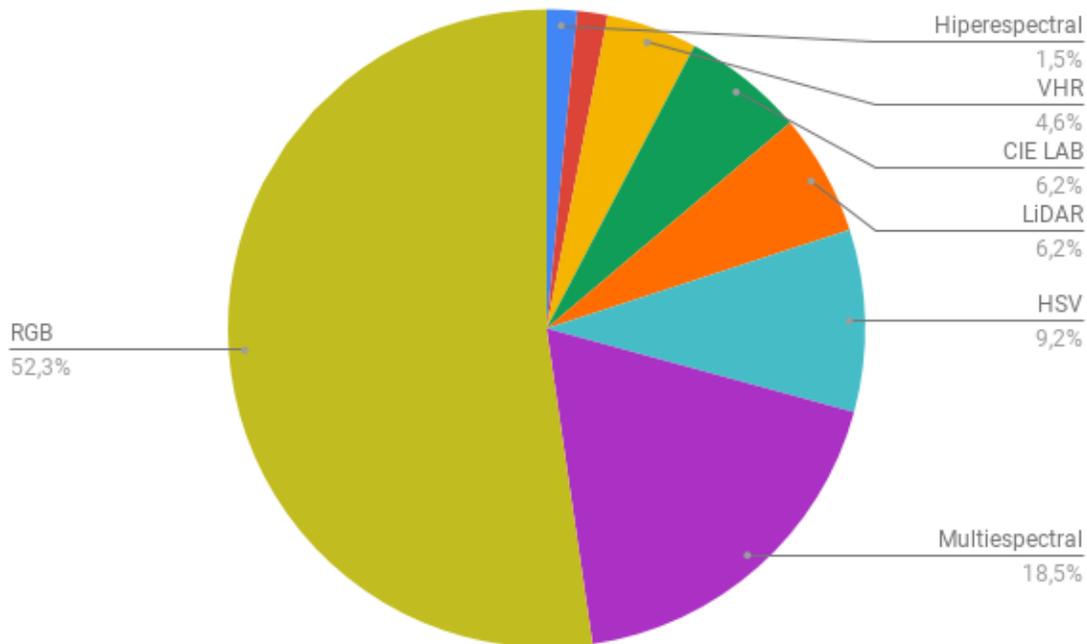


Figura 3.3: Tipos de imágenes o datos utilizados

imágenes adquiridas desde VANT.

Se observó, que desde el año 2012 dada la popularidad que han alcanzado los VANT y los avances tecnológicos en el desarrollo de sensores, se han venido desarrollando cada vez más aplicaciones relacionadas con la detección de plantas. Los estudios abarcan diferentes niveles de granularidad, desde la detección de bosques, parcelas, surcos, hasta la identificación de árboles, arbustos y hierba, pasando por el conteo de plantas y la realización de inventarios de árboles.

La mayoría de los estudios primarios (80%) fueron publicados en revistas científicas, siendo las revistas Remote Sensing de la editorial MDPI y la revista Computers and Electronics in Agriculture de la editorial Elsevier, las más activas en estos temas.

También se mostró que la mayoría de los estudios primarios estudiaron la maleza, los cítricos y los arboles de palmera; las técnicas de aprendizaje más populares son las CNN y SVM. Con respecto al software utilizado para procesar las imágenes se ha utilizado desde lenguajes de programación de propósito general Matlab, Python y C++, hasta software especializado como TerraScan, Agisoft PhotoScan y Pix4D. Finalmente, el espacio de color más utilizado es el RGB. Con respecto al tipo de aeronave, mas del 60% de los VANT utilizados en los estudios primarios fueron vehículos multirrotor; los demás fueron VANT de ala fija. Con respecto a los sensores más utilizados la mayoría son del tipo RGB; con respecto a los estudios basados en cámaras multiespectrales se utilizaron principalmente los siguientes equipos: cámaras Canon S110 NIR, Tetracam mini-MCA-6 y Parrot Sequoia.

Capítulo 4

Materiales y métodos

4.1. Equipo

Para la toma de imágenes aéreas, se ha optado por utilizar el VANT Parrot BlueGrass® Figura 4.1, debido a que presenta tecnología orientada en el sector agrícola. Cuenta con seis sensores, cámara RGB y cámara multiespectral, además de sus accesorios y componentes para el vuelo.



Figura 4.1: Equipo Parrot BlueGrass en vuelo.

Las especificaciones del fabricante Parrot (2019) son las siguientes:

■ Sensores de vuelo

- Global Position System por sus siglas en inglés (GPS) + GLONASS integrados
- Inertial Navegate System por sus siglas en inglés (INS)
- Altímetro
- Ultrasonidos
- Cámara vertical de flujo óptico

■ Sensor de luz solar (Ver Figura 4.2)

- Tamaño: 47x39,6x18,5 mm
- Peso: 35 gramos
- 4 sensores espectrales (filtros idénticos al cuerpo)
- Sistema de posicionamiento global o GPS

- Unidad de medida inercial o Inertial Measure Unit por sus siglas en inglés (IMU) y magnetómetro
- Ranura para tarjeta tipo SD o Secure Digital por sus siglas en inglés (SD)
- Potencia: 1 Watt



Figura 4.2: Sensor de luz solar.

■ **Cámara RGB (Ver Figura 4.3)**

- Foto: cámara gran angular de 14MP
- Video: 1080p Full HD
- Transmisión de vídeo: 360p / 720p
- Memoria interna de vídeo: De 32 GB

■ **Cámara Multiespectral (Ver Figura 4.4)**

- Resolución: 1,2 Mpx, 1280x960 píxeles
- HFOV: 61.9°.
- VFOV: 48.5°.
- DFOV: 73.7°.

■ **Bandas separadas**

- Verde: 550 NM +/- 40 NM



Figura 4.3: Cámara RGB.



Figura 4.4: Cámara Multiespectral.

- Rojo: 660 NM +/- 40 NM
 - Red Edge: 735 NM +/- 10 NM
 - Infrarrojo cercano (NIR): 790 NM +/- 40 NM
- **Segunda cámara RGB**
- Resolución: 16 MP, 4608x3456 píxeles

- HFOV: 63,9°.
- VFOV: 50.1°.
- DFOV: 73.5°.

4.2. Metodología propuesta

La metodología propuesta en el presente trabajo de investigación consta de 4 etapas, véase la Fig. 4.5. La etapa 1 incluye las actividades relacionadas con la planeación del vuelo y la adquisición de las imágenes. En la etapa 2, las imágenes son preprocesadas con el objetivo de crear un ortomosaico y delimitar la región de interés. En la etapa 3, el ortomosaico es procesado aplicando técnicas de segmentación. Finalmente, en la etapa 4 se usa un método de aprendizaje no supervisado para identificar las plantas de agave e inventariarlas.

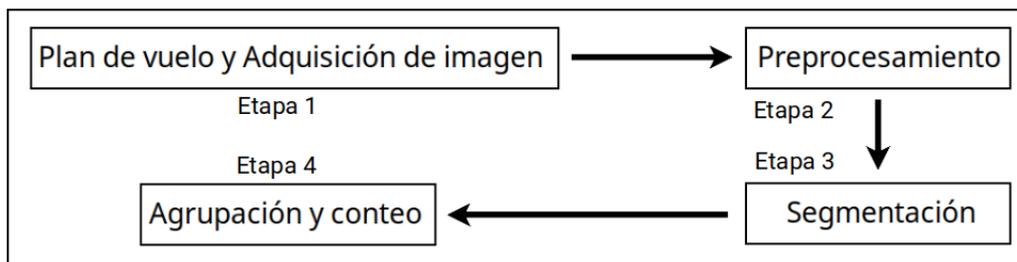


Figura 4.5: Metodología utilizada en el presente trabajo.

En las siguientes secciones se detallan las actividades involucradas en cada etapa de la metodología propuesta.

4.2.1. Planeación de vuelo y adquisición de imágenes

Para la toma de imágenes en un terreno, el vuelo debe realizarse en pasadas paralelas teniendo un recubrimiento longitudinal y otro recubrimiento transversal de una pasada sobre otra. Es importante tomar en cuenta que cada fotografía tiene una parte común con la anterior a la que se llama zona de traslape u *overlap*, expresándose su valor en porcentaje de la superficie de la foto como lo indica la Figura 4.6.

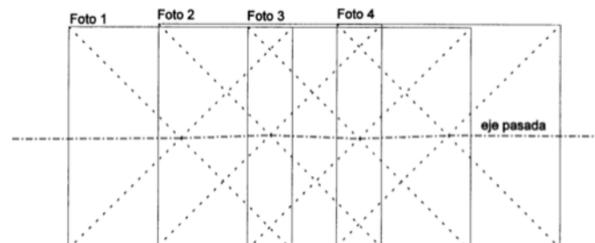


Figura 4.6: Traslape.

Existen tres tipos de vuelo:

- Vuelo Naridal. Es el tipo de vuelo común, el eje de levantamiento es completamente vertical.
- Vuelo Vertical. Es aquel en el que el ángulo de separación entre la vertical y el eje del levantamiento es menor a 3° .
- Vuelo Inclinado. Es aquel vuelo donde el ángulo es mayor a 3° .

Cuando las fotografías se trabajan en estereoscópicas (aquellas que perciben relieve y distancia), es necesario el recubrimiento o solape. Normalmente debe haber un 80 % de recubrimiento o solape de un vuelo en un terreno si se desea obtener mayores precisiones. De lo contrario, un recubrimiento del 20 % no se logra conseguir tal precisión y no se logra una imagen estereoscópica. Sin embargo, se puede obtener un mosaico de un terreno para su estudio planimétrico, agronómico, topográfico, forestal, arqueológico, etc.

Para facilitar el vuelo y la toma de imágenes aéreas, el vuelo debe hacerse regular de este a oeste, sin importar que el terreno sea o no regular. De esta manera se facilita la planificación y la obtención de fotografías de buena calidad.

Para los aspectos en las condiciones de vuelo, el principal problema radica en las condiciones geográficas y ambientales. Sin embargo, para corregir estos problemas es necesario que se cumplan con los siguientes requisitos:

- El mejor caso general se considera un vuelo donde el entorno sea libre de nubes, humo, neblina y polvo en el viento.
- El mínimo en viento y turbulencias.
- Las superficies cubiertas de nieve dificultan bastante la fotointerpretación.
- La elevación del sol influye significativamente las sombras proyectadas en la superficie.

Para cumplir con las normas locales y de la región, el vuelo del VANT se ha llevado a cabo tomando como consideración la norma *NOM-107-SCT3-2019* que establece los requerimientos para operar un sistema de aeronave pilotada a distancia en el espacio aéreo mexicano. Tanto el VANT como el vuelo entra en las pautas de la sección 6.2: *Sistemas de aeronaves pilotadas a distancia RPAS pequeños para uso Privado No comercial o Comercial* de la norma.

4.2.2. Preprocesamiento

Para procesar las fotografías, es necesario establecer un flujo de trabajo mediante el software de Agisoft llamado Metashape®. Primero se debe añadir el grupo de fotos con la opción en el menú *Flujo de trabajo > añadir fotos*. Una vez cargadas o añadidas, es necesario alinearlas u orientarlas según los píxeles que tengan en común, usando la opción *Flujo de trabajo > Alinear fotos*, como se muestra en la Figura 4.7. Para la alineación se debe considerar lo siguiente:

- Que la precisión se alta para una mejor referencia en las fotografías en su alineación.
- Implementar una preselección genérica para optimizar el calculo generando una selección de pares de imágenes superpuestas.

- Implementar una preselección de referencia para reducir el tiempo de procesamiento usando las coordenadas de los fotocentros de las imágenes.

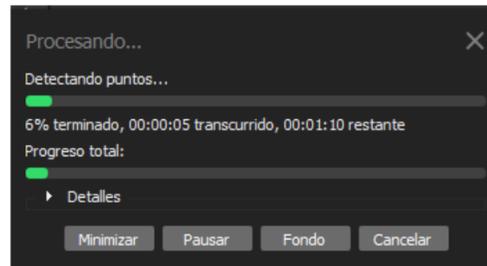


Figura 4.7: Dialogo de progreso en el proceso de alineación en el software Metashape.

Cuando las imágenes fueron agregadas y alineadas, se debe crear una nube de puntos densa para obtener información de profundidad basado en la información de las imágenes. Se selecciona la opción *Flujo de trabajo*>*Crear nube de puntos densa* en el menú principal, estableciendo el valor de calidad alta o dependiendo los recursos de procesamiento del equipo de cómputo, Figura 4.8.

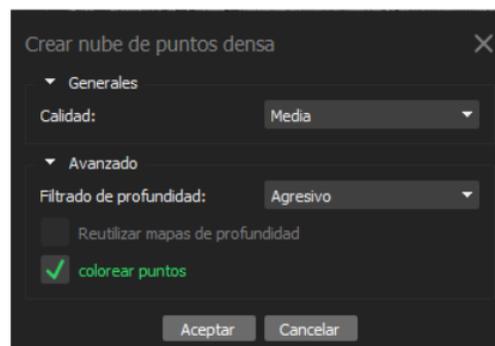


Figura 4.8: Parámetros de nube de puntos en el software Metashap.

Es posible clasificar la nube de puntos en caso de que el terreno tenga pendientes o sea llano, también se establece la distancia máxima de un punto que forma parte a un terreno y especificar el tamaño de la celda con respecto al tamaño del área que no contiene puntos de referencia. Estos parámetros se configuran con las opciones *Ángulo máximo*, *Distancia máxima* y *Tamaño de la celda* en la opción *Herramientas*>*nube de puntos densa*>*Clasificar puntos del terreno*.

Después de crear la nube de puntos densa, es posible generar un modelo de malla mediante la opción *Flujo de trabajo*>*Crear malla* en el menú principal. Se consideran los parámetros *Tipo de superficie* para especificar el relieve del terreno, *Especificar la fuente de datos* con la nube de puntos densa creada anteriormente y el *Número de poligonos* para dar resultado más detallados en la superficie del terreno.

La creación de ortomosaico se utilizan para generar imágenes de alta resolución a partir de un modelo reconstruido. La aplicación más común es el procesamiento de datos de levantamientos fotográficos aéreos, pero también puede ser útil cuando se requieren visualizaciones detalladas.

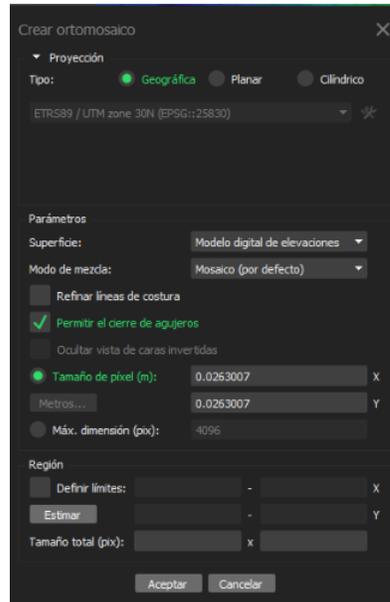


Figura 4.9: Menú Ortomosaico.
Fuente: Agisoft Software.

Mediante la herramienta Agisoft Metashape se puede construir un ortomosaico a partir de las fotografías tomadas por el VANT. Mediante el menú *Flujo de trabajo*, *Crear ortomosaico*, asignado las coordenadas y estableciendo la proyección como geográfica (Ver Figura 4.9).

Si la proyección requiere de un sistemas de coordenadas locales, se elige entonces la opción *Planar* en lugar de *Geográfica*, de esta manera se puede establecer las coordenadas. Se puede optar también por la opción *Cilíndrico* si el objeto de estudio tiene un aspecto cilíndrico.

En los parámetros se puede configurar las opciones de superficie donde el modo malla es la más común para levantamientos de terrenos. Después la opción *Modo de mezcla* se refiere a la manera de integrar todas las imágenes capturadas, ya sea por medio de un mosaico, o con la opción *Promedio* que realiza un promedio del ponderado de todos los píxeles de las fotos individuales. Se puede elegir *refinar las líneas de costura* para realizar automáticamente las líneas de unión, *Permitir el cierre de agujeros* que se refiere a evitar áreas sin color con un efecto *sal y pimienta*, por último la opción *Ocultar vistas de caras invertidas* se refiere a la resolución del muestreo de la tierra.

Una vez creado el ortomosaico, puede haber zonas que no requieren atención e incluso puede afectar en el análisis y estudios de los objetos, se requiere realizar un recorte de tal manera que solo se pueda apreciar aquella zona de interés. Para esto se utiliza el software QGIS cargando la imagen de ortomosaico.

Mediante la opción de *Añadir polígono* se selecciona el perímetro del terreno para después trazar mediante una forma de polígono el área de interés, ver Fig. 4.10a. Teniendo el área de interés seleccionada, se selecciona del menú *Raster*, *Extracción*, *Cortar ráster por capa de mascara* o bien de no contar con una capa puede seleccionar la opción *Cortar por extensión...* como se muestra en la Fig. 4.10b.

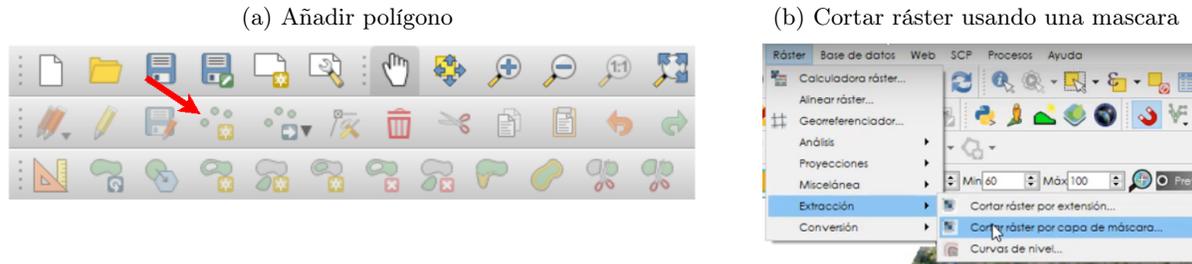


Figura 4.10: Opción: Recortar ortomosaico usando un polígono para seleccionar la región de interés con el software QGIS.

Método de segmentación propuesto

Una vez que la imagen ha sido preprocesada usando los softwares Agisoft Metashape y QGIS, para la creación del ortomosaico y el recorte del área de interés respectivamente; el siguiente paso de la metodología propuesta es la segmentación de la imagen. La segmentación consta 7 pasos, los cuales se describen a continuación.:

1. Cargar la imagen en formato RGB, producto de recortar el área de interés del ortomosaico creado.
2. Redimensionar la imagen, dado el gran tamaño de la imagen de entrada es de 31,425 x 2,3161 con una resolución de 7.48 mm por píxel, se propone cambiarle las dimensiones de tal manera que sea más sencillo de procesar.
3. Convertir la imagen al espacio de colores CIEL^{*}a^{*}b^{*}. Dado el color azulado característico del *agave tequilana weber* var. azul (Calvario Sánchez, 2019), se propone el uso del espacio de color CIEL^{*}a^{*}b^{*} porque este espacio de color tiene mayor perceptibilidad con la visión humana y comparado con el RGB es más rápido hacer correcciones eficientes de color en CIEL^{*}a^{*}b^{*}, esto se debe a que la luminosidad es completamente ignorada en los canales A y B por lo tanto la presencia de errores es mínima.
4. Separación de la imagen por cada canal. Este paso es necesario para reducir la dimensionalidad del problema y solo trabajar con la banda b^{*}.
5. Crear una máscara basada en la técnica de umbralización. Se propone la umbralización del canal b^{*} usando el rango de valores b^{*}, 120, 135 donde b^{*} es también el espacio de color que oscila del azul al amarillo, mientras que rango de color se encuentra entre los 120 y 135nm el cual se refleja el color azul del agave.
6. Aplicar el filtro bilateral. Se aplica este filtro para preservar los bordes y reducir el ruido para el suavizado de la imagen.

- L para la luminiscencia.

- a^* para los componentes verde y rojo
 - b^* para los componentes azul y amarillo
7. Aplicar el filtro gaussiano. Se aplica este filtro para suavizar zonas en las que los bordes son demasiado marcados o el contraste es muy alto.

4.3. Método propuesto para el conteo de agaves

Una vez que la imagen de entrada ha sido segmentada, el siguiente paso es procesarla para resolver el problema de conteo de agaves. A continuación, se describen los pasos que incluye el método de conteo propuesto.

1. Leer la imagen segmentada.
2. Procesar la imagen segmentada. Dadas las características irregulares en los terrenos donde se cultiva el agave, el tamaño de las plantas de agave, la maleza, los diferentes niveles de iluminación, el tipo de surco, la separación entre cada planta, entre otras, se propone el uso de una ventana de 10X10 píxeles para identificar todos aquellos puntos que correspondan a cultivos de agave.
3. Agrupar los puntos encontrados en el paso anterior. Debido a las características irregulares de los cultivos de agave, se propone el uso de un algoritmo de aprendizaje no supervisado que agrupe los puntos identificados como cultivos de agave en el paso anterior. Para llevar a cabo esta tarea se propone el uso del algoritmo Birch ya que al ser un algoritmo de agrupamiento o Clustering busca similitudes en los datos dentro de cada grupo mediante métricas multi-dimensionales entrantes, siendo un algoritmo utilizado para el análisis estadístico de datos y reconocimiento de patrones en análisis de imágenes.
4. Finalmente, el conteo de cada planta de agave corresponderá a cada uno de los puntos detectados por el algoritmo Birch.

El Algoritmo 2 muestra en formato de pseudocódigo el método propuesto en el presente trabajo para realizar el conteo de plantas de agave. El algoritmo recibe como entrada una imagen, la cual es transformada al espacio de color CIE $L^*a^*b^*$, de esta manera se aprovecha el color azulado del agave que se refleja muy bien en la banda b^* ; después, la imagen es segmentada usando los filtros bilateral y Gaussiano. Posteriormente, se utiliza una ventana de tamaño 3×3 para identificar aquellos los puntos de interés, los cuales representan la presencia de agave. Finalmente, se utiliza un algoritmo de aprendizaje no supervisado llamado Birch, este algoritmo es el responsable de agrupar los puntos de interés de acuerdo a un umbral, con el propósito de que cada grupo de píxeles represente a un agave del cultivo.

Algoritmo 2: Conteo de agaves

```

input :  $I$  es un ortomosaico de entrada.
output:  $I'$  es un ortomosaico donde se muestra el total de agaves detectados.
begin
  Leer la imagen de entrada  $I$ ;
  Reducir el tamaño de  $I$ ;
  Cambiar  $I$  al formato CIE  $L * a * b^*$ ;
  Dividir  $I$  en sus tres canales ( $L, a, b$ );
  Aplicar a  $b$  el filtro bilateral;
  Aplicar a  $b$  el filtro Gaussiano;
  Crear una máscara usando  $b$ ;
  foreach renglones  $x \in b$  do                                     /* Usando una ventana  $3 \times 3$  */
    foreach columnas  $y \in b$  do
      if  $b_{x,y} > 0$  then
        | Añadir punto a lista puntos de interés;
      end
    end
  end
  Agrupar los puntos de interés usando el algoritmo Birch;
  Contar los agaves detectados;
  Imprimir informe  $I'$ ;
end

```

4.3.1. Validación del modelo

Se propone la evaluación de resultados mediante en el coeficiente de Silhouette, debido a sus características internas o de cohesión en el mismo cluster y externas o de separación en el cluster más cercano. Rousseeuw (1987) considera este método apropiado para validar los métodos no supervisados (ejemplo. Birch) ya que es una métrica para evaluar la calidad del agrupamiento obtenido con algoritmos de clustering y puede determinar el número óptimo de agrupamientos.

Capítulo 5

Resultados

5.1. Zona de estudio

Para la realización del presente estudio se seleccionaron dos zonas de interés, ubicadas dentro del municipio de *El Arenal* del estado de Jalisco, México. La Figura 5.1 muestra la zona de interés, en ella se resaltan los polígonos correspondientes a los predios conocidos como *La-Tinaja* y *El-Llano-chico*. Se seleccionaron predios del municipio de *El Arenal* dada su importancia cultural, se encuentran ubicados en *El Valle del Tequila*, registrado ante la UNESCO como paisaje agavero.

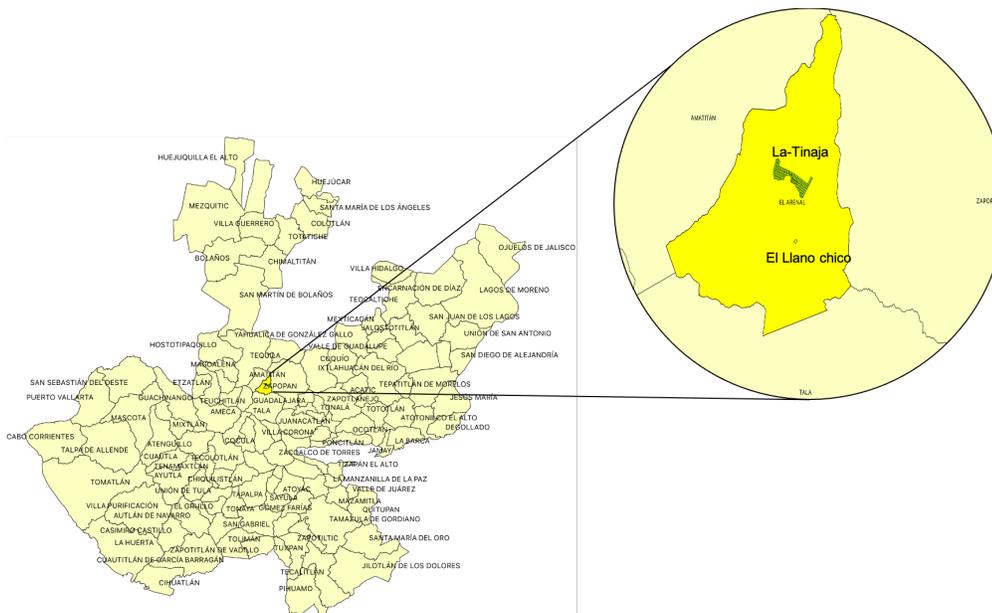


Figura 5.1: Zona de estudio, predios (a) La Tinaja y (b) El Llano chico, ubicados en el municipio del *El Arenal* del estado de Jalisco, México

5.2. Plan de vuelo y adquisición de imágenes

Para la adquisición de las imágenes se usaron los siguientes paquetes de software Pix4DCapture 4.10.0, Agisoft Metashape 1.6.0 y QGIS 3.0. En la Figura 5.2, se muestra el plan de vuelo en Pix4DCapture usado para capturar las fotos del predio el Llano-chico; en la Figura (a) se muestra la ruta que seguirá el VANT para la toma de fotografías, también se pueden apreciar las etiquetas (START y END) que indican las posiciones donde iniciará y terminará el vuelo, además, en la parte izquierda se aprecia la configuración de la altura del vuelo (30 m); en la Figura (b) se muestran otros criterios importantes del plan de vuelo como son el porcentaje de empalme o traslape entre cada fotografía (70 %).

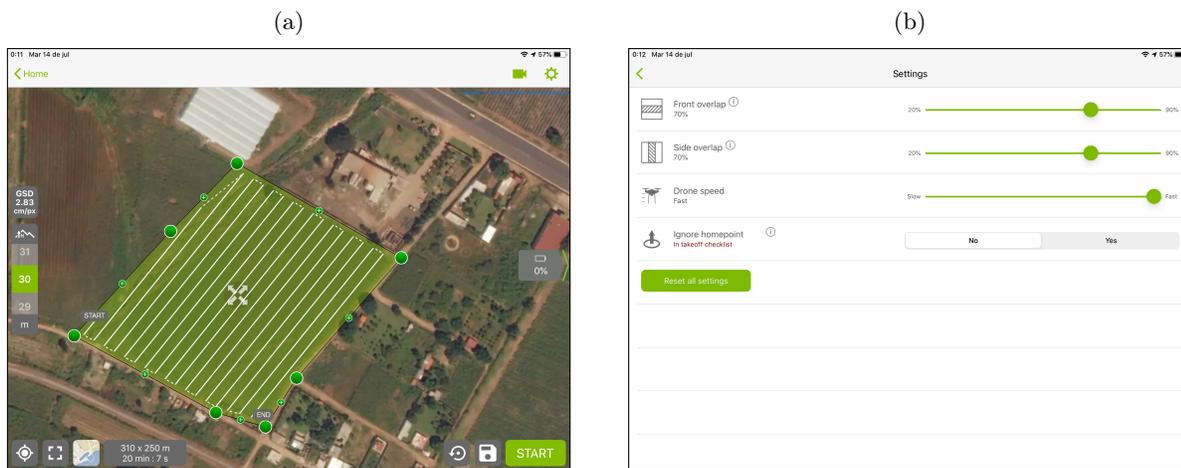


Figura 5.2: Plan de vuelo usando el software Pix4DCapture

Como resultado del plan de vuelo sobre el predio el *Llano-chico* ilustrado en la Figura. 5.2, se creó un conjunto de datos con 584 fotografías con dimensiones de 4608×3456 ; cada una de las imágenes pesa en promedio 3 MB.

5.3. Preprocesamiento

Una vez capturadas las fotografías, se procedió a crear el ortomosaico, para ello se usó el siguiente paquete de software Agisoft Metashape [®] siguiendo un flujo de trabajo de cinco pasos básicos: (1) añadir fotos, (2) alinear fotos, (3) crear nube de puntos, (4) crear malla, y (5) crear el ortomosaico; posteriormente, el ortomosaico generado es recortado usando QGIS [®]. Como ilustración del proceso de generación de ortomosaicos, se muestran los resultados paso a paso de como crear el ortomosaico del predio el *Llano-chico*, ver la Figura 5.3. En la Figura 5.3(a) se muestra una nube de puntos creada a partir de la alineación de las fotografías, en la Figura 5.3(b) se muestra la nube de puntos densa, en la Figura 5.3(c) se muestra el modelo 3D producto de crear una malla. Finalmente, la Figura. 5.4 muestra el ortomosaico creado.

La Figura. 5.4 muestra el ortomosaico del predio el *Llano-chico*, el cual se encuentra sobrepuesto sobre una imagen satelital para ilustrar su georeferenciación. Se muestra la región de interés

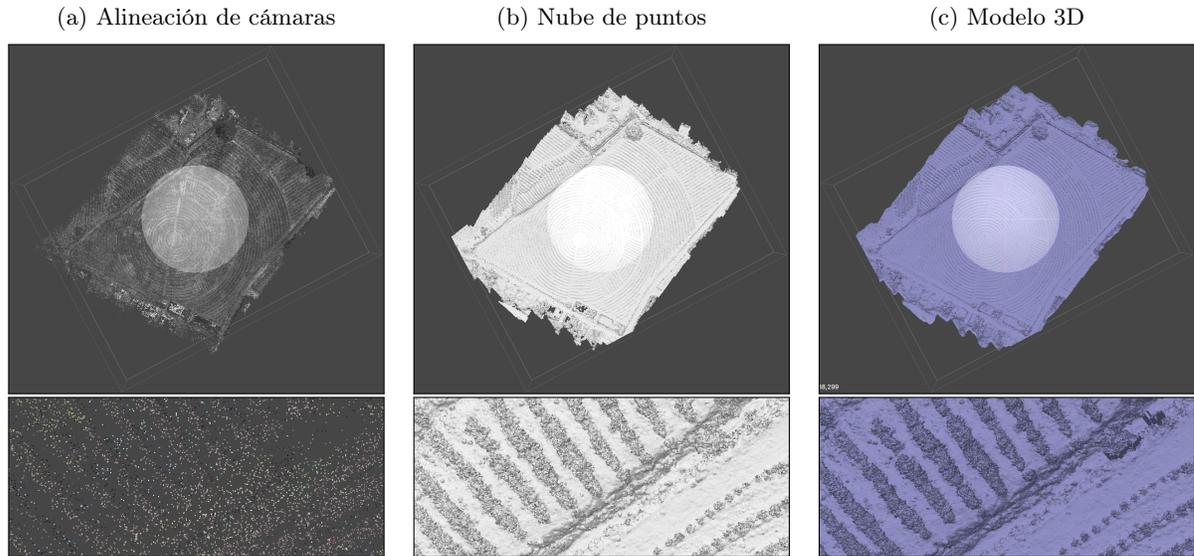


Figura 5.3: Crear un ortomosaico

representada por un polígono delimitado por un borde color rojo, dicho polígono es extraído del ortomosaico y pesa 1.7GB. Dadas las restricciones de algunas bibliotecas de Python¹ es complicado procesar directamente el ortomosaico, por lo tanto, el ortomosaico fue dividido en 25 imágenes cada una con resolución de 5000×5000 píxeles.

5.4. Segmentación

Una vez que se cuenta con el ortomosaico, en este caso dividido en 25 imágenes, se procedió a segmentar la imagen con el propósito de facilitar el proceso de identificación e inventario de las plantas de agave.

5.4.1. Segmentación por bandas

Dado el color azulado característico del *agave tequilana* Weber variedad azul, se decidió usar el espacio de colores $CIEL^*a^*b^*$ donde la banda b^* refleja bien las plantas de agave. Por lo tanto, fue necesario convertir la imagen original que está en el espacio de color RGB al espacio de color $CIEL^*a^*b^*$.

En la Figura. 5.5, muestra el resultado de seleccionar únicamente la banda b^* . La Figura. 5.5(a) muestra la imagen original y la Figura. 5.5(b) muestra una ilustración del cultivo de agave usando la banda b^* , la cual se obtuvo tras dividir la imagen en sus tres bandas. Como se puede apreciar en la imagen, las plantas de agave resaltan del suelo y la mala hierba que tiene el terreno.

¹La biblioteca PIL tiene una restricción de 8×10^7 y OpenCV tiene una restricción de 1×10^9



Figura 5.4: Ortomosaico

5.4.2. Aplicación de filtros

Una vez que la imagen original se convirtió al espacio de color $CIEL^*a^*b^*$ y se dividió la imagen en cada una de sus bandas, se procedió a aplicar filtros sobre la banda b^* con el fin de facilitar el proceso de identificación de plantas de agave; en particular, se usaron los filtros Bilateral y gaussiano. El filtro Bilateral ayuda a suavizar la imagen, reduce el ruido y ajusta los colores y bordes. El filtro gaussiano se usó como complemento del filtro Bilateral con el objetivo de difuminar la imagen y eliminar el ruido de fondo, facilitando la extracción de objetos de agaves.

La Figura 5.6 muestra el resultado de aplicar los filtros Bilateral y gaussiano sobre la banda b^* de la imagen original; en la imagen, se observa como los puntos de agave han sido suavizados, esto ayuda a atenuar las sombras que suelen encontrarse en el centro de la imagen, producto de que las pencas del agave están a diferentes alturas y a la propia posición del sol.

5.4.3. Extracción del suelo y mala hierba

Después que la imagen fue suavizada usando los filtros Bilateral y gaussiano, se procedió a eliminar el fondo de la imagen, i.e., eliminar el suelo y las zonas con mala hierba, de tal manera que se resalte las plantas de agave.

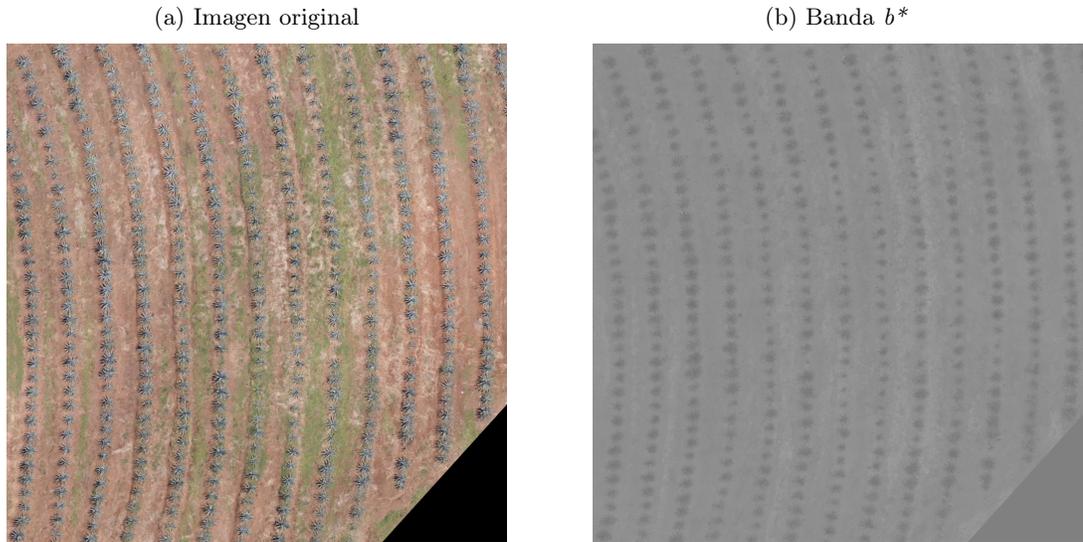


Figura 5.5: Seleccionar la banda b^* .

Para la extracción del fondo se utilizó la técnica de umbralización, se filtraron los píxeles con valores entre 120 y 135 en los cuales se refleja el azul de las plantas de agave, lo cual resultó en una imagen binarizada ilustrada en la Figura. 5.7(a), los puntos blancos representan zonas con plantas de agave, lo que está en color negro se elimina. Posteriormente, se usa la imagen binarizada para crear una máscara, la cual se aplica sobre la imagen original en color RGB con el fin de obtener una imagen en RGB a la cual se le ha eliminado el fondo y la mala hierba, ver la Figura. 5.7(b).

5.5. Clasificación y conteo de agaves

Una vez que la imagen se ha segmentado separando las plantas de agave del suelo, piedras, y mala hierba, la imagen está preparada para ser procesada usando un algoritmo de aprendizaje máquina que pueda detectar los agaves y contabilizarlos.

Dado que no se tiene información previa de cultivos de agaves, por ejemplo, bases de datos con imágenes de agaves ya procesadas y etiquetadas, el presente trabajo se propone un sistema no supervisado. Para ello se seleccionó el algoritmo propuesto por Zhang et al. (1997), el cual es un algoritmo de agrupamiento, que sigue un enfoque no supervisado y tiene una escalabilidad lineal.

5.5.1. Matriz de puntos

A partir de la imagen segmentada mostrada en la Figura. 5.7(b), se crea una matriz de puntos donde cada posición (x, y) representa un agave. Para crear la matriz de puntos, se usa una ventana de 10×10 píxeles para recorrer la Figura. 5.7(b) y extraer todos los puntos donde hay agave. Se escogió una ventana de ese tamaño para poder detectar tanto agaves pequeños como grandes, de hecho se espera que a un agave se le asignen varios puntos, la idea es no omitir ningún punto que represente a un agave por pequeño que sea.

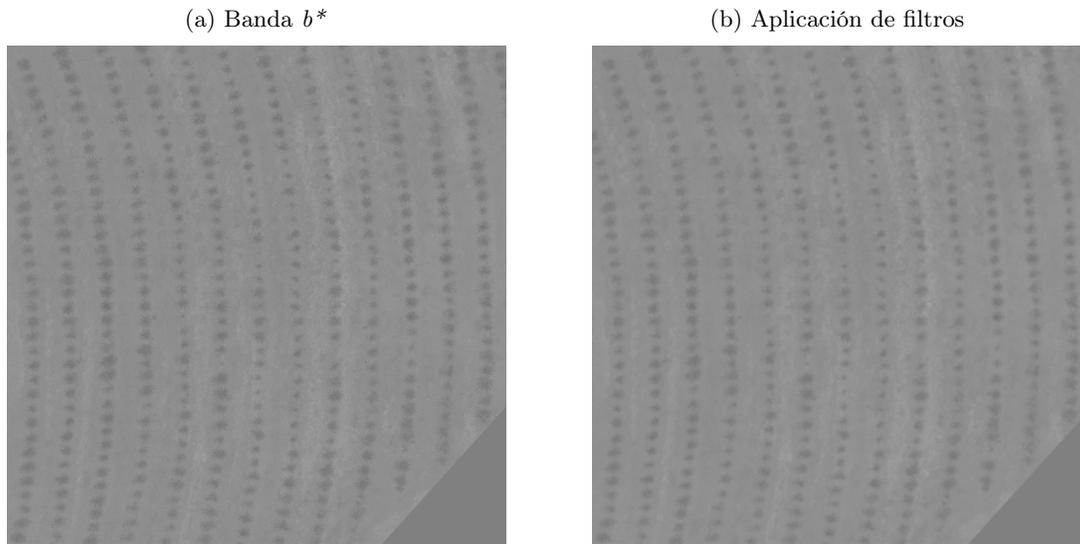


Figura 5.6: Aplicación de filtros Bilateral y Gaussiano.

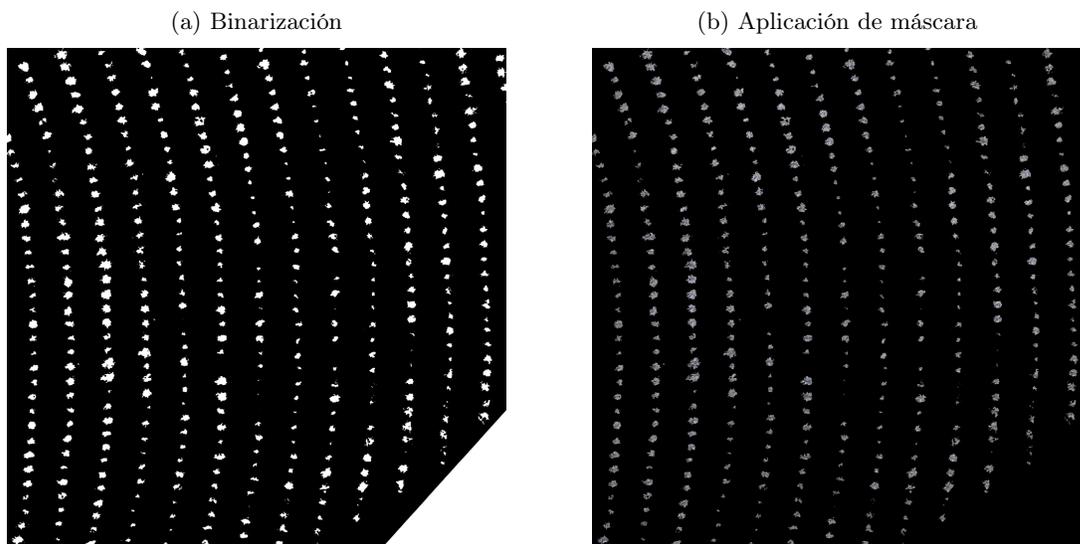


Figura 5.7: Extracción del suelo y mala hierba.

La Figura 5.8 ilustra los puntos detectados, donde cada ventana 10×10 que contiene píxeles asociados a plantas de agave, es numerada en forma incremental y se guarda su posición (x, y) en la matriz de puntos, cada punto en la figura se representa con texto color rojo, por tal motivo, en la imagen se observan los segmentos coloreados de color rojo, cada segmento que contiene agave tiene al menos un punto asignado.

5.5.2. Clasificación y conteo

La matriz de puntos descrita en la sección anterior, tiene el problema de que la mayoría de los agaves tienen asignados muchos puntos, y lo que se busca es poder asociar cada agave con un solo punto. En el método propuesto, se usa el algoritmo Birch para agrupar aquellos puntos que pertenezcan a

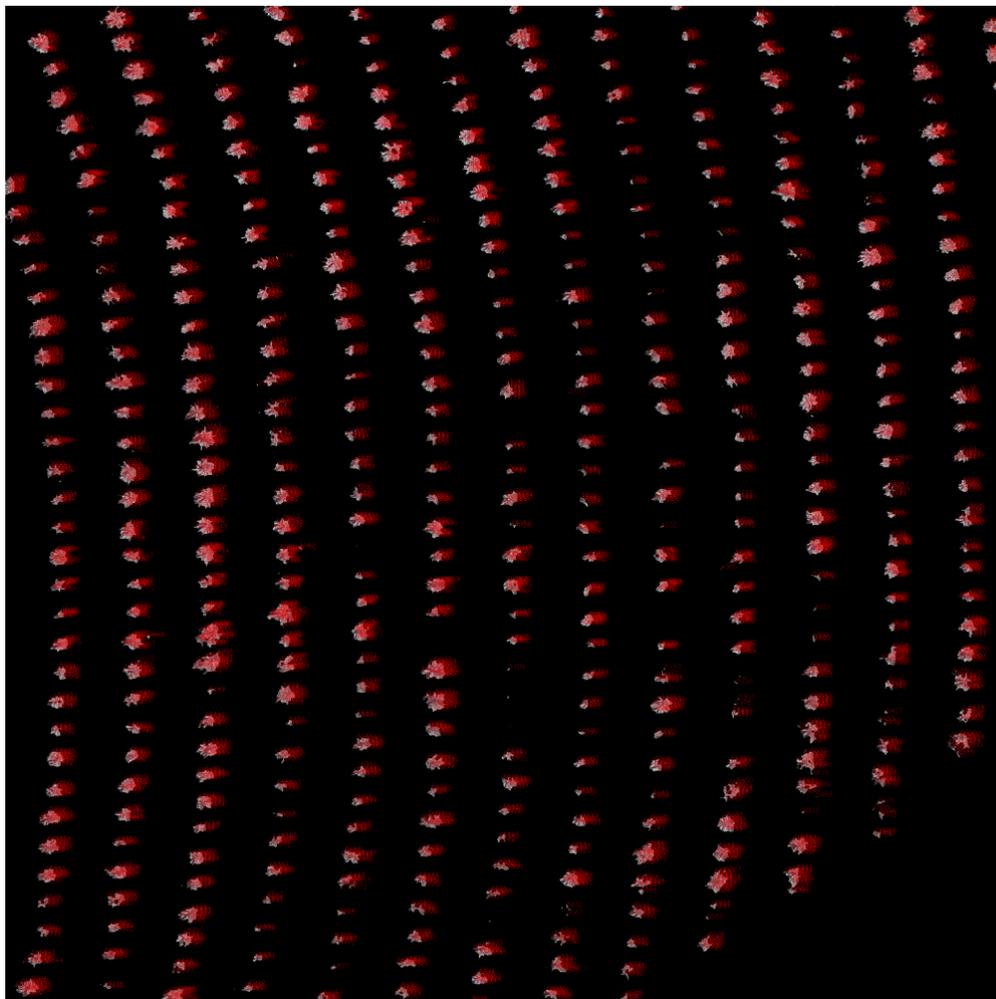


Figura 5.8: Etiquetado segmentos de agave

un solo agave y remplazarlos por su centroide.

Con el propósito de detectar tanto agaves pequeños como grandes, se ejecutan dos rondas del algoritmo Birch, primero utilizando un $threshold = 35$ y en la segunda ronda $threshold = 55$. En la Figura. 5.9, se muestra la imagen original en formato RGB y con puntos rojos se resaltan las plantas de agave detectadas e inventariadas; en la parte superior de la figura se muestra una leyenda con el total de agaves detectados.

5.5.3. Casos

Con el fin de analizar los resultados del método propuesto, en esta subsección se proponen tres casos: (1) imágenes con agaves de tamaño uniforme, separados y con maleza moderada, (2) imágenes con agaves de diferentes tamaños y maleza moderada, y (3) agaves de diferentes tamaños y maleza abundante. Para medir la calidad de los resultados se utilizó el coeficiente de *Silhouette*, que combina los conceptos de cohesión y separación entre los puntos pertenecientes a diferentes grupos.

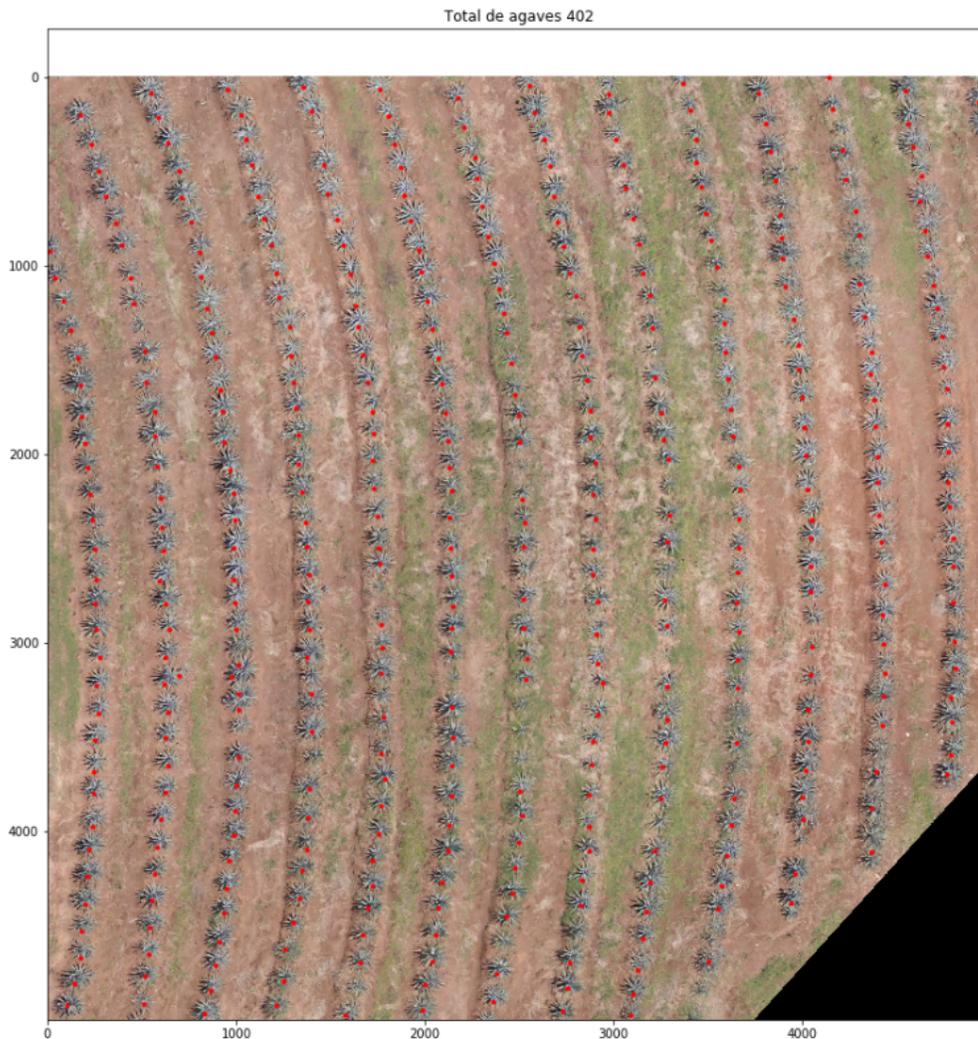


Figura 5.9: Etiquetado segmentos de agave

Caso 1: agaves de tamaño uniforme, separados y con maleza moderada

La Figura 5.10 muestra los resultados del algoritmo propuesto para el caso donde los agaves son de tamaño uniforme, existe una separación clara entre cada agave, y hay escasa presencia de maleza. En la figura se hace un acercamiento a una zona para resaltar que cada agave fue identificado, incluso un par de agave que están cubiertos de maleza. Al validar los resultados, se obtuvo un valor de 0.71 para el coeficiente Silhouette, el cual se muestra en el ID-2-1 de la Figura 5.16.

Caso 2: agaves de tamaño uniforme, separados y con maleza moderada

La Figura 5.11 muestra los resultados de procesar una imagen con agaves de diferentes tamaños y maleza moderada; la figura incluye un acercamiento a una zona que resalta los elementos antes mencionados. Como se puede observar, aunque los agaves tengan diferente tamaño, el algoritmo propuesto en este trabajo es capaz de detectarlos. Al validar los resultados, se obtuvo un valor de

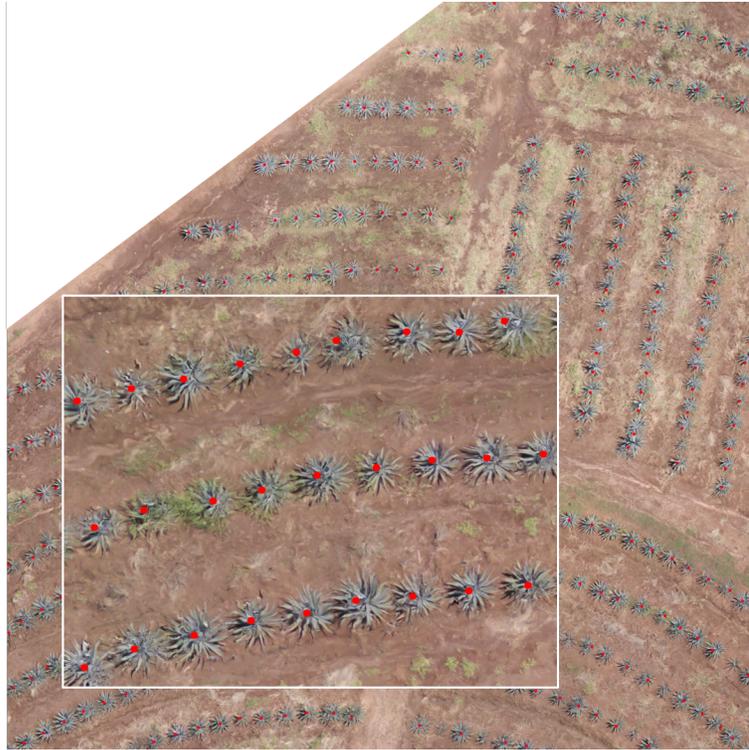


Figura 5.10: Cultivo con agaves de tamaño uniforme con escasa maleza.

0.68 para el coeficiente Silhouette, el cual se muestra en el ID-1-3 de la Figura 5.16.

Caso 3: agaves de tamaño no uniforme, separados y con maleza moderada

En la Figura 5.12, se muestran los resultados de procesar una imagen con agaves rodeados de maleza abundante; como se puede observar, aunque los agaves estén rodeados de mucha maleza el algoritmo propuesto es capaz de detectarlos. Al validar los resultados, se obtuvo un valor de 0.66 para el coeficiente Silhouette, el cual se muestra en el ID-0-2 de la Figura 5.16.

5.6. Resultados

En esta sección, se presentan los resultados de procesar las 25 imágenes en las que se dividió el ortomosaico creado en la Sección 5.3. La Figura 5.13 muestra la cantidad de agaves detectados en cada uno de los 25 segmentos del ortomosaico, los cuales coinciden con el total de agaves detectados al procesar el ortomosaico completo mostrado en la Figura 5.14, en la cual se resaltan con puntos rojos todos los agaves detectados; en total se detectaron 6,258 agaves.

Cabe mencionar que para poder procesar el ortomosaico completo mostrado en la Figura 5.14, fue necesario sacrificar la calidad de la imagen, para ello se exportó el ortomosaico generado en la Sección 5.3 disminuyendo la calidad de la imagen en un 90%.

En la Figura 5.15 se muestra el ortomosaico completo con los agaves detectados señalados con

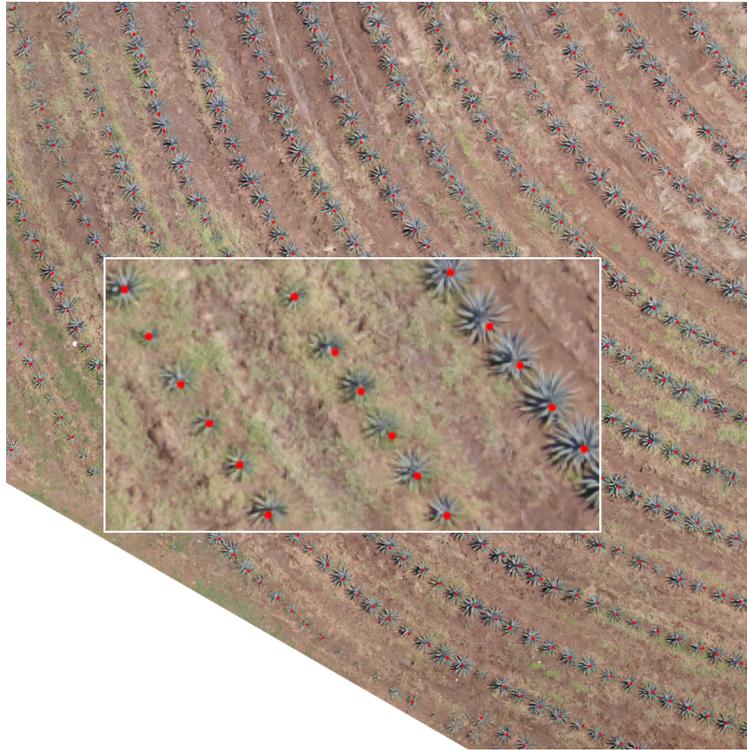


Figura 5.11: Cultivo con agaves de diferentes tamaños y maleza moderada.



Figura 5.12: Cultivo de agave con maleza abundante.

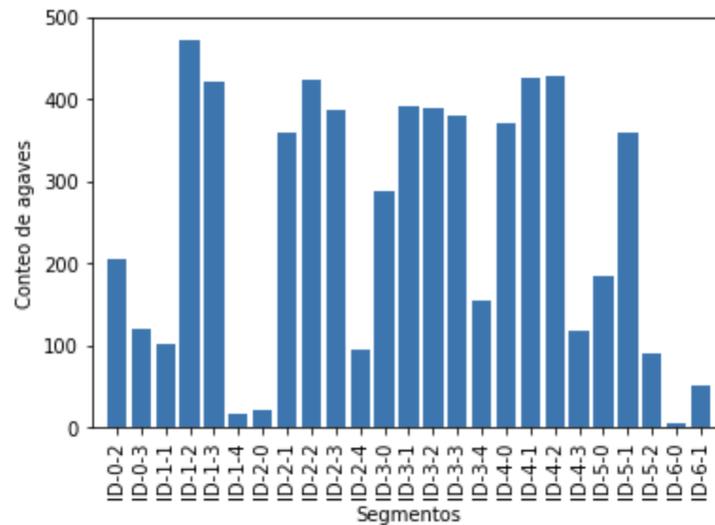


Figura 5.13: Conteo de agaves por cada segmento de la ortofoto.

puntos rojos; en la figura se resaltan tres zonas con el fin de comentar algunas mejoras que necesita el algoritmo propuesto.

1. En la zona (a), se muestra un problema propio de las etapas de captura de imágenes y preprocesamiento, en específico, se muestran los agaves distorsionados, el problema pudo haber sido causado por la falta de calibración de las imágenes debido a la ausencia de puntos de control.
2. En la zona (b), se resalta el problema de las sombras de árboles, combinado con una zona que se usa para plantar pequeños agaves que posteriormente se trasplantarán.
3. Finalmente, en la zona (c), se muestra una zona que combina el problema de abundante maleza con plantas de agave pequeñas y secas.

Como se aprecia en la Figura 5.15 aún quedan algunos problemas que resolver, por lo tanto, es necesario mejorar el método de segmentación considerando algunos índices vegetativos, otros espacios de color y otras regiones del espectro electromagnético; además, dada la complejidad del problema, sería interesante abordarlo usando técnicas de aprendizaje profundo.

5.7. Validación de los datos

Para la validación de los resultados, se utilizó el coeficiente Silhouette debido a que es una métrica que combina la cohesión y separación de los datos a la misma vez. El coeficiente Silhouette proporciona información de como se ha clasificado cada objeto, es una medida de cuán similar es un objeto a su propio clúster en comparación con otros clústers. El coeficiente Silhouette tiene valores que van desde -1 hasta +1, donde un valor cercano a 1 indica que el objeto está bien emparejado con su propio clúster y mal emparejado con los clústers vecinos. Si la mayoría de los objetos tienen un valor

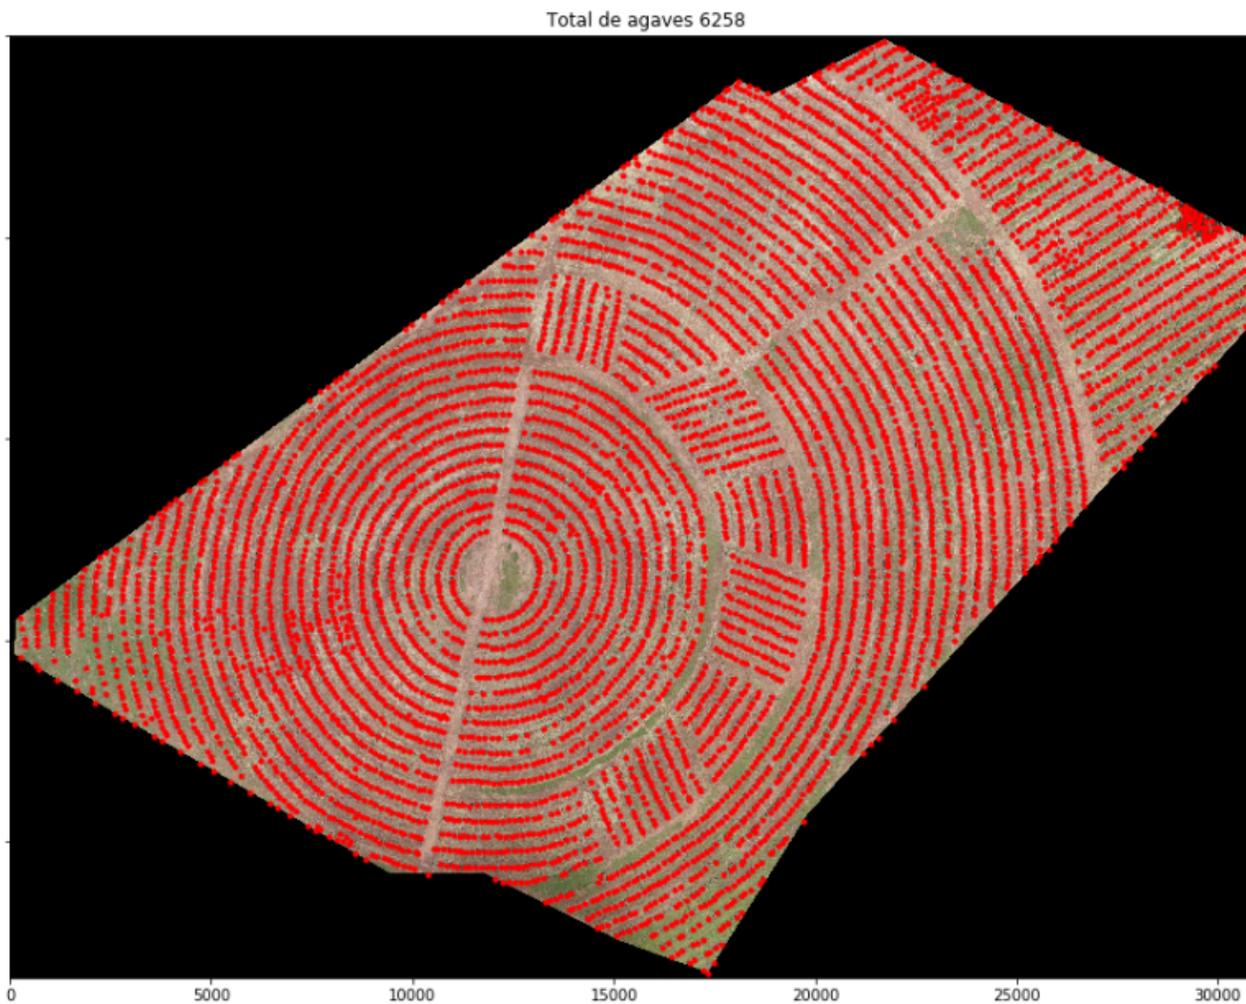


Figura 5.14: Ortomosaico: conteo de agaves.

cercano a 1, entonces la configuración del clúster es apropiada. Si muchos puntos tienen un valor cercano a 0 o negativo, entonces la configuración de clústers no es apropiada.

La Figura 5.16 muestra los resultados de evaluar cada segmento del ortomosaico original usando el coeficiente Silhouette. En el eje X, se representan los 25 segmentos del ortomosaico; en el eje Y, se representan los valores del coeficiente Silhouette, siendo valores altos un indicativo de que la observación se ha asignado al clúster correcto.

Como puede observarse en la Figura 5.16, el algoritmo propuesto asignó de manera aceptable cada punto detectado en el análisis de ventanas de 10×10 al clúster correcto, es decir, cada uno de esos puntos fue asignado a la planta de agave que correspondía. Se puede observar que la asignación se hizo de manera aceptable, porque en cada segmento se logró un coeficiente Silhouette >0.5 ; para poder decir que los resultados son totalmente correctos, el valor del coeficiente Silhouette debió ser igual a 1. También, se puede afirmar que ninguno de los resultados fue malo, es decir, que no se agrupó correctamente, porque ningún valor fue negativo.

Los puntos rojos en la Figura 5.16 con valores de 0.5, indican que en esos segmentos del or-

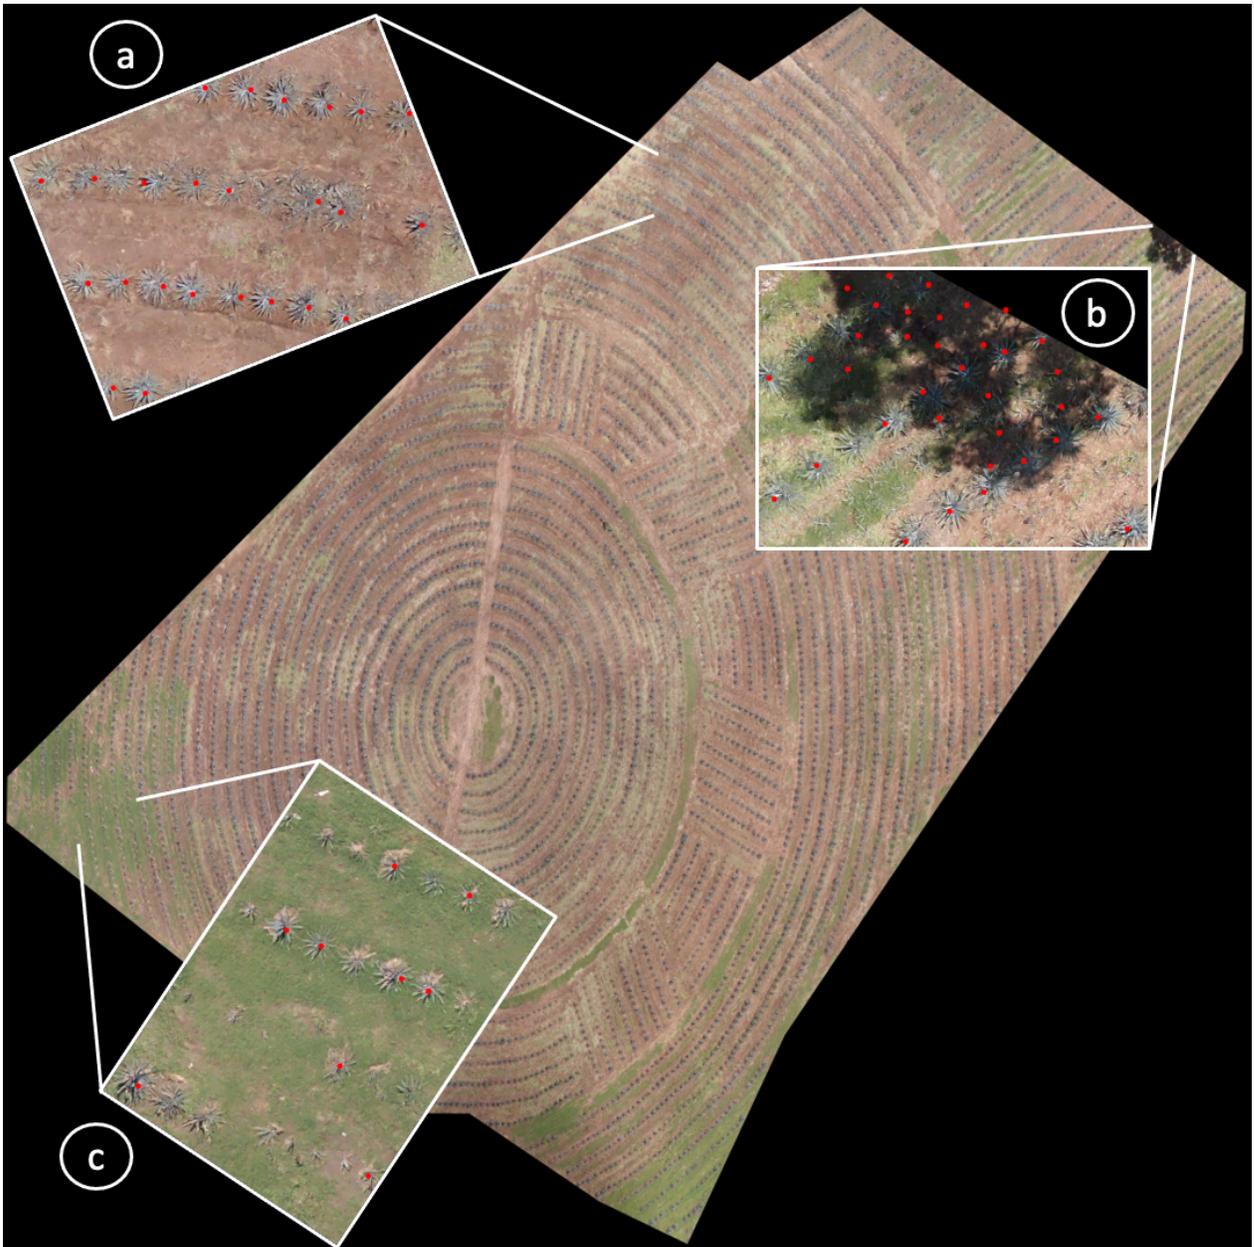


Figura 5.15: Ortomosaico: oportunidades de mejora.

tomosaico hubo algunos errores al asignar un punto al clúster apropiado, esto se puede deber a varios motivos, por ejemplo, a un error en la segmentación de la imagen o debido a que los agaves están demasiado entrelazados que el algoritmo no sabe distinguir a cual de los agaves pertenece cada punto. Por otra parte, los puntos rojos en la Figura 5.16 con valores de 0.75, indican que en esos segmentos del ortomosaico fue donde mejor se realizó el proceso de clustering. Finalmente, se puede concluir que los resultados obtenidos en el presente estudio son muy buenos toda vez que su coeficiente Silhouette tiene valores positivos altos, cercanos a 1.

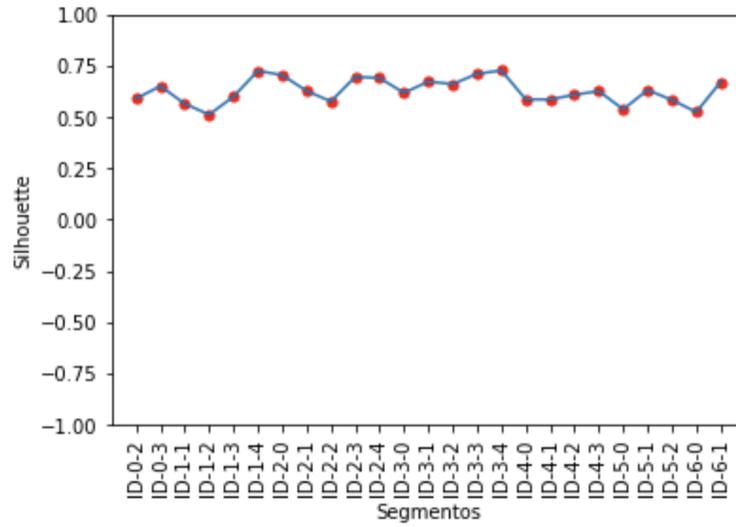


Figura 5.16: Validación del modelo propuesto usando el coeficiente Silhouette.

Capítulo 6

Conclusiones y trabajos futuros

En el presente trabajo se propuso un algoritmo para el conteo de plantas de agave usando imágenes aéreas tomadas desde un vehículo aéreo no tripulado. Para desarrollar el algoritmo se diseñó una metodología que está constituida por cuatro fases, las cuales son: plan de vuelo y adquisición de imágenes, preprocesamiento, segmentación, agrupación y conteo. Con el fin de probar el algoritmo propuesto, se creó un dataset con 584 imágenes y se propusieron tres escenarios, como resultado del proceso de experimentación se llegó a las conclusiones que se mencionan en la siguiente sección.

6.1. Conclusiones

Para el monitoreo de cultivos de agave es de gran importancia definir un plan de vuelo que permita crear ortomosaicos donde los objetos que representan a los agaves sean perfectamente detectables; al realizar la experimentación se llegó a la conclusión de que una altura de vuelo de 30 metros y un traslape u *overlap* del 70% son los parámetros apropiados para crear ortomosaicos de agave en los cuales se pueda identificar plantas de distintos tamaños. Además, como se presentó en la sección de resultados, los ortomosaicos creados contienen algunas zonas con pequeñas distorsiones lo que dificulta el correcto conteo de los agaves, por tal motivo, se considera necesario el levantamiento de puntos de control, con el fin de calibrar las imágenes y minimizar las distorsiones.

A pesar de los buenos resultados obtenidos, se concluye que es necesario mejorar el método de segmentación, hay ciertas zonas de suelo mojado que suelen confundirse con el color azulado del agave usando el canal b^* , asimismo, las sombras de los árboles dificultan la identificación de agaves.

Por otra parte, se mostró como el uso de técnicas de aprendizaje no supervisado ayuda a hacer frente al problema de detección y conteo de agaves, en específico, se usó el algoritmo Birch debido a que su escalabilidad es lineal. El algoritmo propuesto basado en Birch, es un avance significativo para afrontar el problema de identificación y conteo de agaves, toda vez que permite recorrer grandes extensiones de terreno por vuelo y el conteo se hace de manera automática. El escenario ideal es aquel donde los agaves son de tamaño uniforme, existe una separación clara entre cada planta, no hay maleza y el terreno no está mojado. Sin embargo, el algoritmo también obtiene resultados aceptables (coeficiente Silhouette superior a 0.5) en casos adversos caracterizados por la presencia abundante

de maleza, agaves de diferentes tamaños y suelo mojado.

Finalmente, con respecto al procesamiento de las imágenes, se concluye que dadas las restricciones de tamaño de las imágenes de algunas bibliotecas de Python, es recomendable dividir el ortomosaico en segmentos, para ello se puede usar el mismo software **Agisoft Metashape** para exportar el ortomosaico en segmentos de 5000×5000 píxeles.

6.2. Trabajos futuros

Con el fin de seguir mejorando el algoritmo de detección y conteo de agaves, se consideran los siguientes trabajos futuros.

- Usar puntos de control para mejorar el ortomosaico.
- Probar otras técnicas de segmentación, como las basadas en morfologías y la creación de índices vegetativos y probar combinaciones entre las diferentes técnicas de segmentación.
- Crear un algoritmo basado en alguna técnica de reconocimiento de patrones para detectar todo lo que no sea agave y poderlo extraer de la imagen de entrada.
- Incursionar en el desarrollo de un algoritmo basado en técnicas de aprendizaje profundo para mejorar la detección de agaves.

Referencias

- Aggarwal, C. C. and Reddy, C. K. (2013). *Data clustering: algorithms and applications*. CRC Press.
- Calvario Sánchez, G. (2019). *Paradigmas de aprendizaje automático aplicados a la teledetección: imágenes RGB e imágenes multiespectrales*. phdthesis, Universidad del País Vasco.
- Castro, W., Oblitas, J., De-La-Torre, M., Cotrina, C., Bazán, K., and Avila-George, H. (2019). Classification of cape gooseberry fruit according to its level of ripeness using machine learning techniques and different color spaces. *IEEE Access*, 7:27389–27400.
- CRT (2019). Información estadística. En línea, accesado el 17/dic/2019 en: <https://www.crt.org.mx/EstadisticasCRTweb>.
- DOF (2012). Proyecto de Norma Oficial Mexicana PROY-NOM-006-SCFI-2012, Bebidas alcohólicas-Tequila-Especificaciones. En línea, accesado el 17/dic/2019 en: <http://www.dof.gob.mx/normasOficiales/4728/seeco/seeco.htm>.
- Escalante Torrado, J. O., Aceres Jiménez, J. J., and Porras Díaz, H. (2016). Ortomosaicos y modelos digitales de elevación generados a partir de imágenes tomadas con sistemas UAV. *Tecnura*, 20(50):119–140.
- Forsyth, D. A. and Ponce, J. (2015). *Computer Vision: A Modern Approach: A Modern Approach*. Pearson Education Limited.
- Golubov, J., Mandujano, M. C., Arizaga, S., Martínez-Palacios, A., and Koleff, P. (2007). Inventarios y conservación de agavaceae y nolinaceae. *En lo Ancestral hay Futuro: del Tequila, los Mezcales y otros Agaves*, pages 33–52.
- Gonzalez, R. and Woods, R. (2018). *Digital Image Processing*. Pearson.
- Grau, J. F. P. (2011). *Técnicas de análisis de imagen, (2a ed.)*. Publicacions de la Universitat de València.
- Grenzdörffer, G. J., Engel, A., and Teichert, B. (2008). The photogrammetric potential of low-cost UAVs in forestry and agriculture. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 31(B3):1207–1214.

- Hunt, E. R., Hively, W. D., Fujikawa, S., Linden, D., Daughtry, C. S., and McCarty, G. (2010). Acquisition of NIR-green-blue digital photographs from unmanned aircraft for crop monitoring. *Remote Sensing*, 2(1):290–305.
- Jose Jaime Esqueda Elizondo, L. E. P. M. (2005). *Fundamentos para el procesamiento de imágenes*. Universidad de Baja California.
- Keele, S. (2007). Guidelines for performing Systematic Literature Reviews in Software Engineering. Technical Report EBSE-2007-01, Software Engineering Group, School of Computer Science and Mathematics, Keele University.
- Khorram, S., Koch, F. H., van der Wiele, C. F., and Nelson, S. A. (2012). *Remote sensing*. Springer Science & Business Media.
- Koc-San, D., Selim, S., Aslan, N., and San, B. T. (2018). Automatic citrus tree extraction from UAV images and digital surface models using circular hough transform. *Computers and electronics in agriculture*, 150:289–301.
- Morales Manzanares, E. F., Reyes García, C. A., Morales-Reyes, A., and Escalante Balderas, H. J. (2019). *La Computación en México por especialidades académicas*, chapter 2, pages 65–90. maex-comp.
- Muñoz, C. P. A. L. (2006). *Teledetección: Nociones y Aplicaciones*. Carlos Pérez Gutiérrez, Ángel Luis Muñoz Nieto.
- Parrot (2019). Parrot bluegrass. En línea, accesado el 31/ago/2020 en: <https://support.parrot.com/us/support/products/parrot-bluegrass>.
- Ponce-Corona, E., Sánchez, M. G., Fajardo-Delgado, D., Acevedo-Juárez, B., De-la Torre, M., Avila-George, H., and Castro, W. (2020). Una revisión sistemática de la literatura enfocada al uso de vehículos aéreos no tripulados durante el proceso de detección de vegetación. *RISTI-Revista Ibérica de Sistemas e Tecnologías de Informação*, (36):82–101.
- Ponce-Corona, E., Sánchez, M. G., Fajardo-Delgado, D., Castro, W., De-la Torre, M., and Avila-George, H. (2019). Detection of vegetation using unmanned aerial vehicles images: A systematic review. In *2019 8th International Conference On Software Process Improvement (CIMPS)*, pages 1–7.
- Puliti, S., Ørka, H. O., Gobakken, T., and Næsset, E. (2015). Inventory of small forest areas using an unmanned aerial system. *Remote Sensing*, 7(8):9632–9654.
- Quirós Rosado, E. (2015). *Introducción a la Fotogrametría y Cartografía aplicadas a la Ingeniería Civil*. Universidad de Extremadura.
- Rousseuw, P. J. (1987). Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics*, 20:53 – 65.

-
- She, T., Ehsani, R., Robbins, J., Leiva, J. N., and Owen, J. (2014). Applications of small UAV systems for tree and nursery inventory management. In *Proceedings of the 12th International Conference on Precision Agriculture*, 20-23 de julio, Sacramento, CA, USA.
- Westland, S., Ripamonti, C., and Cheung, V. (2012). *Computational Colour Science Using MATLAB*. Wiley.
- Wohlin, C. (2014). Guidelines for snowballing in systematic literature studies and a replication in software engineering. In *Proceedings of the 18th international conference on evaluation and assessment in software engineering*, mayo 13-14, Londres, Reino Unido.
- Zhang, T., Ramakrishnan, R., and Livny, M. (1997). Birch: A new data clustering algorithm and its applications. *Data Mining and Knowledge Discovery*, 1(2):141–182.

Anexos

Anexo A

Publicaciones derivadas de este trabajo de tesis

A.1. Artículo de revista

Ponce-Corona et al. (2020)

Ponce-Corona, E., Sánchez, M. G., Fajardo-Delgado, D., Acevedo-Juárez, B., De-la-Torre, M., Avila-George, H., & Castro, W. (2020). Una revisión sistemática de la literatura enfocada al uso de vehículos aéreos no tripulados durante el proceso de detección de vegetación. *RISTI-Revista Ibérica de Sistemas e Tecnologias de Informação*, (36), 82-101. DOI: <https://doi.org/10.17013/risti.36.82-101>.

La revista RISTI esta indexada en las principales bases de datos internacionales, entre las cuales destacan *Web of Science* y *Scopus*.

A.2. Memorias de congreso

Ponce-Corona et al. (2019)

Ponce-Corona, E., Sánchez, M. G., Fajardo-Delgado, D., Castro, W., De-la-Torre, M., & Avila-George, H. (2019, October). Detection of Vegetation Using Unmanned Aerial Vehicles Images: A Systematic Review. In *8th International Conference On Software Process Improvement (CIMPS)* (pp. 1-7). IEEE. DOI: <https://doi.org/10.1109/CIMPS49236.2019.9082434>.

El artículo presentado en la conferencia esta indexado en las principales bases de datos internacionales, entre las cuales destacan *IEEE Xplore* y *Scopus*.

Anexo B

Conjunto de datos

En este anexo, se muestran los 25 segmentos en los cuales fue dividido el ortomosaico generado en la Sección 5.3.



Figura B.1: Segmento: ID-0-2



Figura B.2: Segmento: ID-0-3

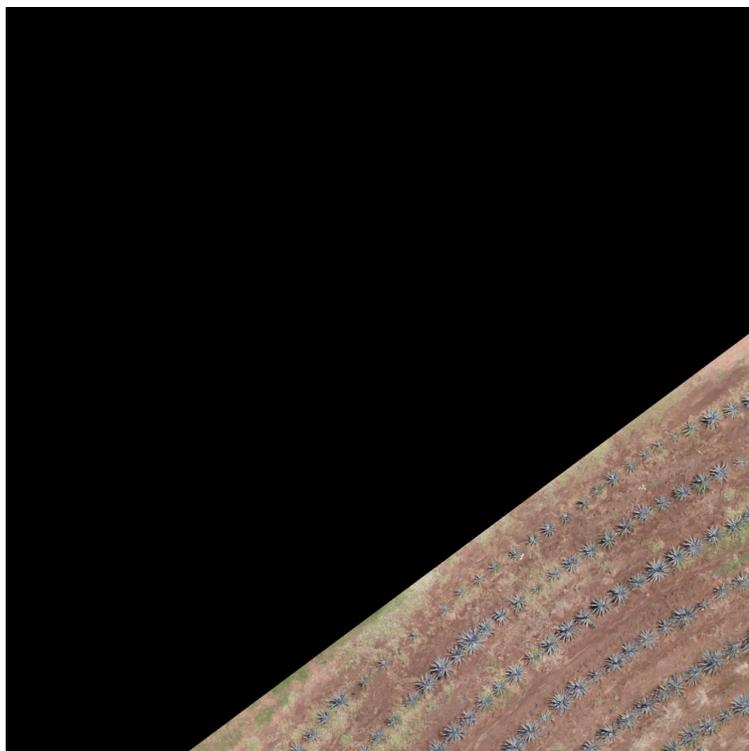


Figura B.3: Segmento: ID-1-1

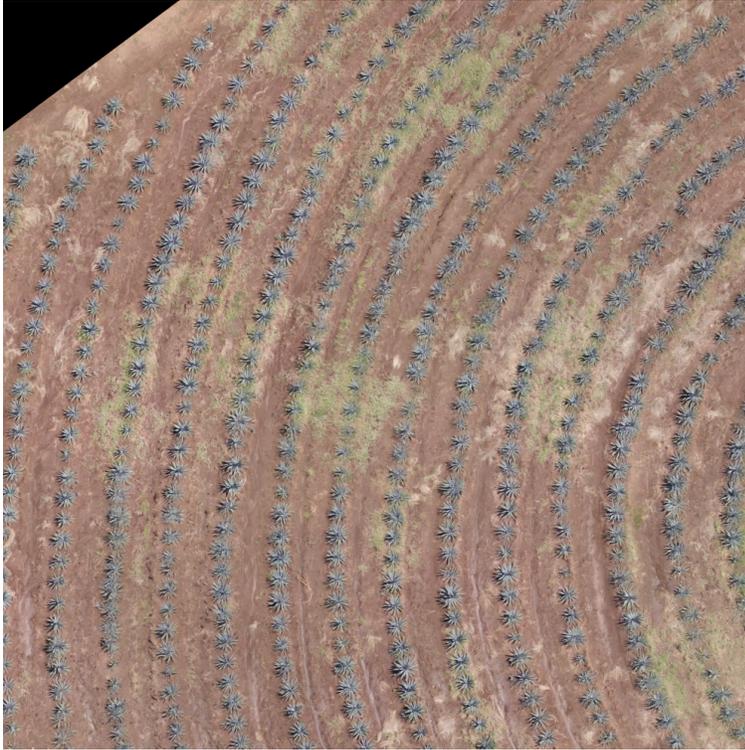


Figura B.4: Segmento: ID-1-2

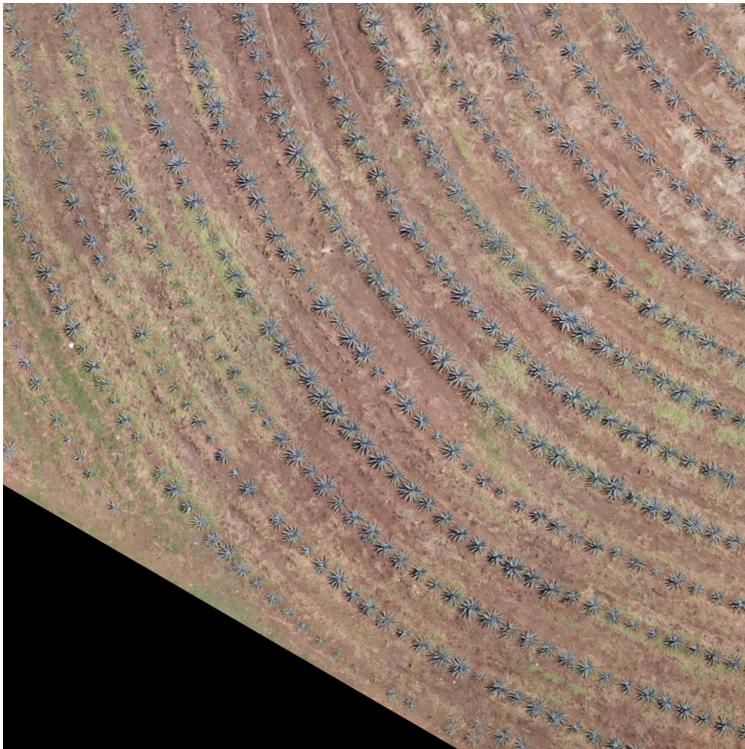


Figura B.5: Segmento: ID-1-3



Figura B.6: Segmento: ID-1-4

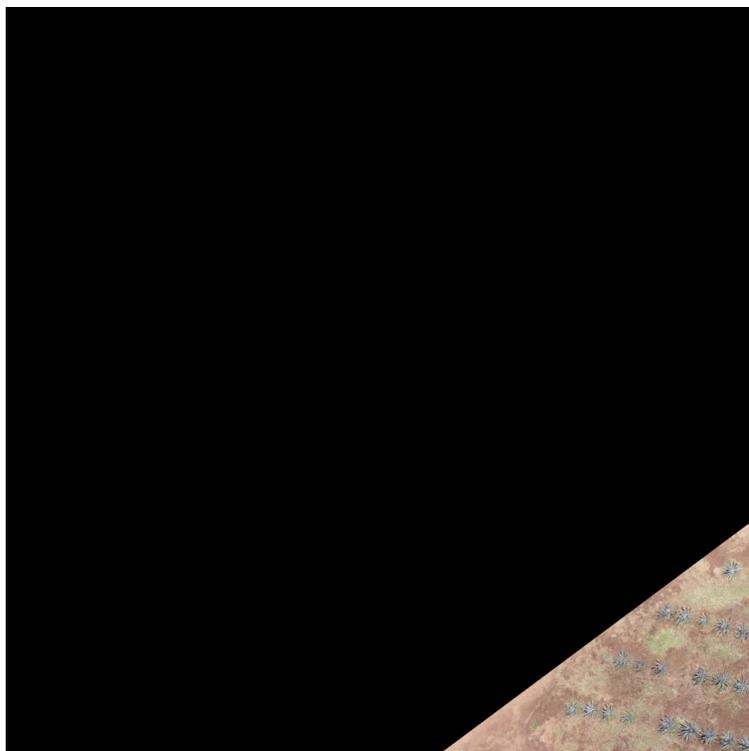


Figura B.7: Segmento: ID-2-0

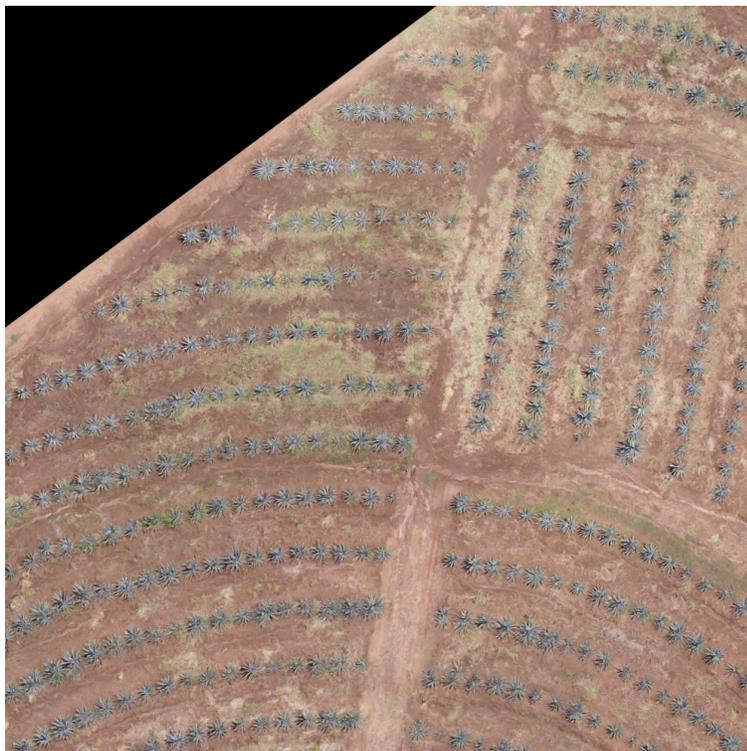


Figura B.8: Segmento: ID-2-1

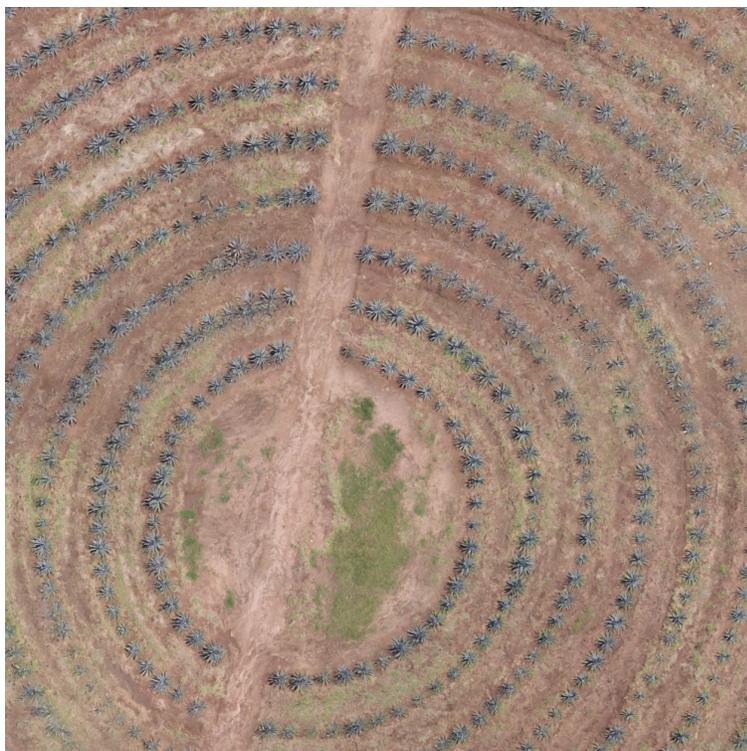


Figura B.9: Segmento: ID-2-2

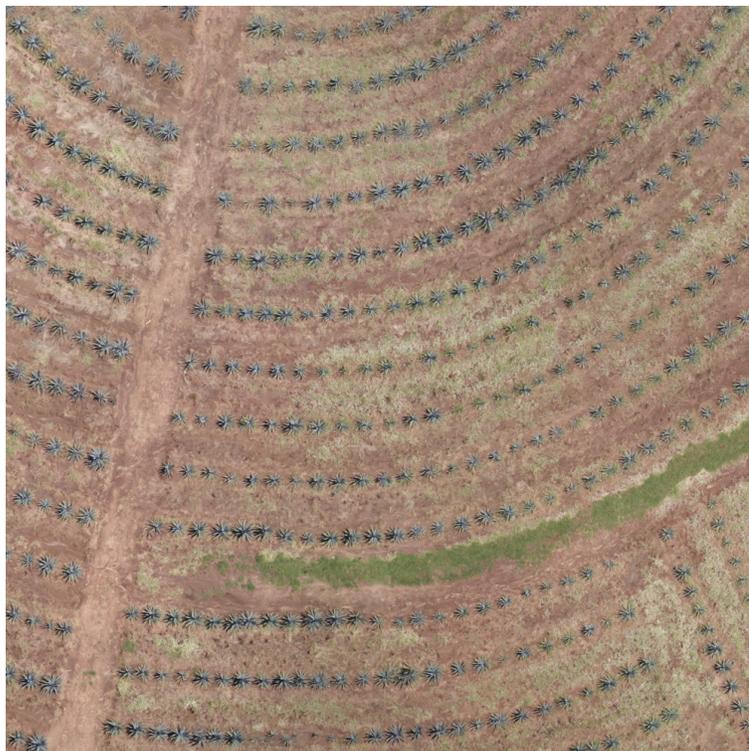


Figura B.10: Segmento: ID-2-3

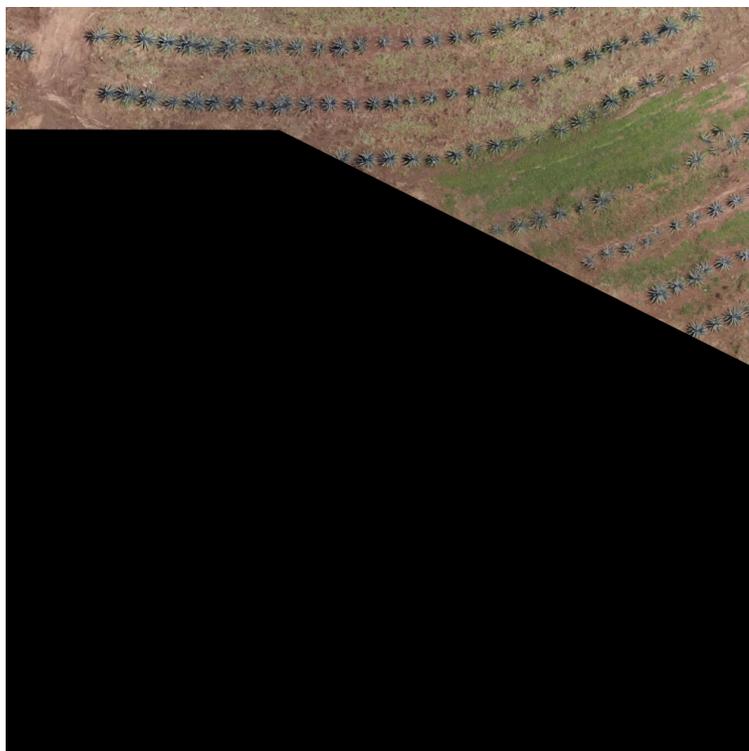


Figura B.11: Segmento: ID-2-4

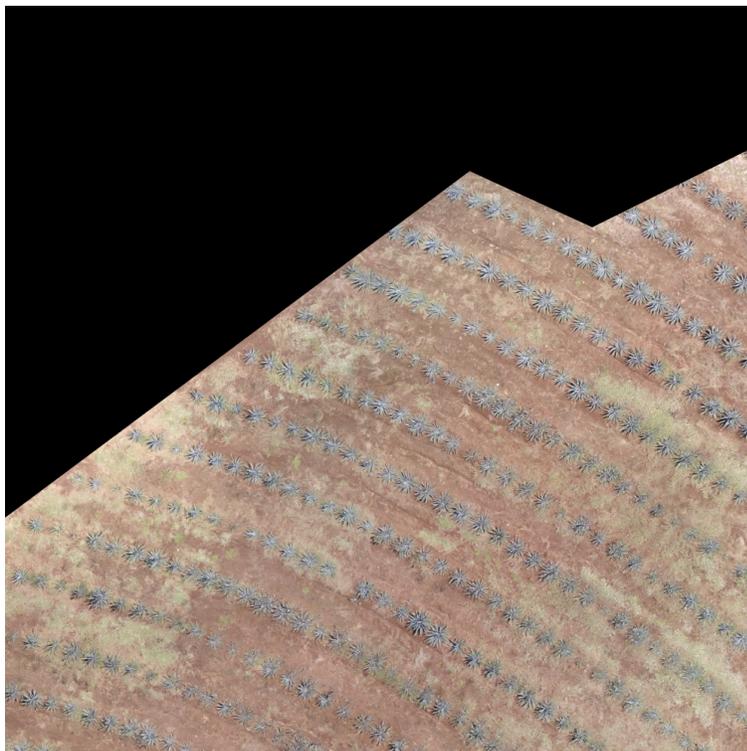


Figura B.12: Segmento: ID-3-0

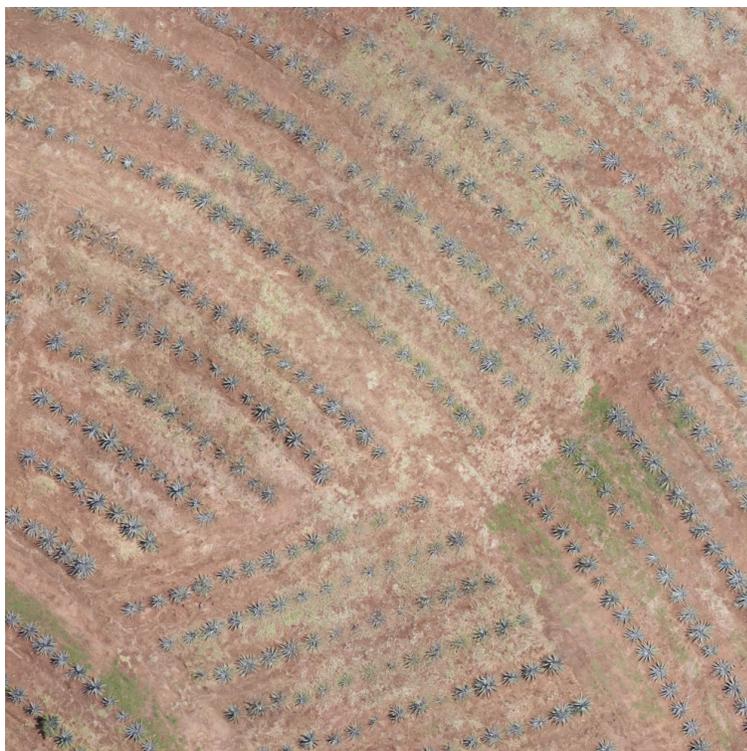


Figura B.13: Segmento: ID-3-1

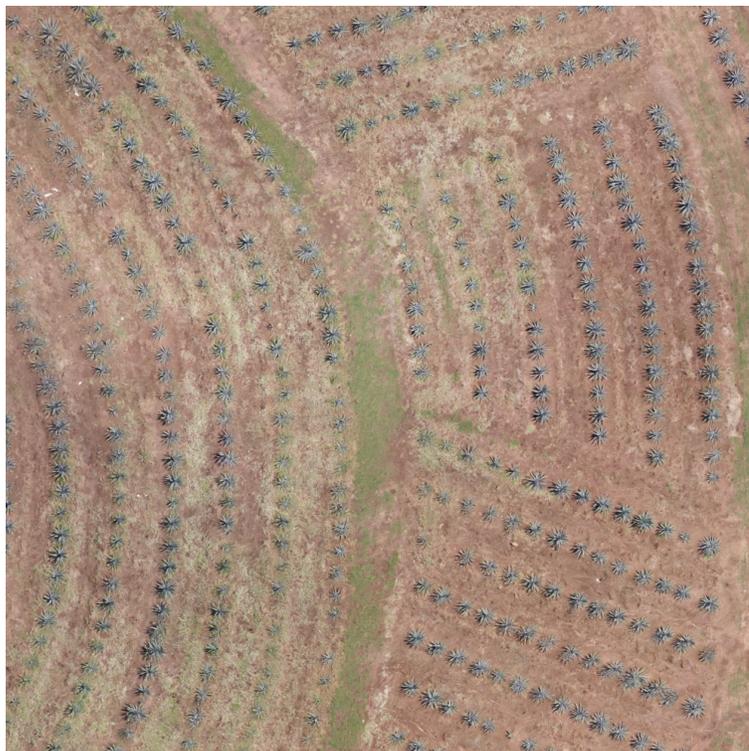


Figura B.14: Segmento: ID-3-2



Figura B.15: Segmento: ID-3-3

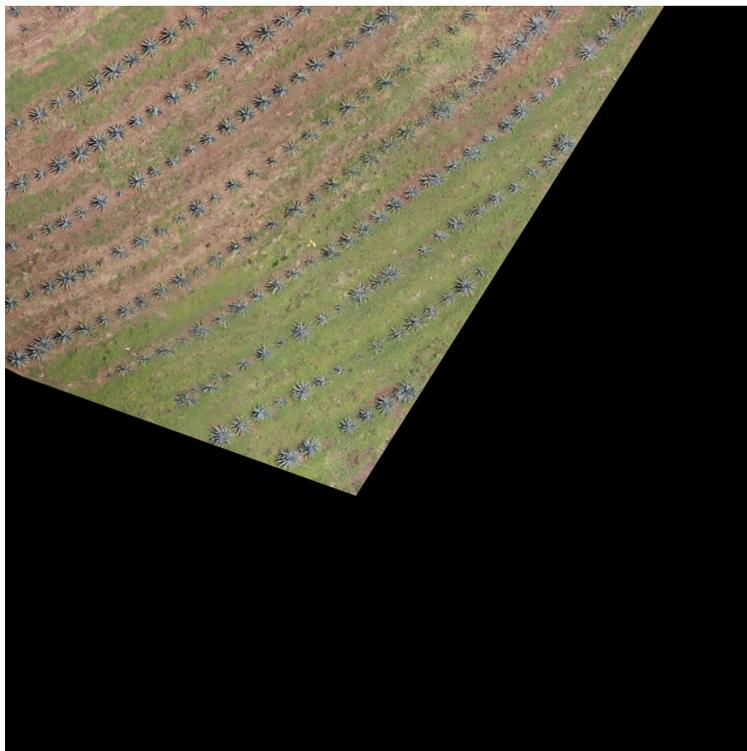


Figura B.16: Segmento: ID-3-4

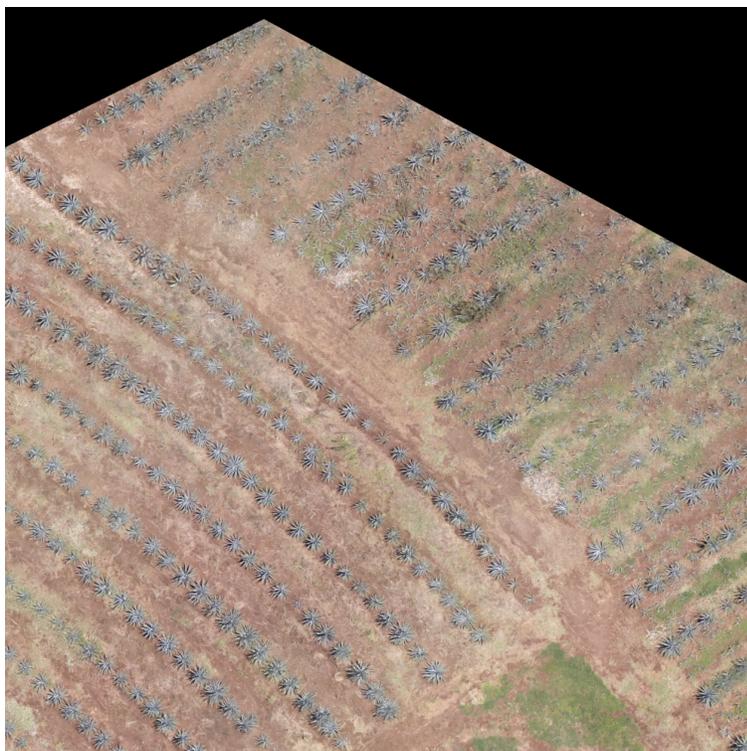


Figura B.17: Segmento: ID-4-0

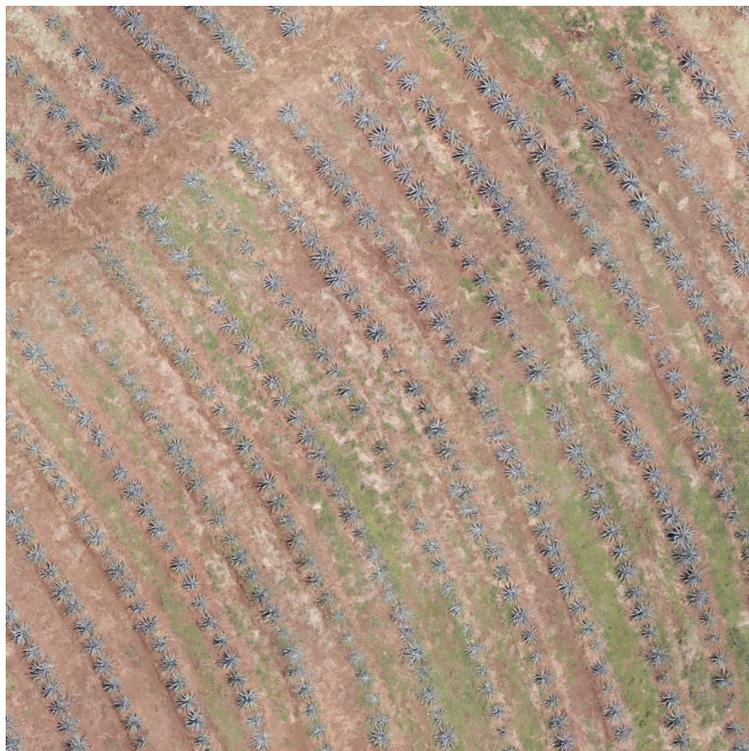


Figura B.18: Segmento: ID-4-1

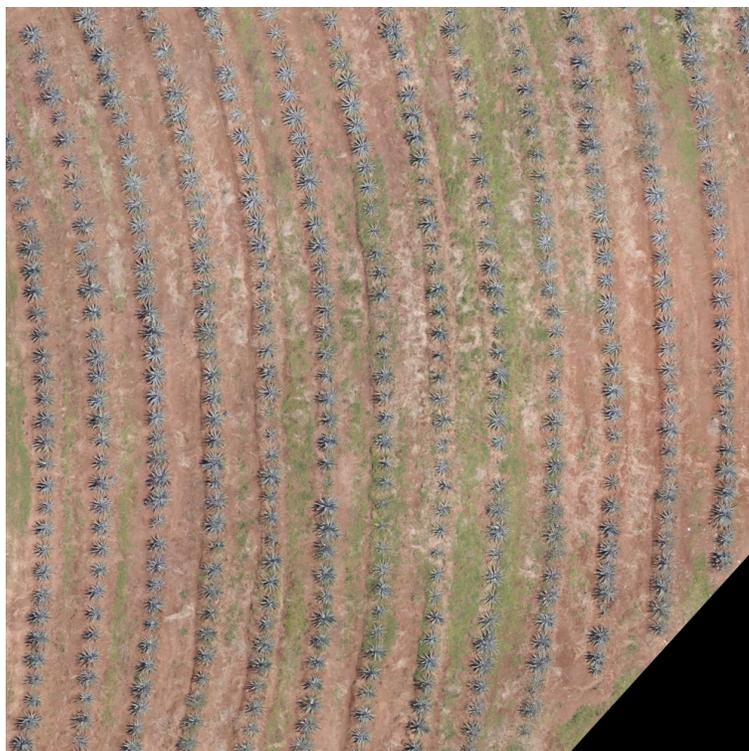


Figura B.19: Segmento: ID-4-2

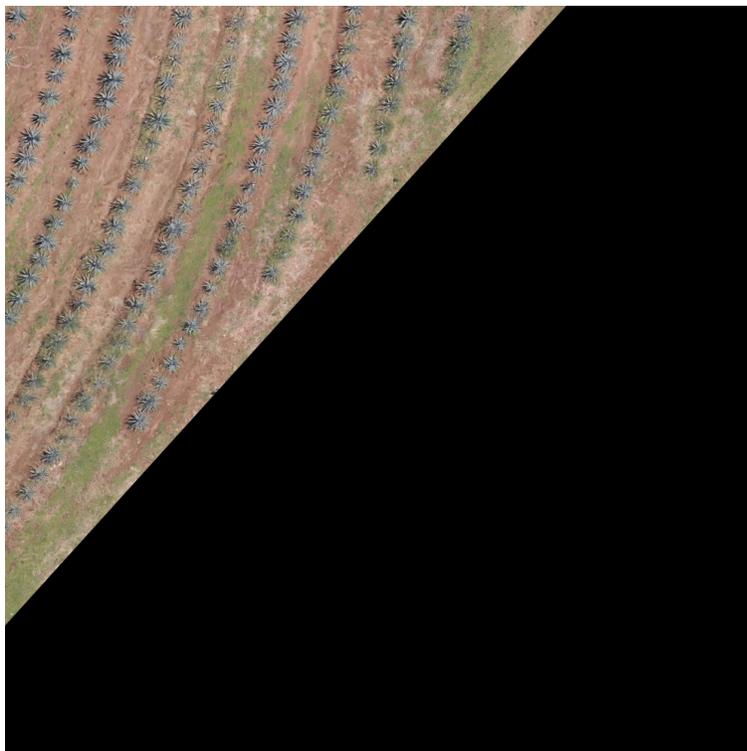


Figura B.20: Segmento: ID-4-3

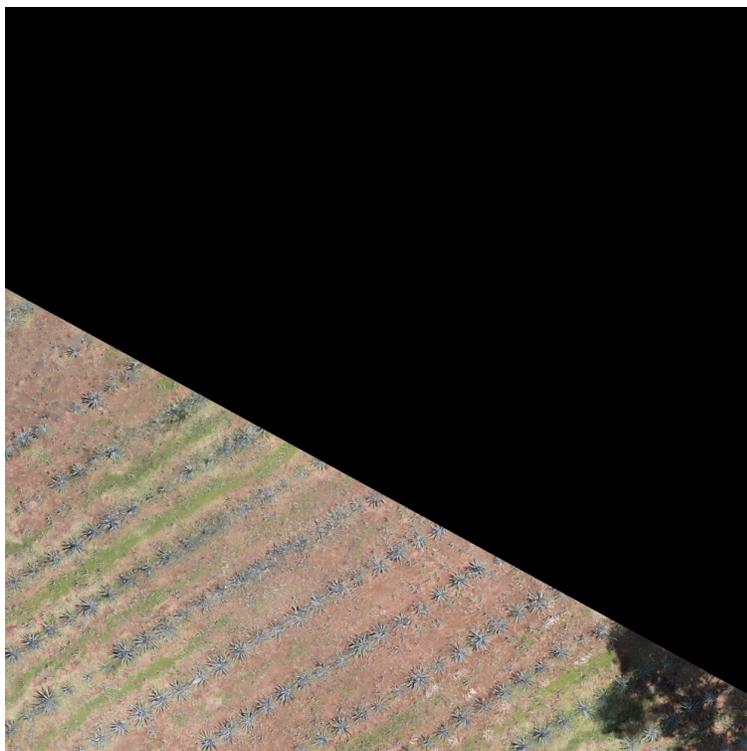


Figura B.21: Segmento: ID-5-0



Figura B.22: Segmento: ID-5-1

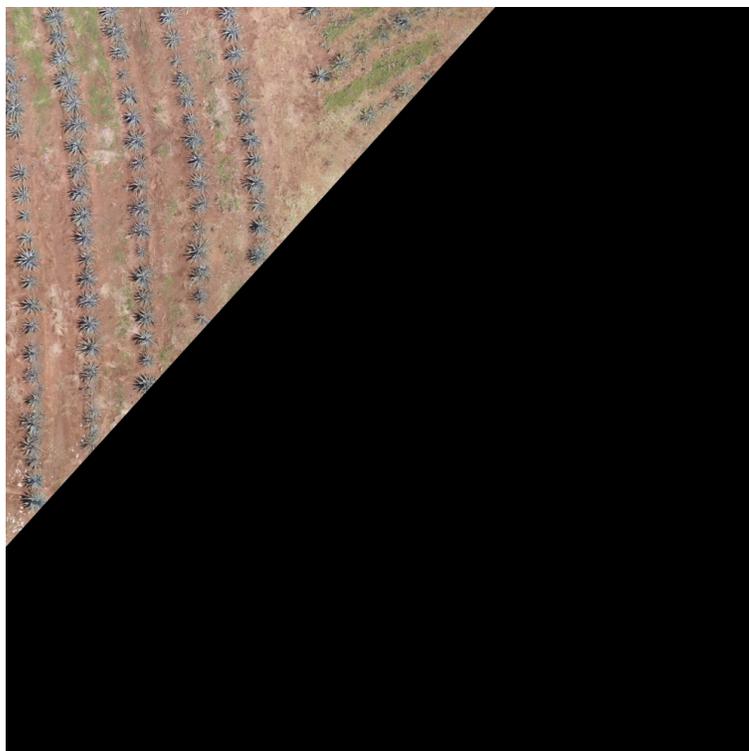


Figura B.23: Segmento: ID-5-2



Figura B.24: Segmento: ID-6-0

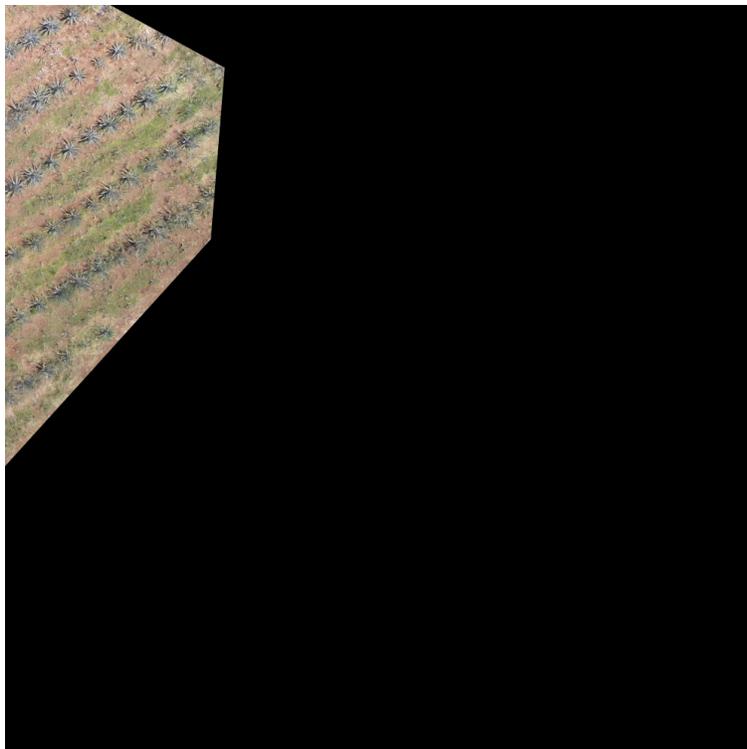


Figura B.25: Segmento: ID-6-1

Anexo C

Estudios primarios

- (EP01) T. Adão, L. Pádua, J. Hruška, P. Marques, E. Peres, and J. J. Sousa, “A pilot digital image processing approach for detecting vineyard parcels in Douro region through high-resolution aerial imagery,” Proceedings of the International Conference on Geoinformatics and Data Analysis - ICGDA '18. 2018.
- (EP02) Y. Bazi, S. Malek, N. Alajlan, and H. AlHichri, “An automatic approach for palm tree counting in UAV images,” 2014 IEEE Geoscience and Remote Sensing Symposium. 2014.
- (EP03) S. Malek, Y. Bazi, N. Alajlan, H. AlHichri, and F. Melgani, “Efficient Framework for Palm Tree Detection in UAV Images,” IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol. 7, no. 12. pp. 4692–4703, 2014.
- (EP04) L. Wallace, A. Lucieer, and C. S. Watson, “Evaluating Tree Detection and Segmentation Routines on Very High Resolution UAV LiDAR Data,” IEEE Transactions on Geoscience and Remote Sensing, vol. 52, no. 12. pp. 7619–7628, 2014.
- (EP05) J. R. Souza et al., “Automatic detection of Ceratocystis wilt in Eucalyptus crops from aerial images,” 2015 IEEE International Conference on Robotics and Automation (ICRA). 2015.
- (EP06) O. Guldogan et al., “Automated tree detection and density calculation using unmanned aerial vehicles,” 2016 Visual Communications and Image Processing (VCIP). 2016.
- (EP07) G. L. A. Carrijo, D. E. Oliveira, G. A. de Assis, M. G. Carneiro, V. C. Guizilini, and J. R. Souza, “Automatic detection of fruits in coffee crops from aerial images,” 2017 Latin American Robotics Symposium (LARS) and 2017 Brazilian Symposium on Robotics (SBR). 2017.
- (EP08) J. Ribera, Y. Chen, C. Boomsma, and E. J. Delp, “Counting plants using deep learning,” 2017 IEEE Global Conference on Signal and Information Processing (GlobalSIP). 2017.
- (EP09) G. V. Nardari et al., “Crop Anomaly Identification with Color Filters and Convolutional Neural Networks,” 2018 Latin American Robotic Symposium, 2018 Brazilian Symposium on Robotics (SBR) and 2018 Workshop on Robotics in Education (WRE). 2018.
- (EP10) H. C. Oliveira, V. C. Guizilini, I. P. Nunes, and J. R. Souza, “Failure Detection in Row Crops From UAV Images Using Morphological Operators,” IEEE Geoscience and Remote Sensing Letters, vol. 15, no. 7. pp. 991–995, 2018.
- (EP11) H. Huang, X. Li, and C. Chen, “Individual Tree Crown Detection and Delineation From Very-

- High-Resolution UAV Images Based on Bias Field and Marker-Controlled Watershed Segmentation Algorithms,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 11, no. 7. pp. 2253–2262, 2018.
- (EP12) Z. Fan, J. Lu, M. Gong, H. Xie, and E. D. Goodman, “Automatic Tobacco Plant Detection in UAV Images via Deep Neural Networks,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 11, no. 3. pp. 876–887, 2018.
- (EP13) A. P et al., “CNN Based Technique for Automatic Tree Counting Using Very High Resolution Data,” 2018 International Conference on Design Innovations for 3Cs Compute Communicate Control (ICDI3C). 2018.
- (EP14) A. O. Ok and A. Ozdarici-Ok, “Combining Orientation Symmetry and LM Cues for the Detection of Citrus Trees in Orchards From a Digital Surface Model,” *IEEE Geoscience and Remote Sensing Letters*, vol. 15, no. 12. pp. 1817–1821, 2018.
- (EP15) I. Ahmed et al., “Automatic Detection and Segmentation of Lentil Crop Breeding Plots From Multi-Spectral Images Captured by UAV-Mounted Camera,” 2019 IEEE Winter Conference on Applications of Computer Vision (WACV). 2019.
- (EP16) L. Wallace, A. Lucieer, C. Watson, and D. Turner, “Development of a UAV-LiDAR System with Application to Forest Inventory,” *Remote Sensing*, vol. 4, no. 6. pp. 1519–1543, 2012.
- (EP17) J. M. Peña, J. Torres-Sánchez, A. Serrano-Pérez, A. I. de Castro, and F. López-Granados, “Quantifying efficacy and limits of unmanned aerial vehicle (UAV) technology for weed seedling detection as affected by sensor resolution,” *Sensors*, vol. 15, no. 3, pp. 5609–5626, Mar. 2015.
- (EP18) S. Puliti, H. Ørka, T. Gobakken, and E. Næsset, “Inventory of Small Forest Areas Using an Unmanned Aerial System,” *Remote Sensing*, vol. 7, no. 8. pp. 9632–9654, 2015.
- (EP19) C. Poblote-Echeverría, G. Olmedo, B. Ingram, and M. Bardeen, “Detection and Segmentation of Vine Canopy in Ultra-High Spatial Resolution RGB Imagery Obtained from Unmanned Aerial Vehicle (UAV): A Case Study in a Commercial Vineyard,” *Remote Sensing*, vol. 9, no. 3. p. 268, 2017.
- (EP20) H. Jiang, S. Chen, D. Li, C. Wang, and J. Yang, “Papaya Tree Detection with UAV Images Using a GPU-Accelerated Scale-Space Filtering Method,” *Remote Sensing*, vol. 9, no. 7. p. 721, 2017.
- (EP21) O. Nevalainen et al., “Individual Tree Detection and Classification with UAV-Based Photogrammetric Point Clouds and Hyperspectral Imaging,” *Remote Sensing*, vol. 9, no. 3. p. 185, 2017.
- (EP22) J. Albetis et al., “Detection of Flavescence dorée Grapevine Disease Using Unmanned Aerial Vehicle (UAV) Multispectral Imagery,” *Remote Sensing*, vol. 9, no. 4. p. 308, 2017.
- (EP23) T. K. Alexandridis et al., “Novelty Detection Classifiers in Weed Mapping: *Silybum marianum* Detection on UAV Multispectral Images,” *Sensors*, vol. 17, no. 9, Sep. 2017.
- (EP24) M. Mohan et al., “Individual Tree Detection from Unmanned Aerial Vehicle (UAV) Derived Canopy Height Model in an Open Canopy Mixed Conifer Forest,” *Forests*, vol. 8, no. 9. p. 340, 2017.

- (EP25) O. Csillik, J. Cherbini, R. Johnson, A. Lyons, and M. Kelly, "Identification of Citrus Trees from Unmanned Aerial Vehicle Imagery Using Convolutional Neural Networks," *Drones*, vol. 2, no. 4. p. 39, 2018.
- (EP26) M. Hassanein, Z. Lari, and N. El-Sheimy, "A New Vegetation Segmentation Approach for Cropped Fields Based on Threshold Detection from Hue Histograms," *Sensors*, vol. 18, no. 4, Apr. 2018.
- (EP27) L. Han et al., "Quantitative Identification of Maize Lodging-Causing Feature Factors Using Unmanned Aerial Vehicle Images and a Nomogram Computation," *Remote Sensing*, vol. 10, no. 10. p. 1528, 2018.
- (EP28) J. Yeom, J. Jung, A. Chang, M. Maeda, and J. Landivar, "Automated Open Cotton Boll Detection for Yield Estimation Using Unmanned Aircraft Vehicle (UAV) Data," *Remote Sensing*, vol. 10, no. 12. p. 1895, 2018.
- (EP29) X. Wu, X. Shen, L. Cao, G. Wang, and F. Cao, "Assessment of Individual Tree Detection and Canopy Cover Estimation using Unmanned Aerial Vehicle based Light Detection and Ranging (UAV-LiDAR) Data in Planted Forests," *Remote Sensing*, vol. 11, no. 8. p. 908, 2019.
- (EP30) J. Wu, G. Yang, X. Yang, B. Xu, L. Han, and Y. Zhu, "Automatic Counting of in situ Rice Seedlings from UAV Images Based on a Deep Fully Convolutional Neural Network," *Remote Sensing*, vol. 11, no. 6. p. 691, 2019.
- (EP31) E. Salamí, A. Gallardo, G. Skorobogatov, and C. Barrado, "On-the-Fly Olive Trees Counting Using a UAS and Cloud Services," *Remote Sensing*, vol. 11, no. 3. p. 316, 2019.
- (EP32) A. Safonova, S. Tabik, D. Alcaraz-Segura, A. Rubtsov, Y. Maglinets, and F. Herrera, "Detection of Fir Trees (*Abies sibirica*) Damaged by the Bark Beetle in Unmanned Aerial Vehicle Images with Deep Learning," *Remote Sensing*, vol. 11, no. 6. p. 643, 2019.
- (EP33) C. Hung, M. Bryson, and S. Sukkarieh, "Multi-class predictive template for tree crown detection," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 68. pp. 170–183, 2012.
- (EP34) R. Calderón, J. A. Navas-Cortés, C. Lucena, and P. J. Zarco-Tejada, "High-resolution airborne hyperspectral and thermal imagery for early detection of *Verticillium* wilt of olive using fluorescence, temperature and narrow-band spectral indices," *Remote Sensing of Environment*, vol. 139. pp. 231–245, 2013.
- (EP35) R. A. Diaz-Varela, P. J. Zarco-Tejada, V. Angileri, and P. Loudjani, "Automatic identification of agricultural terraces through object-oriented analysis of very high resolution DSMs and multispectral imagery obtained from an unmanned aerial vehicle," *J. Environ. Manage.*, vol. 134, pp. 117–126, Feb. 2014.
- (EP36) P. J. Zarco-Tejada, R. Diaz-Varela, V. Angileri, and P. Loudjani, "Tree height quantification using very high resolution imagery acquired from an unmanned aerial vehicle (UAV) and automatic 3D photo-reconstruction methods," *European Journal of Agronomy*, vol. 55. pp. 89–99, 2014.
- (EP37) Y. Lin, M. Jiang, Y. Yao, L. Zhang, and J. Lin, "Use of UAV oblique imaging for the detection of individual trees in residential environments," *Urban Forestry & Urban Greening*, vol. 14,

- no. 2. pp. 404–412, 2015.
- (EP38) M. Pérez-Ortiz, J. M. Peña, P. A. Gutiérrez, J. Torres-Sánchez, C. Hervás-Martínez, and F. López-Granados, “A semi-supervised system for weed mapping in sunflower crops using unmanned aerial vehicles and a crop row detection method,” *Applied Soft Computing*, vol. 37. pp. 533–544, 2015.
- (EP39) J. Torres-Sánchez, F. López-Granados, and J. M. Peña, “An automatic object-based method for optimal thresholding in UAV images: Application for vegetation detection in herbaceous crops,” *Computers and Electronics in Agriculture*, vol. 114. pp. 43–52, 2015.
- (EP40) L. Comba, P. Gay, J. Primicerio, and D. R. Aimonino, “Vineyard detection from unmanned aerial systems images,” *Computers and Electronics in Agriculture*, vol. 114. pp. 78–87, 2015.
- (EP41) O. Hassaan, A. K. Nasir, H. Roth, and M. Fakhir Khan, “Precision Forestry: Trees Counting in Urban Areas Using Visible Imagery based on an Unmanned Aerial Vehicle,” *IFAC-PapersOnLine*, vol. 49, no. 16. pp. 16–21, 2016.
- (EP42) A. dos S. Ferreira, A. dos Santos Ferreira, D. M. Freitas, G. G. da Silva, H. Pistori, and M. T. Folhes, “Weed detection in soybean crops using ConvNets,” *Computers and Electronics in Agriculture*, vol. 143. pp. 314–324, 2017.
- (EP43) S. Puliti, L. T. Ene, T. Gobakken, and E. Næsset, “Use of partial-coverage UAV data in sampling for large scale forest inventories,” *Remote Sensing of Environment*, vol. 194. pp. 115–126, 2017.
- (EP44) J. Gao et al., “Fusion of pixel and object-based features for weed mapping using unmanned aerial vehicle imagery,” *International Journal of Applied Earth Observation and Geoinformation*, vol. 67. pp. 43–53, 2018.
- (EP45) V. Otero et al., “Managing mangrove forests from the sky: Forest inventory using field data and Unmanned Aerial Vehicle (UAV) imagery in the Matang Mangrove Forest Reserve, peninsular Malaysia,” *Forest Ecology and Management*, vol. 411. pp. 35–45, 2018.
- (EP46) R. Näsi et al., “Remote sensing of bark beetle damage in urban forests at individual tree level using a novel hyperspectral camera from UAV and aircraft,” *Urban Forestry & Urban Greening*, vol. 30. pp. 72–83, 2018.
- (EP47) L. Comba, A. Biglia, D. R. Aimonino, and P. Gay, “Unsupervised detection of vineyards by 3D point-cloud UAV photogrammetry for precision agriculture,” *Computers and Electronics in Agriculture*, vol. 155. pp. 84–95, 2018.
- (EP48) D. Koc-San, S. Selim, N. Aslan, and B. T. San, “Automatic citrus tree extraction from UAV images and digital surface models using circular Hough transform,” *Computers and Electronics in Agriculture*, vol. 150. pp. 289–301, 2018.
- (EP49) D. Yin and L. Wang, “Individual mangrove tree measurement using UAV-based LiDAR data: Possibilities and challenges,” *Remote Sensing of Environment*, vol. 223. pp. 34–49, 2019.
- (EP50) K. S. Ochoa and Z. Guo, “A framework for the management of agricultural resources with automated aerial imagery detection,” *Computers and Electronics in Agriculture*, vol. 162. pp. 53–69, 2019.

- (EP51) M. Pérez-Ortiz, P. A. Gutiérrez, J. M. Peña, J. Torres-Sánchez, C. Hervás-Martínez, and F. López-Granados, “An Experimental Comparison for the Identification of Weeds in Sunflower Crops via Unmanned Aerial Vehicles and Object-Based Analysis,” *Advances in Computational Intelligence*. pp. 252–262, 2015.
- (EP52) I. H. Yano, J. R. Alves, W. E. Santiago, and B. J. T. Mederos, “Identification of weeds in sugarcane fields through images taken by UAV and Random Forest classifier,” *IFAC-PapersOnLine*, vol. 49, no. 16. pp. 415–420, 2016.
- (EP53) R. A. Diaz-Varela, P. J. Zarco-Tejada, V. Angileri, and P. Loudjani, “Automatic identification of agricultural terraces through object-oriented analysis of very high resolution DSMs and multispectral imagery obtained from an unmanned aerial vehicle,” *J. Environ. Manage.*, vol. 134, pp. 117–126, Feb. 2014.
- (EP54) . M. K. Hentz, A. P. D. Corte, S. P. Netto, M. P. Strager, and E. R. Schoeninger, “Treedetection: automatic tree detection using UAV-based data,” *Floresta*, vol. 48, no. 3. p. 393, 2018.
- (EP55) M. Bah, A. Hafiane, and R. Canals, “Deep Learning with Unsupervised Data Labeling for Weed Detection in Line Crops in UAV Images,” *Remote Sensing*, vol. 10, no. 11. p. 1690, 2018.
- (EP56) Y. Wang, X. Zhu, and B. Wu, “Automatic detection of individual oil palm trees from UAV images using HOG features and an SVM classifier,” *International Journal of Remote Sensing*. pp. 1–15, 2018.
- (EP57) R. Kestur, A. Angural, B. Bashir, S. N. Omkar, G. Anand, and M. B. Meenavathi, “Tree Crown Detection, Delineation and Counting in UAV Remote Sensed Images: A Neural Network Based Spectral–Spatial Method,” *Journal of the Indian Society of Remote Sensing*, vol. 46, no. 6. pp. 991–1004, 2018.
- (EP58) K. Kuželka and P. Surový, “Automatic detection and quantification of wild game crop damage using an unmanned aerial vehicle (UAV) equipped with an optical sensor payload: a case study in wheat,” *European Journal of Remote Sensing*, vol. 51, no. 1. pp. 241–250, 2018.
- (EP59) N. Demir, “Using UAVs for detection of trees from digital surface models,” *Journal of Forestry Research*, vol. 29, no. 3. pp. 813–821, 2018.
- (EP60) J. A. Thomasson et al., “Disease detection and mitigation in a cotton crop with UAV remote sensing,” *Autonomous Air and Ground Sensing Systems for Agricultural Optimization and Phenotyping III*. 2018.
- (EP61) M. Basso and E. P. de Freitas, “A UAV Guidance System Using Crop Row Detection and Line Follower Algorithms,” *Journal of Intelligent & Robotic Systems*. 2019.
- (EP62) S. Selim, N. K. Sonmez, M. Coslu, and I. Onur, “Semi-automatic Tree Detection from Images of Unmanned Aerial Vehicle Using Object-Based Image Analysis Method,” *Journal of the Indian Society of Remote Sensing*, vol. 47, no. 2. pp. 193–200, 2019.
- (EP63) T. Kattenborn, M. Sperlich, K. Bataua, and B. Koch, “Automatic Single Tree Detection in Plantations using UAV-based Photogrammetric Point clouds,” *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. XL–3. pp. 139–144, 2014.

- (EP64) M. Zortea, M. M. G. Macedo, A. B. Mattos, B. C. Ruga, and B. H. Gemignani, "Automatic Citrus Tree Detection from UAV Images based on Convolutional Neural Networks," in Conference on Graphics, Patterns and Images, Foz do Iguaçu.
- (EP65) M. B. Cruzan et al., "Small unmanned aerial vehicles (micro-UAVs, drones) in plant ecology," *Appl. Plant Sci.*, vol. 4, no. 9, Sep. 2016.