



UNIVERSIDAD  
**NACIONAL**  
DE COLOMBIA

# **Metodología para discriminación de malezas basada en la respuesta espectral de la vegetación**

**Ruby Stella Hernández Salazar**

Universidad Nacional de Colombia  
Facultad de Ciencias Agrarias  
Bogotá, Colombia  
2017



# **Metodología para discriminación de malezas basada en la respuesta espectral de la vegetación**

**Ruby Stella Hernández Salazar**

Tesis o trabajo de investigación presentada como requisito parcial para optar al título de:  
**Magister en Geomática**

Directora:  
PhD. Yolanda Rubiano Sanabria  
Codirector:  
PhD. Guido Armando Plaza Trujillo

Línea de Investigación:  
**Geoinformación para el uso sostenible de los recursos naturales**

Universidad Nacional de Colombia  
Facultad de Ciencias Agrarias  
Bogotá, Colombia  
2017



*“Los desafíos son la fuente primaria de los logros”.*

*(Anónimo)*

*A mi esposo Jaime por su apoyo, confianza y amor incondicional, a mis hijas Alejandra y Diana de quienes me siento orgullosa y feliz de tenerlas en mi vida. A mi padre Erasmo (Q.P.D.), a mi madre Edilma artífice de mis sueños, a mi hermano Carlos, mis hermanas Eva, Ma. Teresa, Dora, Cristina, Cecilia y Norma, por estar conmigo en todos los momentos de mi vida, por último a Agatha quien me acompañó con su ronroneo durante las noches de escritura de este trabajo.*



## **Agradecimientos**

Esta tesis se transformó en una realidad con el soporte generoso, habilidades, entusiasmo y el tiempo valioso de muchas personas e instituciones, a todo ellos les extiendo mi más sincera gratitud.

Muy especial a mi directora Yolanda Rubiano Sanabria, por su disposición para compartir su conocimiento, por la exigencia constante, el tiempo dedicado y por ser una estu-penda profesora y una persona de una invaluable calidad humana.

A La Corporación Colombiana de Investigación Agropecuaria CORPOICA, CI La Libertad, en el marco del proyecto: “Desarrollo de estrategias tecnológicas y vinculación del conocimiento en los sistemas de producción de cultivos transitorios, en la altillanura plana y piedemonte llanero”.

Al Dr. Jaime H. Bernal Riobo, por su invaluable colaboración, por su entusiasmo en la exploración de la geomática como ciencia, apoyo logístico y su aporte científico, sin los cuales no se habría podido desarrollar este trabajo.

A los ingenieros Javier Salcedo, Edwin Grisales, Nicolás Álvarez, Jazmín Gutiérrez por el apoyo en las etapas del trabajo. A la señora Eldire Tafur, por su colaboración en la toma de los datos de campo

Al equipo de aeronáutica de la Universidad San Buenaventura USBAgro: Ingenieros Pedro Jiménez, Rafael Cerpa, Henry Porras, Alejandro Urrego y Jorge, por su apoyo en el continuo aprendizaje en la programación de los vuelos y ejecución de los mismos.

Al Instituto Geográfico Agustín Codazzi, Subdirección de Docencia CIAF, por su apoyo en el marco del Convenio con la Universidad Nacional.

A la Universidad Nacional de Colombia, sede Bogotá, a mis profesores, colegas egresados de la Maestría de Geomática, compañeros y amigos.

Muy especial al Dr. Luis Marino Santana, profesor de la Universidad del Valle.





## Resumen

Uno de los problemas que afecta la competitividad y sostenibilidad ambiental de los sistemas de producción de cultivos transitorios, lo ocasiona el manejo de malezas asociado a un excesivo uso de agroquímicos. Los avances desarrollados, en las últimas décadas por la geomática en el contexto de la agricultura de precisión, buscan optimizar el uso de insumos y recursos, y disminuir el efecto negativo derivado de esta actividad. El objeto de este trabajo fue evaluar el potencial de las imágenes del sensor multiespectral MicaSense RedEdge3, adquiridas con RPAS, para la discriminación de malezas en cultivos de soya. El área de estudio se ubicó en las terrazas del piedemonte llanero colombiano, sembradas con soya, en Villavicencio, a las cuales se les tomaron imágenes a dos alturas (30 y 60 m), en los periodos de desarrollo fenológico 11 y 61, (escala BBCH). La metodología propuesta incluye, calibración de la plataforma, planificación del vuelo, adquisición de imágenes, corrección, generación de mosaicos y procesamiento e interpretación de imágenes, usando la clasificación orientada a objetos, la validación se realizó con datos de campo. Se propone el uso de índices diferencia normalizada de vegetación 2 NDVI2 y el Exceso de Verde ExG, para obtener indicadores de vegetación sana no saturados y diferenciar espectralmente las malezas del cultivo. La precisión de la validación de la metodología con datos de campo, utilizando porcentajes de fracción vegetal real, tiene una precisión mayor al 80%.

**Palabras clave:** imágenes digitales, clasificación orientada a objetos, malezas, índice de vegetación, sistema aéreo remotamente pilotado (RPAS).

## Abstract

One of the problems affecting the competitiveness and environmental sustainability of transitory crop production systems, is caused by weed management associated to an excessive use of agrochemicals. Advances developed in the last decades by geomatics in the context of precision agriculture, seek to optimize the use of inputs and resources, and reduce the negative effect derived from this activity. The purpose of this work was to evaluate the images potential of the multispectral MicaSense RedEdge3 sensor, acquired with RPAS, for the identification of weeds in soybean crops. The study area is located on the terraces of the Colombian plains piedmont, planted with soy, in Villavicencio, to which images were taken at two heights (30 and 60 m), in the phenological development periods 11 and 61, (BBCH scale). The proposed methodology includes, platform calibration, flight planning, image acquisition, correction, mosaic generation, image processing and interpretation, using object-oriented classification, validation was performed with field data. The use of normalized difference indices of vegetation 2, NDVI2 and ExG Green ExG is proposed to obtain indicators of healthy unsaturated vegetation and spectrally differentiate weeds from the crop. The validation of the methodology with field data using percentages of real vegetal fraction, has an accuracy greater than 80%.

**Key Words:** Digital images, object-oriented classification, weeds, vegetation index, remotely piloted air system (RPAS).

# Contenido

	Pág.
<b>Resumen</b> .....	<b>IX</b>
<b>Lista de figuras</b> .....	<b>XIII</b>
<b>Lista de tablas</b> .....	<b>XV</b>
Introducción .....	1
<b>1. Objetivos</b> .....	<b>5</b>
1.1 Objetivo General .....	5
1.2 Objetivos Específicos .....	5
<b>2. Revisión de literatura</b> .....	<b>7</b>
2.1 Plataformas RPAS en agricultura .....	7
2.2 Sensores remotos en el monitoreo agrícola .....	10
2.3 Respuesta espectral de la vegetación .....	10
2.4 Índices para estudiar la vegetación .....	12
2.5 Distribución espacial de las malezas .....	14
2.6 Discriminación espectral de malezas .....	17
<b>3. Materiales y Métodos</b> .....	<b>19</b>
3.1 Metodología .....	19
3.2 Localización y área de estudio .....	20
3.3 Registro de datos agronómicos .....	21
3.4 Toma de las imágenes .....	23
3.4.1 Descripción de la plataforma .....	24
3.4.2 Descripción de los sensores .....	25
3.5 Procesamiento de imágenes y construcción del ortomosaico .....	27
3.5.1 Corrección geométrica y radiométrica .....	27
3.5.2 Índices de vegetación .....	30
3.5.3 Programas de procesamiento .....	31
3.6 Clasificación de las imágenes .....	32
3.7 Validación del protocolo metodológico .....	33
<b>4. Resultados y Discusión</b> .....	<b>35</b>
4.2 Adquisición de imágenes .....	38
4.3 Índices de Vegetación .....	46
4.4 Clasificación de imágenes .....	55
4.5 Validación .....	62
<b>5. Conclusiones y recomendaciones</b> .....	<b>65</b>

**Bibliografía .....67**

## Lista de figuras

	Pág.
<b>Figura 2-1:</b> Curva de reflectancia espectral de la vegetación	12
<b>Figura 3-1:</b> Flujograma general de trabajo para el desarrollo de la investigación	19
<b>Figura 3-2:</b> Localización del área de estudio (Sistema de coordenadas geográficas: WGS84)	21
<b>Figura 3-3:</b> Condiciones agrometeorológicas durante el ciclo de desarrollo del cultivo, días de realización de vuelos. Estación meteorológica C.I. La libertad, 2016	23
<b>Figura 3-4:</b> RPAS equipado con el sensor multiespectral, baterías y gps, sobrevolando el cultivo de soya	25
<b>Figura 3-5:</b> localización y amplitud de las cinco bandas espectrales de la cámara MicaSense, respecto a la firma espectral de la vegetación	27
<b>Figura 3-6</b> Mapa ubicación del área de estudio, Lote 53, C.I. la Libertad, con puntos de control y marcos de monitoreo. Imagen tomada con la cámara MicaSense a 60 m de altura en la etapa fenológica 61	28
<b>Figura 3-7:</b> Fotografía tomada a 1.5 m de altura a uno de los marcos de monitoreo, marco construido en pvc. Panel de reflectancia y punto de control.	29
<b>Figura 3-8:</b> Flujograma para la clasificación orientada a objetos para discriminar malezas y parches de malezas en el cultivo de soya.	32
<b>Figura 4-1:</b> Polígono del área de estudio para la programación del plan de vuelo	35
<b>Figura 4-2:</b> Generación de las líneas de vuelo y, sitios de toma de las imágenes	36
<b>Figura 4-3:</b> Efecto de la altura de vuelo sobre la resolución espacial y sobre el área cubierta	37
<b>Figura 4-4:</b> Líneas de vuelo y puntos de ruta; para el vuelo de 30 m altura se realizó 2 vuelos.	39
<b>Figura 4-5:</b> Flujograma usado por el programa Pix4D para la generación de ortomosaicos	40
<b>Figura 4-6:</b> Nube de puntos, Puntos de Control (GCP) y de chequeo (ChP), sobre	42

el área de estudio. Lote 53

<b>Figura 4-7:</b> Cobertura follaje del cultivo de soya y maleza en estado de desarrollo 11 según escala BBCH para cultivo de soya. Imagen original e imagen procesada con el programa ImageJ.	47
<b>Figura 4-8:</b> Mapa cobertura del cultivo de soya, maleza y suelo generado con la aplicación del algoritmo de Ruptura Natural al ortomosaico de NDVI a 30 m	50
<b>Figura 4-9:</b> Marco de monitoreo y sus correspondientes índices de vegetación; etapa de desarrollo del cultivo 11, altura de vuelo 30 m en el mes de septiembre	51
<b>Figura 4-9:</b> Marco de monitoreo y sus correspondientes índices de vegetación; etapa de desarrollo del cultivo 11, altura de vuelo 60 m en el mes de septiembre	51
<b>Figura 4-10:</b> Cobertura del cultivo de soya y malezas en estado de desarrollo 61 según escala BBCH para cultivo de soya. Marco de monitoreo e imagen procesada con el programa ImageJ.	53
<b>Figura 4-11:</b> Mapa cobertura cultivo de soya, maleza y suelo generado con la aplicación del algoritmo de Ruptura Natural al ortomosaico de NDVI2 a 60 m	54
<b>Figura 4-12:</b> Escala de segmentación de la imagen para definir el tamaño de los objetos adecuados para discriminar maleza y cultivo	56
<b>Figura 4-13:</b> Clasificación parches de maleza (plantas 2 hojas) estado de desarrollo 11 con NDVI2, ortomosaico a 30 m de altura. Parámetros usados en el programa eCognition; parámetro de escala 0.6, forma 0.3 y compacidad 0.5	59
<b>Figura 4-14:</b> Clasificación parches malezas (plantas de 2 hojas) Estado Desarrollo 11 con el índice NDVI2, ortomosaico a 60 m de altura. Parámetros usados en el programa eCognition; parámetro de escala 0.6, forma 0.3 y compacidad 0.5	60
<b>Figura 4-15:</b> Clasificación parches malezas (plantas de 2 hojas) Estado Desarrollo 61 con el índice ExG, ortomosaico a 30 m de altura. Parámetros usados en el programa eCognition parámetro de escala 0.6, forma 0.3 y compacidad 0.5	61
<b>Figura 4-16:</b> Clasificación parches malezas (plantas de 2 hojas) Estado Desarrollo 11, ortomosaico a 30 m de altura. Con los índices de vegetación NDVI (izquierda) y NDVI2 (derecha)	63

## Lista de tablas

	Pág.
<b>Tabla 2-1:</b> Índices de vegetación y combinaciones reportados en la literatura para la cuantificación de la fracción vegetal en imágenes aéreas	13
<b>Tabla 3-1</b> Características sensores utilizados en el estudio	26
<b>Tabla 3-2.</b> Longitud de onda y ancho de banda, para la cámara MicaSense.	27
<b>Tabla: 3-3:</b> Valores del panel de reflectancia Micasense, para corrección radiométrica	30
<b>Tabla 3-4:</b> Índices de vegetación evaluados para clasificar la vegetación y la maleza	31
<b>Tabla 3-5:</b> Programas y actividades desarrolladas para clasificación de malezas, parches de malezas en el cultivo de soya.	31
<b>Tabla 4-1:</b> Parámetros requeridos por el programa <i>mission planner</i> para la realización del plan de vuelo	36
<b>Tabla 4.2:</b> Efecto de la altura de vuelo sobre la resolución espacial (imagen izquierda) y sobre el área cubierta	41
<b>Tabla 4-3:</b> Puntos de Control Posprocesados. Datum: Magna_Central, Proyección: WGS84.	42
<b>Tabla 4-4:</b> Precisión de localización por los GCP y errores medios en las tres direcciones de las coordenadas en el vuelo de 30 m de altura	44
<b>Tabla 4-5:</b> Precisión de localización por los GCP y errores medios en las tres direcciones de las coordenadas en el vuelo de 60 m de altura	44
<b>Tabla 4-6:</b> Estadísticas centrales y de dispersión (valores de reflectividad) de las banda originales e índices de vegetación evaluados en la etapa 11 de desarrollo del cultivo, mes septiembre a una altura de vuelo de 30 m	48
<b>Tabla 4-7:</b> Estadísticas centrales y de dispersión (valores de reflectividad) de las banda	49

originales e índices de vegetación evaluados en la etapa 11 de desarrollo del cultivo, mes septiembre a una altura de vuelo de 60 m

**Tabla 4-8:** Estadísticas centrales y de dispersión (valores de reflectividad) de las banda originales e índices de vegetación evaluados en la etapa 61 de desarrollo del cultivo, mes octubre a una altura de vuelo de 30 m 52

**Tabla 4-9:** Estadísticas centrales y de dispersión (valores de reflectividad) de las banda originales e índices de vegetación evaluados en la etapa 61 de desarrollo del cultivo, mes octubre a una altura de vuelo de 60 m 54

**Tabla 4-10:** Umbrales usados para los tres índices de vegetación y evaluados en las dos etapas fenológicas. 58

**Tabla 4-11:** Valores de precisión para la fracción de cobertura de maleza, soya y total estimada con tres índices de vegetación, en dos alturas de vuelo, durante el estado de desarrollo del cultivo 11. 60

**Tabla 4-12:** Valores de precisión para la fracción de cobertura de maleza, soya y total estimada con tres índices de vegetación, en dos alturas de vuelo, durante el estado de desarrollo del cultivo 61. 62



# Lista de Símbolos y abreviaturas

## Abreviaturas

Abreviatura	Término
a.s.n.m	Altura Sobre el Nivel del Mar
BBCH	Escala de estadio fenológico
ChP	Punto de Chequeo
CP	Punto de Control
DEM	Modelo de Elevación de Superficie
DSM	Modelo de Elevación Digital
DTM	Modelo Digital de Terreno
FWHM	Ancho Total a la Mitad del Máximo ( <i>Full Width - Half Maximum</i> )
GCP	Puntos de Control en Tierra
GCS	Sistema de Control de Tierra
GIMBAL	Soporte giroestabilizado para sensores aéreos
GLONASS	Sistema Global de Navegación por Satélite (31 satélites rusos en órbita)
GNSS	Conjunto de tecnologías del Sistema Global de Navegación Satelital
GPS	Sistema de Posicionamiento Global (24 satélites americanos en órbita)
GSD	( <i>Ground Sample Distance</i> ) Resolución Espacial.
IMU	( <i>Inertial Measurement Unit</i> ) unidad de medida inercial
MOSAICO	Conjunto de imágenes georreferenciadas u ortorectificadas y corregidas,
ND	Nivel Digital
NDVI	Índice Normalizado Diferencial de Vegetación
NDVI2	Índice Normalizado Diferencial de Vegetación Modificado
NIR	Infrarrojo Cercano
OBIA	Análisis de Imágenes Basada en Objetos
PA	Agricultura de precisión
RAW	Formato crudo de las imágenes digitales correspondientes a los datos obtenidos por cada uno de los lentes de la cámara
RINEX	( <i>Receiver Independent Exchange Format</i> ) Formato ASCII para almacenamiento e intercambio de datos GNSS rastreados y efemérides
RE	Red Edge
REM	Radiación Electromagnética
RGB	Rojo, Verde, Azul

Abreviatura	Término
RMSE	Cuadrado Medio del Error
RPAS	Sistema Aéreo Tripulado en forma Remota
RS	Teledetección ( <i>Remote sensing</i> )
SFM	Estructura en Movimiento
SNR	Relación Señal/Ruido
UAS	Sistema Aéreo No Tripulado
UAV	Vehículo Aéreo No Tripulado
UgCS	Sistema Universal de Control en Tierra
Wkw	Promedio ponderado del índice de evaluación de la calidad de la imagen

# Introducción

En el paisaje de Piedemonte Llanero, tipo de relieve denominado “Piedemonte Deposicional” (IGAC, 2004), donde se concentra la mayor cantidad de población del departamento del Meta (IGAC, 2005). Para ese entonces la actividad pecuaria, era la actividad económica de mayor frecuencia en el departamento, con el 68% del área, desarrollada de forma extensiva sobre pasturas nativas y mejoradas con algún nivel de degradación dada la presencia de malezas, las que afectan la calidad de las mismas (IGAC, 2005); en cambio la actividad agrícola ocupaba apenas el 6% del área, localizada tanto en el piedemonte, como en, valles aluviales y planicies, por presentar la mejor oferta de suelos, clima e infraestructura de la región. Los cultivos principales son pastos introducidos, arroz, sorgo, maíz y soya (IGAC, 2005) y permanentes como la palma africana, caucho, especies forestales y algunos frutales; el aumento de la producción agrícola que según algunos autores ha ocurrido en la última década se deriva de un aumento de áreas que en el pasado sustentaban cubiertas naturales lo que ha derivado en el incremento de las dosis de enmiendas y fertilizantes que buscan incrementar los rendimientos y hacer competitiva esta actividad (Rodríguez, 2016).

La presión ejercida sobre el suelo, el aumento de insumos agrícolas y la introducción de monocultivos han estado acompañados de manera paulatina, por un incremento en la cantidad y variedad de malezas, que entran a competir con los cultivos y hacen necesaria la aplicación de herbicidas, los cuales, en la mayoría de los casos, son usados en cantidades excesivas y manejados de manera inadecuada. Los desarrollos de la Geomática aplicada a la producción agrícola actual, en el contexto de la agricultura de precisión, buscan la optimización del uso de insumos y recursos sin detrimento de la calidad ambiental y, garantizando la sustentabilidad de la actividad agrícola.

Uno de los pilares de la producción agrícola se enfoca en el manejo de las malezas, las cuales poseen alta capacidad para adaptarse a condiciones adversas; son colonizadoras naturales del suelo que, interfieren en el desarrollo del cultivo, compiten por luz, agua,

nutrientes, CO<sub>2</sub> y espacio; dificultan y encarecen las labores del cultivo, causan pérdidas en el rendimiento y disminuyen la calidad de la cosecha. Se estima que aproximadamente el 50% de las labores de mecanización que se realizan en los cultivos directa o indirectamente, tienen como fin el control de las malezas (Knezevic, 2014). Esto hace que se tengan que introducir estrategias para reducir el uso de productos fitosanitarios; no solo mejorando aspectos de las dosis, si no también enfocando su aplicación a los sitios en donde sea necesario y evitando las áreas que no lo requieran. Así se mejora la rentabilidad de la producción y se disminuye la rentabilidad de agroquímicos vertidos al ecosistema suelo.

En las últimas dos décadas los sensores remotos, han sido ampliamente explorados como herramientas para la detección y cartografía de malezas en cultivos agrícolas (Joshi *et al.* 2002); se trata de una tecnología no invasiva que permite obtener información sobre un objeto, área o fenómeno a través del análisis de los datos adquiridos por un dispositivo, conocido como sensor remoto, que no está en contacto con la superficie observada (Chuvienco, 2008). La base de la teledetección radica en que cada cuerpo u objeto presenta un patrón de energía reflejada propia y diferente conocida como firma espectral, que lo distingue de los demás (Chuvienco y Huete, 2010)

Una adecuada y eficiente delimitación de los parches de malezas en campo, a través de la teledetección, permite realizar una aplicación eficiente de herbicidas por sitio específico. La disminución en el uso de herbicidas, como resultado de esta práctica reducirá los costos de manejo por parte de los agricultores y promoverá un descenso en la aplicación de agroquímicos en el ambiente (Mulla, 2013).

Por ello el avance en las estrategias de aspersion de “herbicidas” en los cultivos, en el contexto de la agricultura de precisión, requiere del mejoramiento en las técnicas de detección de las malezas, para lo cual la teledetección es considerada una técnica eficaz (Mulla, 2013).

Diferentes estudios han reportado que las poblaciones de malezas presentan alta dependencia espacial, se distribuyen a lo largo de las líneas del cultivo o forman parches (Martin y Gallastegui, 2005; Jurado *et al.* 2003; Ngouajio y Lemieux, 1999). Como se señaló anteriormente la teledetección hace posible la discriminación de malezas y

cultivos y la elaboración de mapas de manejo por sitio específico, a fin de realizar las aplicaciones en el momento y lugar oportunos, reduciendo y optimizando la cantidad de herbicida (Chunyuan y Wang, 2014; Agostinetti y Piesanti, 2008; Noble, *et al.* 2005; Thorp y Tian, 2004b; Lamb, y Brown, 2001).

Ahora bien, autores como Thorp y Tian (2004a) han establecido que la discriminación de malezas con teledetección se puede abordar desde dos aproximaciones metodológicas: 1) la diferenciación de las malezas/cultivo en estados de crecimiento temprano (desde el estado de plántula 2-4 hojas verdaderas) o 2) en fases fenológicas tardías (desde el inicio de la floración o inicio de senescencia). La detección en estado de crecimiento temprano de las malezas requiere la utilización de sensores de alta resolución espacial; debido a que en ese estado de crecimiento las malezas y el cultivo presentan firmas espectrales y apariencia similares, las malezas se suelen distribuir en parches pequeños y, dado que el cultivo aún no ha cubierto las zonas entre-hileras, la reflectancia del suelo podría interferir en la detección. Por otra parte la detección en estados tardíos permite una mejor diferenciación espectral de las malezas y el cultivo, debido a las diferencias en sus ciclos de crecimiento, y la reducción en la interferencia del suelo gracias a la cobertura total del área por parte de la vegetación (López-Granados, 2013; Thorp y Tian, 2004b).

Estas dos aproximaciones requieren la selección las longitudes de onda más adecuadas en productos multiespectrales o hiperespectrales para aumentar la probabilidad de discriminar las malezas presentes en el cultivo, con los cuales se procede a realizar la corrección radiométrica y cálculos de índices de vegetación (Gómez *et al.* 2010). La curva de reflectancia de una planta (o cultivo), está directamente relacionada con sus características morfológicas y fisiológicas (Schmidt, 2003). A final del siglo pasado, Zwiggelaar, (1998) reportó bandas espectrales específicas (rojo, borde rojo e infrarojo cercano) para lograr la identificación de las malezas.

Como parte de los sensores remotos se están usando cada vez más las imágenes digitales tomadas con vehículos aéreos no tripulados (UAV); por su versatilidad y control local se pueden programar vuelos en épocas críticas del cultivo, o en días nublados; también estos pueden transportar sensores con diferentes tipos de rango espectral y a menores alturas de vuelo dependiendo de la finalidad del estudio (Peña *et al.* 2015;

Zhang y Kovacs, 2012; Da Silva, 2010; Martín *et al.* 2005).

El manejo de malezas en los cultivos transitorios es un prerrequisito importante para mantener la calidad y cantidad de la producción de granos. En Colombia, el Instituto Colombiano Agropecuario (ICA), mediante estudios realizados durante 12 años, encontró que el efecto de la competencia de las malezas en la reducción de los rendimientos de los cultivos de maíz, arroz y algodón eran en promedio del 56%, 54% y 31%, respectivamente (Fuentes y Romero, 1991). Pero se sabe que la competencia ejercida por las malezas es dinámica, cambia con las condiciones ambientales, la disponibilidad de factores de crecimiento, la habilidad competitiva del cultivo, la densidad del cultivo y de las malezas, la biomasa y el vigor de las malezas (Yeganehpoor *et al.* 2014).

Estudios orientados a determinar el periodo crítico de competencia de malezas aportan información útil para ajustar el tiempo de monitoreo de las malezas en los lotes de cultivo, que integrados al conocimiento de la distribución espacial y temporal de las mismas, permiten mejorar la eficiencia en las labores de manejo para evitar daños irreversibles ocasionados por la competencia (Dille, 2014). La implementación y uso de tecnologías de percepción remota y de automatización, junto con la información de densidad y distribución espacial de las especies de malezas, podrían ayudar al diseño de prácticas más efectivas de manejo de malezas.

Trabajos de esta naturaleza, uso de teledetección para la discriminación de malezas en cultivos transitorios, son muy necesarios en Colombia, por cuanto aún no se reportan artículos publicados o estudios en esta materia, a pesar de ser una problemática que se está incrementando con el ingreso y crecimiento de nuevas áreas y cultivos, especialmente en el Piedemonte Llanero. Los resultados de esta investigación en lo práctico y metodológico, podrán implementarse en las áreas agrícolas del país, especialmente donde se realice agricultura de precisión, beneficiando a los agricultores y sociedad en general, ya que redundará en una disminución en las aplicaciones de herbicidas y por ende en la contaminación de los suelos y ambiente.

# 1. Objetivos

## 1.1 Objetivo General

Generar una metodología basada en la respuesta espectral de imágenes tomadas con un Sistema Aéreo Remotamente Pilotado RPAS (*Remote Piloted Aircraft Systems*) para discriminar malezas en cultivos transitorios. Estudio de caso: cultivo de soya

## 1.2 Objetivos Específicos

- Determinar la potencialidad de las imágenes del sensor multiespectral MicaSense RedEdge 3 y de un RPAS para la identificación de malezas en cultivos de soya.
- Generar el protocolo metodológico para la discriminación de malezas en cultivo de soya a partir de imágenes multiespectrales (RedEdge3).
- Evaluar el protocolo metodológico con datos de campo en el área de estudio.





## 2. Revisión de literatura

### 2.1 Plataformas RPAS en agricultura

La disponibilidad de imágenes de sensores remotos obtenidos desde plataformas satelitales, es a menudo limitada por la nubosidad; esto ha conducido a la búsqueda de nuevas alternativas, como la teledetección con RPAS, que surge como una técnica promisoriosa para las áreas afectadas por condiciones atmosféricas adversas. (Moran *et al.* 1997).

Los RPAS, son prometedores para la agricultura actual; que requiere información espacial y temporal de alta resolución, ya que facilitan identificar, mediante cámaras multispectrales o hyperspectrales la variabilidad de los cultivos en campo y mejorar la toma de decisiones del manejo agronómico del cultivo en tiempo real (Link *et al.* 2013).

Los RPAS son vehículos de fácil acceso para los científicos de teledetección y los agricultores (Swain *et al.* 2010). Sin embargo, su uso está regulado por las normas de la navegación aérea establecidas en cada país. En Colombia, la legislación para la parte agrícola aún no es clara, pues se encuentra en proceso de construcción; por lo que la Aeronáutica Civil en su "Circular Reglamentaria N° 002, de 2015 presenta los Requisitos Generales de Aeronavegabilidad y Operaciones para RPAS (*Remotely Piloted Aircraft Systems* o Aeronave Pilotada a Distancia) (Numeral 4.25.8.2)", publicada en el Diario Oficial Número 49.624 del 03 de Septiembre de 2015, y da a conocer que para su uso en la agricultura esta debe acogerse al numeral *Uso recreativo*, con sus normas básicas de operación. Es importante aclarar que se han usado diferentes términos para denominar estas aeronaves como UAV, UAS, DRONE, ahora RPAS. Estos términos también están definidos en la circular arriba citada.

Zhang y Kovacs (2012) realizaron una revisión sobre los avances en la aplicación de plataformas UAV (Vehículo Aéreo no Tripulado) en la agricultura, que incluyó aspectos relacionados con la toma de imágenes remotas, georreferenciación y generación de ortomosaicos.

Desde el año 2000, la utilización de los RPAS en aplicaciones fotogramétricas es más frecuente, este nuevo escenario puede ser explicado por la mayor disponibilidad de sistemas de posicionamiento global/navegación inercial (GPS/INS) de bajo costo. Como resultado, hoy es posible obtener productos georreferenciados con alta precisión espacial (submétrica) (Sieber y Teizer, 2014; Chiabrandon *et al.*, 2011).

La alta calidad espacial de los ortomosaicos obtenidos de sensores acoplados a RPAS no es siempre garantía de alta precisión, ya que los movimientos extremos de la plataforma, traslapes inapropiados, errores en los planes de vuelo y la incapacidad de almacenamiento de grandes volúmenes de datos, pueden generar mosaicos distorsionados (Turner *et al.*, 2014; Samad, 2013).

Al relacionar los datos espectrales y las poblaciones de malezas estas plataformas ofrecen una gran oportunidad para la discriminación y el manejo de las mismas; no obstante, las imágenes deben estar ortorectificadas, para asegurar ajuste multitemporal, correcciones radiométricas, fusión de bandas y cálculos de índices de vegetación (Martín, 2005; Rabatel *et al.* 2013).

Sin embargo, antes de dar inicio al análisis de las imágenes es importante asegurarse de que éstas mantengan patrones de iluminación similar (corrección atmosférica y de iluminación), con mínima deformación (corrección geométrica) y alineadas apropiadamente (imagen registrada). Esto hace parte de las etapas de pre-procesamiento, corrección atmosférica y rectificación de la imagen (georreferenciación) (Shi *et al.* 2011). En la corrección atmosférica se mejoran factores relacionados con iluminación, azimuth, elevación y condiciones atmosféricas, tales como alto brillo solar y nubosidad. Para esto se utilizan algoritmos que remueven los efectos atmosféricos. La corrección geométrica se realiza utilizando aproximaciones paramétricas y no paramétricas.

La aproximación no paramétrica requiere la identificación de atributos comunes en la imagen y en un mapa. Para esto se utilizan puntos de control tomados en campo. Las paramétricas requieren la detección de la geometría y los parámetros de orientación exterior (altitud y posición), los cuales describen las condiciones en las que se capturó la imagen (Dowman *et al.* 1984).

Vioix *et al.* (2002) trabajaron en la detección y localización de parches de malezas mediante el desarrollo de un algoritmo de análisis de frecuencia en fotografías aéreas con filtros ópticos y análisis de redes neurales. De Castro (2013) evaluó el uso de imágenes aéreas para medir la infestación de parches de *Ditoplotaxis* spp., *Sinapis* spp. en cultivos de trigo en España, y también las potencialidades y limitaciones del uso de imágenes QuikBird para la discriminación de parches de éstas malezas. (Sartori y Galo, 2005) utilizaron la respuesta espectral para discriminar malezas en plantaciones de café, mediante mosaicos de fotografías aéreas y análisis *IHS* (Intensity, Hue; Saturation).

En Polonia, Pudelko *et al.* (2008), utilizaron la teledetección para el mapeo de malezas en el cultivo de maíz y realizaron la zonificación de parches de malezas con fotografías aéreas, generando un mapa de prescripción de herbicidas que se ingresó a las pulverizadoras, reduciendo significativamente la descarga innecesaria de agroquímicos.

Para la detección automática y evaluación de malezas en el cultivo de algodón, Alchanatis *et al.* (2005); desarrollaron un sensor hiperespectral sintonizable acústico-óptico y un algoritmo de detección (reflectancia espectral), aplicaron el algoritmo a una base de datos de imágenes de plantas de algodón y malezas en estados de desarrollo tempranos. Los resultados mostraron la presencia de malezas en todas las imágenes, las áreas afectadas con malezas fueron estimadas con un error del 14% mientras que una falsa detección fue estimada con un 15%.

En Colombia, se han realizado estudios aplicados de teledetección, pero más hacia la coberturas arbóreas, los más frecuente han sido los de Cartografía de coberturas terrestres (Coordination of Information on the Environment) CORINE Land Cover, adaptada para Colombia, a escala 1:100.000, liderados por el IDEAM, (2010). Otros son los realizados por Rodríguez, (2011); Ángel, (2012); Hernández y Orduña, (2013).

Para el caso de la altillanura, existen varios trabajos enfocados a la discriminación de áreas de cultivos, pastos nativos y mejorados, utilizando distintas técnicas Rodríguez *et al.* (2013), Santana y Salas, (1998). Sin embargo, a la fecha no se reportan estudios en el área de malezas y sensores remotos con RPAS en cultivos comerciales.

## **2.2 Sensores remotos en el monitoreo agrícola**

La teledetección se basa en la interacción entre la radiación electromagnética (REM) y los objetos de interés. Los sensores remotos perciben la REM reflejada o emitida por la superficie. La interacción es registrada y analizada con fines específicos y se fundamenta en la Ley de Lambert-Beer, que relaciona la absorción de la luz con las propiedades ópticas del material que atraviesa, así: del total de la radiación incidente sobre un objeto, parte es reflejada por éste (Reflectancia), parte es transmitida (Transmitancia) y parte es absorbida (Absorbancia) para posteriormente ser emitida en forma de calor (Moreira, 2011).

La agricultura y las ciencias ambientales demandan en forma permanente de la percepción remota utilizando imágenes satelitales y aéreas; sin embargo, la necesidad de una alta resolución espacial significa costos altos, esto ha permitido que la incursión de los RPAS en la teledetección haya ganado espacios importantes debido a la versatilidad de su tamaño. A la par con estas plataformas los sensores también han evolucionado, presentando grandes desarrollos en su peso y tamaño y también para adaptarse a las necesidades del usuario y de la aplicación (Colomina y Molina, 2014).

## **2.3 Respuesta espectral de la vegetación**


Los objetos examinados mediante sensores remotos tienen un patrón espectral único que los hace distinguibles de otros. Del conjunto de ondas que tiene el espectro electromagnético, las porciones de los rayos visibles e infrarrojo cercano VIS-NIR (400 - 1300 nm) son las más utilizadas en las aplicaciones agrícolas, ya que la luz del sol es la fuente de energía que activa el proceso de fotosíntesis en las plantas. La cantidad de radiación reflejada por las plantas es inversamente proporcional a la radiación absorbida por los pigmentos vegetales y varía con la longitud de onda de la radiación incidente

(Pinter *et al.* 2003). La clorofila absorbe la radiación en el espectro visible de 400 a 700 nm, particularmente en las longitudes de onda de 430 nm (azul-B) y 660 nm (rojo-R) para la clorofila *a*, y 450 nm (B) y 650 nm (R) para la clorofila *b* (Blackburn, 2007).

En contraste, la reflectancia de la planta es alta en la región del NIR (700-1300 nm), como resultado de los efectos de la estructura de las hojas. Este comportamiento de la reflectancia, entre las porciones roja y NIR del espectro, es la base teórica sobre la cual se fundamenta el desarrollo de índices de vegetación (Sripada *et al.* 2006).

Diferencias fenotípicas entre especies de plantas resultan de factores genéticos y ambientales, los cuales afectan la eficiencia fotosintética que se reflejará en diferencias en la concentración de pigmentos vegetales, en la estructura de las hojas y arquitectura del dosel y en la química foliar; por tanto es razonable esperar que las plantas presenten espectros característicos de reflectancia (Schmidt y Skidmore, 2002).

En la agricultura de precisión es frecuente el uso de los espectros de reflectancia de la vegetación, los que están determinados por la composición química y propiedades físicas de las plantas, además de las propiedades espectrales de la fuente emisora de luz. La firma espectral de una superficie u objeto representa una medida cuantitativa única de la energía que se refleja en cada espectro electromagnético. En el caso de la vegetación la curva de reflectancia cambia en función de su estadio fenológico, de ahí que la vegetación vigorosa tenga una reflectancia reducida en el espectro visible, con un máximo relativo en la banda del verde (Figura 2-1), debido a que los pigmentos presentes en las hojas muestran diferentes características de absorción (De Castro, 2013; Bhandari *et al.* 2012)

**Figura 2-1.** Curva de reflectancia espectral de la vegetación

Fuente: Elaboración propia

Las técnicas de percepción remota también involucran la toma de información con espectrorradiómetros de campo o de laboratorio (Mulla, 2013; Ollinger, 2011; Lee *et al.* 2010; Chuvieco, 2008); lo que han posibilitado el seguimiento de factores como el estado nutricional de los cultivos (Houborg *et al.* 2009), valoración de propiedades del suelo (Haboudane *et al.* 2004), de condiciones de estrés hídrico en los cultivos (Meron *et al.* 2010), distribución de malezas en cereales y leguminosas (De Castro *et al.* 2012).

## 2.4 Índices para estudiar la vegetación

La radiación reflejada por los cultivos según la longitud de onda (firmas espectrales), son afectadas por factores relacionados a la planta, tales como la morfología y fisiología (Gates *et al.* 1965) y por el suelo en doseles abiertos.

La reflectancia en el rango visible se basa en el contenido de clorofila de la hoja, y la reflectancia en el NIR está relacionada con la estructura de la hoja (Daughtry *et al.* 2000

y Knipling, 1970). Esto significa que en una hoja verde y en una hoja clorótica, la radiación visible se reflejará en forma diferencial aunque la reflectancia en el NIR no se afecte.

El suelo desnudo y el follaje de los cultivos se encuentran con frecuencia muy juntos en las imágenes de los sensores remotos, y la mezcla de sus firmas espectrales confunde a menudo su respuesta espectral. Existen algoritmos para separar espectros mezclados Huete y Escadafal, (1991), los espectros derivados de Demetriades-Chat y Clark, (1990) o índices espectrales ajustados al suelo (Haboudane *et al.* 2004), que buscan aislar la respuesta espectral de la planta cuando es afectada por el suelo.

Una forma simple de extraer información acerca de los cultivos con las imágenes digitales es a través de la estimación de índices de vegetación. Estos son cálculos aritméticos de la reflectancia en diferentes longitudes de onda; producto de estos datos espectrales que son sumados, divididos o multiplicados, se obtiene un valor, que expresa la cantidad o vigor de la vegetación dentro de un pixel (Campbell, 2008).

Sin duda los índices más extendidos son los de vegetación (Tabla 2-1), los cuales varían debido a las bandas espectrales utilizadas para su cálculo, resoluciones espectrales (anchos de banda) y a los algoritmos utilizados. El índice de vegetación más utilizado en agricultura, es el Índice de Vegetación de Diferencia Normalizada (NDVI), el cual responde a los cambios en la cantidad de biomasa verde, al contenido de clorofila, contenido de nitrógeno y al estrés hídrico en las plantas. Sin embargo, presenta problemas al emplearse en cultivos con follaje denso ya que se satura la región del infrarrojo cercano (Mulla, 2013).

**Tabla 2-1:** Índices de vegetación y combinación de bandas reportados en la literatura para la cuantificación de la fracción vegetal en imágenes aéreas.

Índice	Relación entre bandas	Referencia
"Relation Vegetation Index"	$RVI = \frac{NIR}{R}$	(Jordán, 1969)
"Simple Ratio Index"	$SR = \frac{NIR}{R}$ $SR(RE) = \frac{NIR}{RedEdge}$	(Jordan, 1969)
Normal Dfference Vegetation Index	$NDVI = \frac{NIR - R}{NIR + R}$	(Rouse <i>et al.</i> 1974)
"Green Normal Difference Vegetation	$GNDVI = \frac{NIR - G}{NIR + G}$	(Gitelson <i>et ál.</i> 1979)

"Index"		
"Index Red/Blue"	$BR = \frac{R}{B}$	(Everitt y Villarreal, 1987)
"Soil-Adjusted Vegetation Index"	$SAVI = \left[ \frac{(NIR - R)}{(NIR + R) + L} \right] \times (1 + L)$	(Jackson y Huete, 1991)
"Soil-Adjusted Vegetation Index modified"	$MSAVI2 = \frac{NIR - R}{NIR + R} (1 + L)$ $L = \text{Factor corrección brillo del suelo}$	(Qi et al. 1994 b)
"Excess Green"	$ExG = 2g - r - b$	(Woebbecke et al. 1995)
"Enhanced Vegetation Index"	$EVI = 2.5 \frac{NIR - R}{NIR + 6 \times R - 7.5 \times B}$	(Huete et al. 1996, 1997)
"Normalized Difference RedEdge Index"	$NDRE = \frac{NIR - RE}{NIR + RE}$	(Barnes et al. 2000)
"Normalized Green-Red Difference Index"	$NGRDI = \frac{(G - R)}{(G + R)}$	(Gitelson et al. 2002)
"Color Index of vegetation"	$CIVE = 0.441r - 0.881g + 0.385b + 18.78745$	(Kataoka et al. 2003)
"Excess Green Minus Excess Red"	$ExGR = ExG - 1.4r - g$	(Camargo Neto, 2004)
"Vegetativen Index"	$VEG = \frac{g}{r^a b^{(1-a)}} \quad \text{con } a = 0.667$	(Hague et al. 2006)
"Combination of vegetation Index"	$r = \frac{R}{R + G + B} \quad g = \frac{G}{R + G + B} \quad b = \frac{B}{R + G + B} \quad r + g + b = 1$	(Gée et al. 2008), (Meyer y Neto, 2008)
"Combination Index"	$COM = 0.25ExG + 0.3ExGR + 0.33CIVE + 0.12VEG$	(Guijarro et al. 2010)
"Combination Index 2"	$COM(2) = 0.36E \times G + 0.47CIVE + 0.17VEG$	(Guerrero et al. 2012)

Fuente: Elaboración propia

Estudios agrícolas, basados en el cálculo de Índices de Vegetación a partir de imágenes RPAS, han sido utilizados en varias aplicaciones, tales como el mapeo de la cobertura foliar en cereales (Torres-Sánchez et al. 2014), el contenido de clorofila en cereales (Berni et al. 2009; Ramos, 2016), enfermedades en plantas (García-Ruiz et al. 2013; Castañeda, 1999), la infestación de malezas (Torres-Sánchez et al. 2013) e impactos en los cultivos debidos al control de malezas (Streibig et al. 2014).

## 2.5 Distribución espacial de las malezas

El manejo, a nivel de sitio específico del cultivo, de las malezas en estadios tempranos requiere del desarrollo de metodologías que permitan generar mapas espaciales de las arvenses y que puedan ser ingresados a los equipos de agricultura de precisión



(fumigadoras) para el control exitoso de estas, con el fin de maximizar los beneficios económicos y reducir el impacto ambiental del uso indiscriminado de herbicidas (Gómez y López, 2013). Para generar un mapa de dosis variable de herbicida que pudiera ser llevado a las pulverizadoras, y redujera significativamente la descarga de productos químicos al ambiente, Pudelko *et al.* (2008) usaron la teledetección para mapear las malezas en un cultivo de maíz y zonificaron los parches de malezas con fotografías aéreas.

En la cartografía de malezas es importante definir el tamaño óptimo del pixel requerido, el cual se calcula teniendo en consideración el tamaño de la maleza que se quiere discriminar, la distancia entre hileras del cultivo y el tipo de cultivo. En general, se requieren al menos cuatro pixeles para capturar objetos pequeños en una imagen. Hengl, (2006) y López-Granados *et al.* (2016) encontraron que para discriminar malezas en un cultivo de girasol se requería de un tamaño de pixel entre 1 a 4 cm, los cuales se alcanzaron con una altura de vuelo de 27 m a 105 m con una cámara RGB (Olympus PEN E-PM1, de 12 megapíxeles y resolución radiométrica de 8 Bits) y de 19 a 74 m en el caso de una cámara multiespectral (Tetracam mini-MCA-6, de seis bandas independientes y 1.3 megapíxeles) Sin embargo, cuando lo que se buscaba era la discriminación de parches de malezas servirían imágenes remotas con un tamaño de pixel de 5 cm o superior, tomadas a alturas de vuelo superiores a 100 m para ambas cámaras (Torres *et al.* 2013).

Las imágenes satelitales disponibles para la obtención de información de cultivos tienen resolución espacial que van de 30 y 120 m para el Landsat, 5, 10 y 20 m en SPOT, 10 m en Sentinel 2A, 5.8 m para IRS1, 5 m con RapidEye, 1 a 4 m con Ikonos y 0.6 a 2.4 m con QuickBird. No obstante estas resoluciones dejan fuera el nivel de precisión requerido para el monitoreo de malezas (Lamb y Brown, 2000).

El costo de las imágenes satelitales ya no es la mayor limitante, pero lo que constituye un fuerte impedimento hasta hoy es la imposibilidad de adquirir imágenes de alta resolución espacial, temporal y espectral que posibiliten el monitoreo efectivo de las infestaciones de malezas durante el ciclo de crecimiento del cultivo, aunado a la cobertura frecuente de nubosidad que existe en el trópico húmedo.

Con la utilización de imágenes satelitales y aéreas en el manejo por sitio específico de las malezas se han reportado resultados exitosos en el control de arvenses en estadios tardíos de crecimiento del cultivo, floración, con ahorros hasta de un 50% en la aplicación de herbicidas en España (De Castro *et al.* 2013; Peña, *et al.* 2007; López *et al.* 2006). Sin embargo, en la mayoría de los escenarios de manejo de malezas, el periodo crítico para su control ocurre en los estadios tempranos de crecimiento del cultivo, justo después de la emergencia de este. En tales condiciones, el mapeo de malezas con sensores remotos presenta un mayor grado de dificultad debido a: 1) la necesidad de trabajar con imágenes remotas de alta resolución espacial (centímetros) para detectar malezas pequeñas, en estadios de una a dos hojas, y distribuidas en parches dentro del campo cultivado (López, 2011), 2) las similitudes en la reflectancia (firmas espectrales) que se dan en estadios de crecimiento temprano entre las malezas y cultivos pertenecientes a la misma familia, lo que reduce la posibilidad de utilizar la información espectral para discriminarlas del cultivo y 3) la interferencia (ruido) de la reflectancia del suelo (Thorp y Tian, 2004 b).

De Castro y Mejía, (2013) evaluaron el uso de imágenes aéreas para medir la infestación de parches de *Ditoplotaxis* spp. y *Sinapis* spp en cultivos de trigo en España, y estudiaron las potencialidades y limitaciones de las imágenes QuikBird para la discriminación de parches de estas malezas encontrando que estas imágenes pueden ser una buena opción para mapear los parches de malezas crucíferas en los cultivos de trigo a escala mayor a tres hectáreas.

Los RPAS pueden volar a bajas alturas (< 120 m), admitiendo la toma de imágenes de resolución espacial menor a 3 cm/pixel, que permiten distinguir parches de malezas y plantas individuales pequeñas (Xiang y Tian, 2011). También, facilitan la adquisición de imágenes aún en días nublados con menores tiempos en la preparación y realización del vuelo, lo que da una mayor flexibilidad.

Trabajos de investigación se han enfocado en la detección e identificación de malezas sobre la base de la morfología de la planta (espacial), de la radiación reflejada por el follaje de la planta (espectral) y en la reflectancia y en las propiedades espectrales de la especie. Sin embargo, han hecho énfasis en las características espectrales con sensor aéreo o remoto (Pérez-Ortiz *et al.* 2016; López, 2013; Zhang y Kovacs, 2012; Bhandari *et*

*al.* 2012; Martín *et al.* 2005; Noble *et al.* 2002; Zwiggelaar, 1998).

## 2.6 Discriminación espectral de malezas

Para la, discriminación, identificación y mapeo de malezas utilizando sensores remotos en Dijon (Francia), se reporta la investigación realizada por Vioix *et al.* (2002), quienes trabajaron en la detección y localización de parches de malezas usando un algoritmo de análisis de frecuencia en fotografías aéreas con filtros ópticos y análisis de redes neurales.

En la ciudad de Lavras, Mina Gerais, Sartori *et al.* (2009) utilizaron exitosamente la respuesta espectral para discriminar malezas en plantaciones de café, usando mosaicos de fotografías aéreas y mediante transformación *IHS* (Intensity, Hue; Saturation).

Alchanatis *et al.* (2005) desarrollaron un sensor hiperspectral sintonizable, acústico-óptico, y un algoritmo de reflectancia espectral para la detección automática y la evaluación de malezas en un cultivo de algodón. Aplicaron el algoritmo a una base de datos de imágenes de plantas de algodón y malezas en estados de desarrollo tempranos; los resultados mostraron la presencia de malezas en todas las imágenes; las áreas afectadas con malezas fueron estimadas con un error del 14% mientras que una detección no acertada fue detectada en un 15%.

La similitud espectral entre las malezas y los cultivos, principalmente en la primera fase de crecimiento, hace difícil la discriminación entre los dos, convirtiéndose en una limitación en la aplicación de los métodos de análisis de imágenes basados únicamente en la información tomada del píxel. Para resolver este tipo de problemáticas, el análisis de imágenes orientado a objetos (Object-Based Image Analysis OBIA) planteado como un algoritmo que permite distinguir las malezas de los cultivos, en estadios tempranos (Torres-Sánchez, *et al.* 2014; Peña, *et al.* 2014; Hernández y Orduña, 2013; Rodríguez, 2012; Laliberte *et al.* 2012; Laliberte y Rango, 2009).

El OBIA identifica unidades homogéneas espaciales y espectrales denominadas objetos, creados a partir de la agrupación de píxeles adyacentes de acuerdo a un procedimiento conocido como segmentación. Posteriormente, se utilizan atributos de localización,

textura, proximidad y relaciones jerárquicas, los cuales mejoran los resultados de la clasificación de las imágenes (Blaschke, 2010; Peña, *et al.* 2011).

La habilidad para incorporar elementos utilizados tradicionalmente en la interpretación de fotografías aéreas (color, tamaño, forma, textura y patrones), es una de las fortalezas del análisis de imágenes orientada a objetos (Laliberte *et al.* 2012). La técnica de selección de los atributos (bandas de la imagen, relación entre bandas, área, compactación, diferencias con su vecino y propiedades de textura) varía desde métodos gráficos hasta aproximaciones estadísticas que involucran la distancia de separación para la clasificación de las imágenes Laliberte *et al.* (2012); Carleer y Wolff, (2006); Herold *et al.* (2003) emplearon la distancia Bhattacharyya, mientras que Zhang *et al.* (2010) usaron la distancia Jeffreys-Matusita (KM) para la selección de atributos. Van Coillied *et al.* (2007) recurrieron al uso de algoritmos genéticos y evaluaron gráficas espaciales, gráficas de cajas, histogramas de las bandas y técnicas de optimización espacial. En cambio para (Laliberte *et al.* 2012; Laliberte *et al.* 2007; Chubey *et al.* 2006; Yu *et al.* 2006), los análisis de árboles de clasificación para la selección de los atributos óptimos resultaron exitosos. De igual forma, López-Granados *et al.* (2016) evaluaron en España el desempeño de algoritmos para clasificar y mapear parches de malezas en cultivo de maíz encontrando una buena precisión cuando se usaron imágenes tomadas a una altura de vuelo de 30 m.

En Colombia, a la fecha no se encontraron reportes de procesamiento de imágenes digitales aplicadas al estudio de malezas.

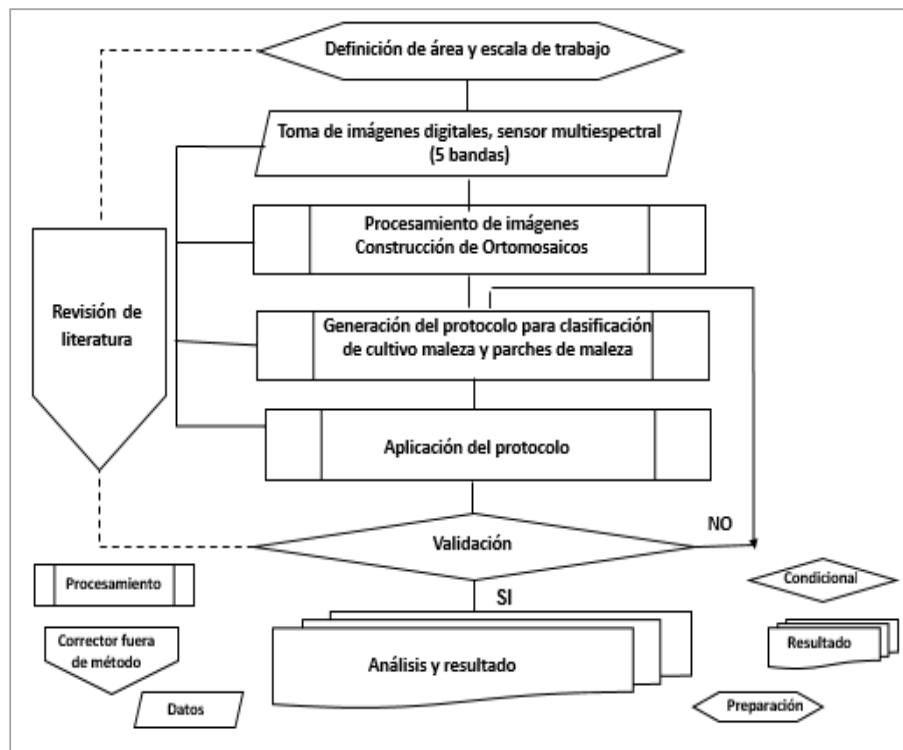
En un campo de cultivo en estadios tempranos de crecimiento, la posición relativa de las plantas en las hileras del cultivo, además de la información espectral, puede ser un atributo clave para distinguir las plantas de las malezas (Torres, *et al.* 2013). Por ende, una planta localizada fuera de la hilera del cultivo, se asumirá como una maleza, por lo que partiendo de esta premisa, será posible: 1) la discriminación de la vegetación (cultivo y maleza) del suelo utilizando la información espectral, y 2) la discriminación de las malezas de las hileras de cultivo utilizando la metodología de análisis de imágenes orientada a objetos.

## 3. Materiales y Métodos

### 3.1 Metodología

En el esquema de la Figura 3-1 se presenta los procesos metodológicos llevados a cabo para alcanzar los objetivos propuestos en la investigación. La metodología se planeó partiendo de la conceptualización en torno a la utilización de los sensores remotos, la respuesta espectral y las técnicas de procesamiento implementadas internacionalmente para discriminar vegetación y particularmente para discriminar malezas y parches de malezas en cultivos.

**Figura 3-1:** Flujograma general de trabajo para el desarrollo de la investigación



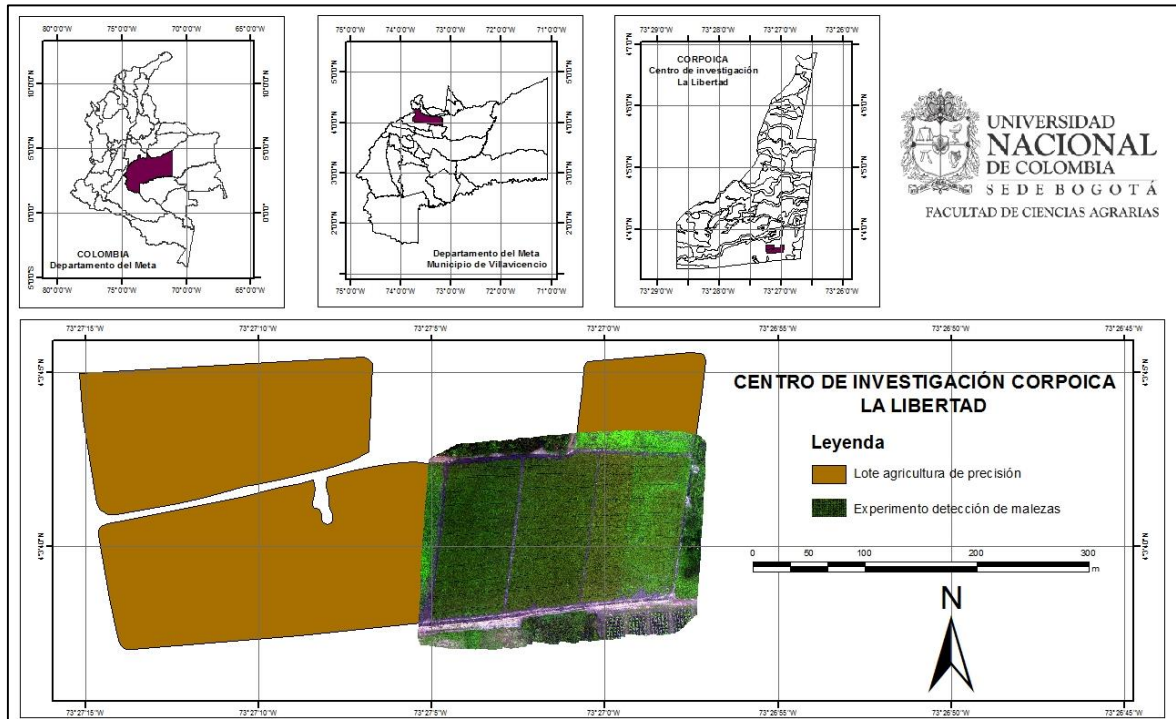
## 3.2 Localización y área de estudio

El área de estudio se ubica en el piedemonte depositacional del departamento del Meta específicamente en el plano de la terraza alta del abanico-terrace del municipio de Villavicencio, con suelos descritos por el IGAC (2004) y Corpoica (1973), como parte de la Consociación La Libertad, y que pertenecen al taxón Typic Hapludox Franco Fino Isohipertérmico.

El lote seleccionado está localizado en el Centro de Investigación La Libertad (área representativa del piedemonte llanero, franja paralela a la cordillera Oriental); ubicado entre las coordenadas geográficas 4°03'40.07" N y 73°27'05.07" W a 328 msnm, con una extensión de 3.97 ha, tal como se ilustra en la Figura 3-1

Las terrazas medias y altas del piedemonte depositacional son regularmente utilizadas en cultivos permanentes (palma, caucho y frutales) y transitorios (arroz, maíz, sorgo y soya).

**Figura 3-2:** Localización del área de estudio (sistema de coordenadas geográficas: WGS84).



### 3.3 Registro de datos agronómicos

El cultivo de soya objeto de estudio fue sembrado en el mes de septiembre del año 2016, en surcos distanciados a 0.36 m. Se estableció con una densidad de población de 300.000 plantas ha<sup>-1</sup>, con semilla certificada inoculada con la cepa de *Rizobium* ICA-J01. Las malezas identificadas dentro del cultivo fueron: caminadora *Rottboellia cochinchinensis* (Lour.) Clayton, guarda rocío *Digitaria sanguinalis* (L.) Scop, chilinchili *Senna tora* (L.) Roxb., batatilla *Ipomoea sp* (L.) y bledo *Amarantus sp*.

Para la identificación fenológica de estadios de crecimiento del cultivo se usó la escala BBCH para soya (Munger *et al.*, 1997). De acuerdo con esta escala las imágenes fueron tomadas cuando el cultivo se encontraba en los estados principales de desarrollo: 11 desarrollo del primer par de hojas verdaderas en el primer nudo (vuelos realizados a dos

alturas 30 y 60 m, en el mes de septiembre de 2016); y estado de desarrollo 61, 10% de floración en el tallo principal (vuelos realizados a dos alturas 30 y 60 m, en el mes de octubre de 2016).

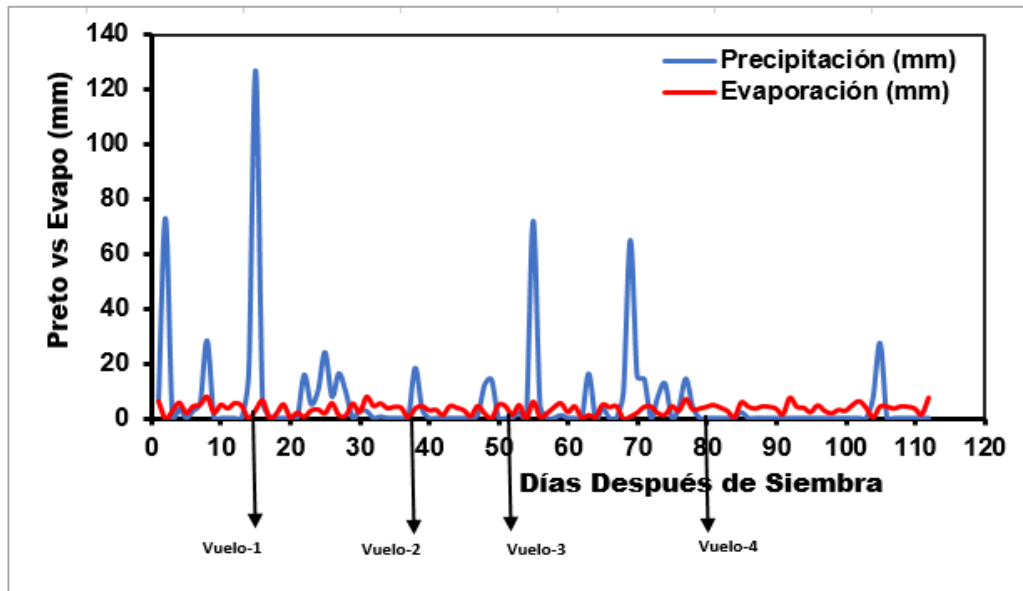
El cultivo de soya es considerado un cultivo planófilo, con movimientos heliotrópicos que dejan las hojas más perpendiculares para la radiación electromagnética (REM) en las primeras horas de la mañana y al final de la tarde; sus hojas tienden a distribuirse predominantemente en posición horizontal (menos de 35° respecto a la horizontal); permitiendo que se aumente su reflectancia (Breunig, 2011).

Durante el periodo de toma de las imágenes, fueron realizados dos manejos químicos de malezas en el cultivo, uno en preemergencia con una mezcla de 0.5 litros ha<sup>-1</sup> de Sencor + 2.0 litros ha<sup>-1</sup> de Dual, para control de malezas de hoja ancha y angosta. Cuando el cultivo se encontraba en estado de desarrollo 12 (hoja trifoliar desplegada en el 2do nudo, escala BBCH) se realizó una aplicación en post emergencia de 1.2 litros ha<sup>-1</sup> del herbicida Select para el control de la maleza caminadora la cual se encontraba con 4 hojas verdaderas (estado 14, escala BBCH).

El cultivo y las malezas contaron con un balance hídrico climático adecuado; las lluvias se mostraron bien distribuidas, aunque la evaporación superó la precipitación por cortos periodos durante el periodo de crecimiento y desarrollo del cultivo (Figura 3-3).



**Figura 3-3** Condiciones agrometeorológicas durante el ciclo de desarrollo del cultivo y días de realización de vuelos. Estación meteorológica C.I. La libertad, 2016



### 3.4 Toma de las imágenes

Para esta investigación se efectuó la revisión de literatura en aspectos básicos y avanzados de plataformas, cámaras y programas de procesamiento, enfocados en la geomática y en la agricultura de precisión.

El proceso de definición del protocolo para la toma de las imágenes para la discriminación de malezas comprendió dos fases: primera fase, exploratoria para evaluar el efecto de la altura de vuelo sobre la resolución espacial y la cobertura de las imágenes obtenidas con una Cámara Canon SX260HS modificada (GBN) y una cámara multispectral (MicaSense RedEdge), acoplada en una plataforma multirrotor (RPAS).

Para el desarrollo del protocolo metodológico se decidió continuar solo con la cámara multispectral MicaSense por su versatilidad en entregar imágenes por separado de cada una de las bandas y registro en el Exif de cada fotografía de información necesaria para las correcciones de ajuste de la imagen, que no la generaba la cámara Canon SX260HS. Con esto se garantizaba la obtención de ortomosaicos con mayor calidad espectral.

Para el desarrollo del protocolo metodológico se tomaron imágenes con la cámara Micasense conectada al multirrotor, a dos alturas de vuelo (30 m y 60 m) con un traslape longitudinal y transversal del 75%. Estas dos alturas determinaron la escala de trabajo de 1:100 para las imágenes tomadas a 30 m y de 1:200 para las imágenes tomadas a 60 m de altura, valor máximo en el que los objetos no presentaron distorsión visual. Los vuelos se efectuaron entre las 10 y 11 de la mañana, y en la tarde entre las 2 y 3 pm.

### **3.4.1 Descripción de la plataforma**

Se utilizó una plataforma multirrotor-RPAS equipada con un controlador de vuelo Pixhawk, para realizar una navegación autónoma con un sistema de posicionamiento global (GPS) y sistema de medición inercial (IMU), construido con seis motores sin escobillas accionados por dos baterías de LiPo, con una capacidad de carga paga menor a un kilogramo (Figura 3-4).

El sistema de carga (*Gimbal*) es giro-estabilizado y controlado por servomecanismos para mantener los sensores paralelos al suelo, independientes de la posición del vuelo, lo que garantiza la verticalidad de la toma de las imágenes. El hexacóptero equipado con dos baterías y la cámara, tiene una autonomía de vuelo de quince minutos al nivel del mar.

El sistema comprende: el vehículo aéreo, una estación de control terrestre (GCS) con el programa para realizar el plan de vuelo, un radio control, un sistema de datos de vuelo y de telemetría.

El programa *Mission Planner* (programa gratuito de código abierto) fue utilizado para configurar la trayectoria, con un módulo editor del plan y el seguimiento de los datos de vuelo. Además, el módulo de telemetría registró los datos y almacenó la información en un texto plano que incluía el nivel de carga de la batería, información de GPS, altitud, potencia del motor, duración del vuelo, y mensajes de la cámara.

**Figura 3-4:** RPAS equipado con el sensor multiespectral, baterías y gps, sobrevolando el cultivo de soya



De acuerdo con la Circular reglamentaria N° 002 (2015) de la Aeronáutica Civil de Colombia, se requirió de la participación de tres personas para asegurar el uso de la plataforma (RPAS): un piloto responsable del radiocontrol, un operador de la estación de tierra y un observador RPAS. El piloto con el radio control despegó, activó el plan de vuelo y aterrizó la aeronave en forma manual. El operador de la estación en tierra verificó durante todo el vuelo la información suministrada por el sistema de telemetría que Incluyó la posición de la aeronave, altura y velocidad de vuelo, el nivel de carga de la batería y la calidad de la señal del radio control, además de la velocidad del viento. El observador se encargó de prevenir al piloto de posibles colisiones con otras aeronaves u objetos durante la trayectoria del vuelo.

### **3.4.2 Descripción de los sensores**

La cámara multiespectral MicaSense RedEdge™ toma información en 5 bandas o espectros (rojo-R, verde-G, azul-B, borde rojo-RE e infrarrojo cercano-NIR). Fue creada

para su uso en sistemas RPAS, con un diseño de lectura global con obturador para obtener imágenes sin distorsión y un GPS incorporado, con fibra óptica de banda estrecha que suministra imágenes de alta resolución para cada banda, captura datos de la superficie en forma simultánea, en las cinco bandas espectrales discretas señaladas, con velocidad de captura rápida que permite adquirir imágenes a altas velocidades de vuelo y bajas altitudes; está calibrada para medidas precisas y repetibles. Las características de las cámaras Canon y MicaSense se describen en la tabla 3-1.

**Tabla 3-1** Características de los sensores utilizados en el estudio

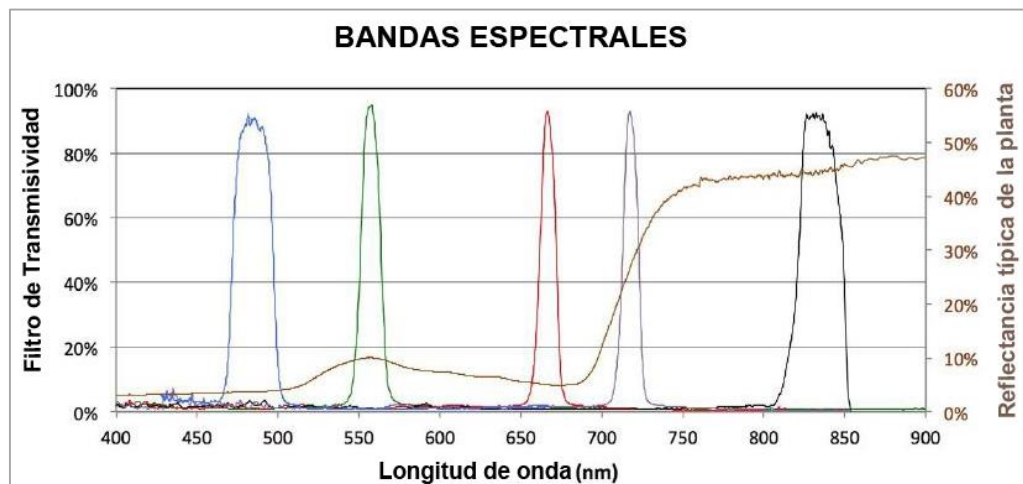
<b>Característica</b>	<b>Canon SX260HS</b>	<b>MicaSense RedEdge</b>
Longitud focal de las lentes	4.5 mm	5.5 mm
Campo de visión de las lentes	71.5 deg. HFOV	47.2 deg. HFOV
Tamaño de la imagen	6.2 mm x 4.6 mm	4.8 mm x 3.6 mm
Resolución de la imagen	4000 x 3000 pixeles	1280 x 960 pixeles
Formato de archivos admitido	JPG	RAW 12-bit DNG o 16-bit TIFF

Una de las características de la cámara MicaSense es que el ancho de banda en la región del rojo y el borde rojo es estrecha, lo que permite detectar variaciones pequeñas de reflectancia en estas bandas que pueden ser enmascaradas con sensores con bandas amplias (Granados, 2011).

Las imágenes obtenidas con la cámara MicaSense corresponden a franjas del espectro electromagnético que guardan relación con los sensores montados en plataformas satelitales Landsat TM (BGR, NIR) y RapidEye (BGR, NIR, RedEdge). Las especificaciones de las bandas de este sensor, se presentan en la tabla 3-2 y la localización y amplitud de cada banda en la figura 3-5.

**Tabla 3-2.** Longitud de onda y ancho de banda, para la cámara MicaSense.

Número de banda	Nombre de banda	Centro longitud de onda (nm)	Ancho de banda FWHM (nm)
1	Azul ( <i>Blue</i> )	475	20
2	Verde ( <i>Green</i> )	560	20
3	Rojo ( <i>red</i> )	668	10
4	Infrarrojo cercano ( <i>Near IR</i> )	840	40
5	Borde rojo ( <i>Red Edge</i> )	717	10

**Figura 3-5:** localización y amplitud de las cinco bandas espectrales de la cámara MicaSense, respecto a la firma espectral de la vegetación

### 3.5 Procesamiento de imágenes y construcción del ortomosaico


El procesamiento de las imágenes para generar el ortomosaico, con corrección geométrica y radiométrica, se realizó con el programa Pix4Dmapper Pro®. En tres etapas y cada etapa, realizando un determinado número de pasos.

#### 3.5.1 Corrección geométrica y radiométrica.

En el lote experimental se distribuyeron en forma homogénea quince puntos de control (GCP), los cuales fueron posicionados con una estación de referencia Topcon NET-G3 (Figura 3-6). Para realizar el pos procesamiento de los GCPs se identificó una estación base del IGAC (VIVI) localizada en el municipio de Villavicencio a 5 km del área de

trabajo. Una vez localizada la estación se realizó la descarga de los datos RINEX correspondientes al día de la georeferenciación de los GCPs y se realizó el pos proceso con el programa Topcon Tools con el fin de garantizar precisión centimétrica a los GCP. Sobre cada uno de los puntos de control se ubicaron cuadros de tela impermeabilizada color blanco y negro de 1 m x 1 m, con el fin de que pudieran ser visualizadas en las imágenes.

**Figura 3-6** Mapa ubicación del área de estudio, Lote 53, C.I. la Libertad, con puntos de control (círculos blancos) y marcos de monitoreo (Cuadros negros). Imagen tomada con la cámara MicaSense a 60 m de altura en la etapa fenológica 61.



Un panel de calibración suministrado por el fabricante de la cámara MicaSense RedEdge fue utilizado para realizar la corrección radiométrica. Antes de iniciar el vuelo se tomó una imagen al panel de calibración cuidando de no generar sombra sobre el panel. Solo si las condiciones de luminosidad variaban durante el vuelo se tomaba nuevamente una imagen al panel de calibración (Figura 3-7).



**Figura 3-7** Fotografía tomada a 1.5 m de altura a uno de los marcos de monitoreo, marco construido en pvc (foto izquierda). Panel de reflectancia (foto centro) y punto de control (derecha).



Los valores de reflectancia calibrados para cada banda (Tabla 3-3) fueron ingresados en el programa de Pix4Dmapper Pro® para obtener los ortomosaicos de reflectancia para cada una de las bandas.

El panel de calibración radiométrica (superficie lambertiana) permitió convertir los números digitales de las imágenes a valores de reflectividad, tomando en consideración la iluminación y características del sensor; para este procedimiento el programa utiliza la siguiente ecuación:

$$\text{Reflectancia} = \text{Imagen} / (\text{Sensor} * \text{Iluminación}).$$

Los valores de reflectancia de cada una de las bandas fueron usados para calcular los índices de vegetación evaluados en este estudio

Para realizar el proceso de clasificación de la cobertura en el ortomosaico y validar la viabilidad del método, se ubicaron 21 marcos de 1 m x 1 m, los cuales se distribuyeron al azar en el campo antes de cada vuelo (Figura 3-7). A los cuadros se les registró su posición geográfica con un colector GPS de mano Trimble Juno 3D, y se le tomó una imagen RGB (foto) a una altura de 1.50 m. La fotografía registrada en el sitio se utilizó para ajustar los rangos de reflectividad para separar el cultivo de soya, del parche de malezas y el suelo

Para la corrección radiométrica se utilizó el panel de calibración suministrado por el fabricante de la cámara MicaSense RedEdge, con valores de reflectancia calibrados para cada banda (Tabla 3-3).

**Tabla: 3-3:** Valores del panel de reflectividad MicaSense, para corrección radiométrica

<b>Banda</b>	<b>Promedio</b>	<b>Centro</b>	<b>Mínimo</b>	<b>Máximo</b>
Azul	0.71	0.71	0.7058	0.7119
Verde	0.72	0.73	0.7224	0.7223
Rojo	0.72	0.72	0.7172	0.7262
Borde rojo	0.71	0.71	0.7061	0.7117
Infra Rojo Cercano NIR	0.65	0.65	0.6326	0.6658

### 3.5.2 Índices de vegetación

Para cuantificar la cobertura del cultivo y de las malezas, así como los píxeles de suelo, se seleccionaron siete índices de vegetación. Esos índices de vegetación fueron seleccionados por su habilidad para clasificar el suelo la vegetación y parches de malezas según los resultados reportados por otros investigadores (Tabla 3-4).



**Tabla 3-4:** Índices de vegetación evaluados para clasificar la vegetación y la maleza

Índice	Relación entre bandas	Referencia
"Normal Difference Vegetation Index"	$NDVI = \frac{NIR - R}{NIR + R}$	(Rouse <i>et al.</i> 1974)
"Green Normal Difference Vegetation Index"	$GNDVI = \frac{NIR - G}{NIR + G}$	(Gitelson <i>et al.</i> 1979)
"Normal Difference Vegetation Index2"	$NDVI2 = \frac{RE - R}{RE + R}$	(Filella y Peñuelas, 1994)
"Soil-Adjusted Vegetation Index modifié"	$MSAVI2 = \frac{NIR - R}{NIR + R} (1 + L)$ <i>L = Factor corrección brillo del suelo</i>	(Qi <i>et al.</i> 1994 b)
"Excess Green"	$ExG = 2g - r - b$	(Woebbecke <i>et al.</i> 1995)
"Normal Difference RedEdge Index"	$NDRE = \frac{NIR - RE}{NIR + RE}$	(Barnes <i>et al.</i> 2000)
"Normalized Green-Red Difference Index"	$NGRDI = \frac{(G - R)}{(G + R)}$	(Gitelson <i>et al.</i> 2002)

### 3.5.3 Programas de procesamiento

Para el desarrollo de los objetivos de este trabajo se utilizaron los programas que se describen en la tabla 3-5.

**Tabla 3-5:** Programas y actividades desarrolladas para la clasificación de malezas y, parches de malezas en el cultivo de soya.

Programa	Procesos
<i>Mission Planner</i>	<i>Programa de código abierto. Ajuste de parámetros y planificación de los vuelos</i>
<i>Topcon Position Tools v.8.2.3</i>	<i>Posproceso de los puntos de control tomados con Net G3A Station receiver</i>
<i>Pix4Dmapper Pro, non-commercial (version 3.1.23, Pix4D SA, Lausanne, Switzerland</i>	<i>Proceso fotogramétrico y construcción de ortomosaico: Calibración de la cámara, parametrización para construcción de Ortomosaicos, construcción de DMS, correcciones geométricas y radiométricas, índices de vegetación.</i>

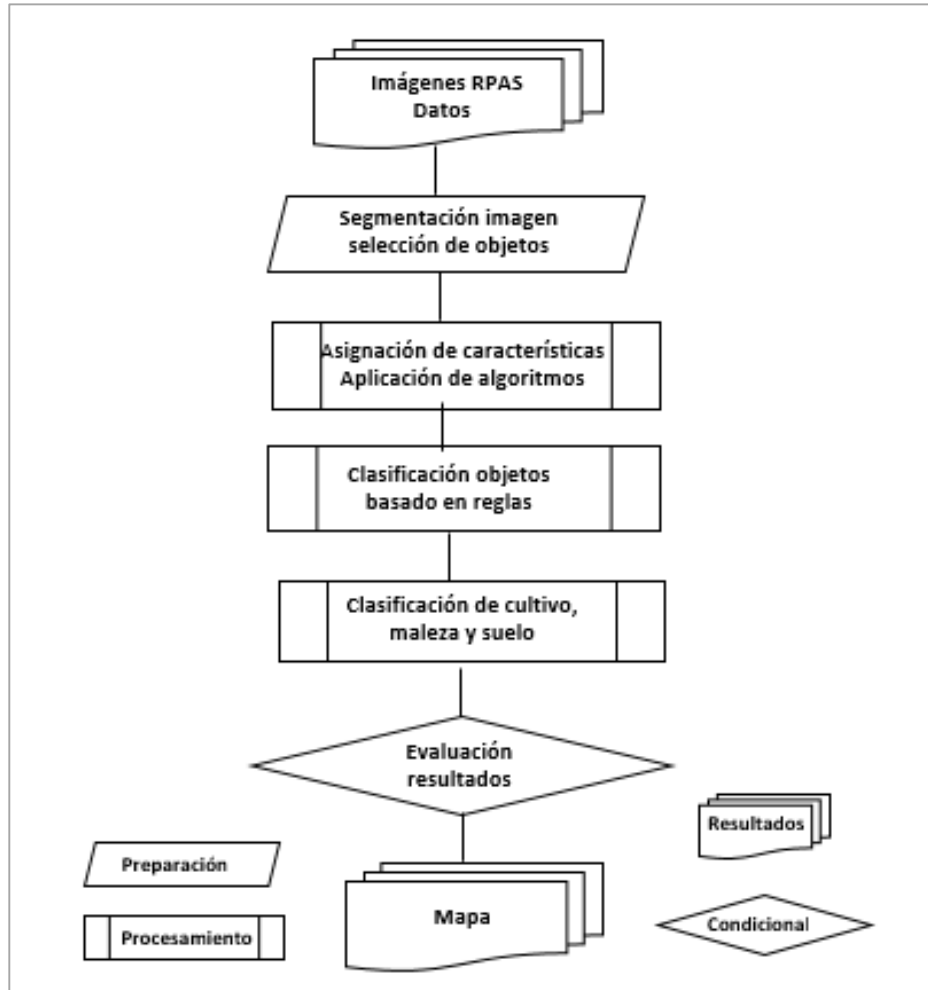
<i>PCI Geomatics Geomatica Focus V 10.0.3 11/10/2006</i>	Unión de bandas en un solo mosaico
<i>eCognition Developer 8.9 (Trimble GeoSpatial, Munich Germany)</i>	Segmentación, reglas, algoritmos, clasificación
<i>ArcGis DeskTop vers. 10.2 (ESRI, Redlands, CA, USA).</i>	Índices de vegetación, capas , edición de clasificaciones, mapas
<i>ImageJ macro (<a href="http://imagej.nih.gov/ij/">http://imagej.nih.gov/ij/</a>)</i>	Programa de código abierto. Análisis de coberturas y procesamiento de imágenes
<i>SAS (version 9.3 Institute, Cary, NC, USA).</i>	Cálculos de precisión de los marcos de evaluación o aforo en campo

### 3.6 Clasificación de las imágenes

Los ortomosaicos de alta resolución obtenidos del procesamiento fotogramétrico fueron usados en el proceso de desarrollo de la metodología OBIA, tal como se detalla en el flujograma de la Figura 3-8. Esta metodología ha sido reportada en diferentes artículos relacionados con la discriminación de malezas en cultivos semestrales (Kelly, 2012; Castillejo-González *et al.* 2014; Perez-Ortíz, M. *et al.* 2015; López-Granados *et al.* 2016; Tamouridou *et al.* 2016).

En el desarrollo de esta metodología se utilizó el programa eCognition Developer®. El algoritmo de conjunto de reglas combina varias características contextuales, jerárquicas y basadas en objetos donde se tiene en cuenta su valor espectral y espacial.

**Figura 3-8:** Flujograma para la clasificación orientada a objetos para discriminar malezas y parches de malezas en el cultivo de soya.



### 3.7 Validación del protocolo metodológico

Para la evaluación del protocolo metodológico se utilizó el procedimiento reportado por Torres-Sánchez *et al.* (2014) para evaluar la precisión de la fracción de la vegetación (FV) estimada con diferentes índices de vegetación.

La exactitud de la fracción vegetal estimada (FVE) con los índices de vegetación después del proceso de clasificación fue comparada con los valores registrados en los cuadros de monitoreo (FVO) utilizando la ecuación:

$$\text{Precisión (\%)} = 100 - |FVO - FVE| \quad (\text{Torres-Sánchez et al. 2014}).$$

$$FV = \frac{\text{Píxeles clasificados como vegetación en marco de evaluación}}{\text{Total píxeles en marco evaluación}} \times 100$$


Las imágenes obtenidas de los marcos de monitoreo fueron ingresadas al programa ImageJ donde se realizó el procedimiento de substracción del suelo ("*Subtract Background*"), ajuste del brillo para realzar la vegetación; también se realizó la binarización de la imagen y se realizó el análisis de la cobertura de cada fracción (número píxeles de maleza y soya), en cada uno de los cuadros de evaluación o control tomados en campo. Los datos obtenidos con este procedimiento fueron procesados con el programa estadístico SAS (ver 9.3).

## 4. Resultados y Discusión

### 4.1 Ajuste de la plataforma RPAS para la adquisición de imágenes digitales

El proceso inicial de ajuste consistió en la elaboración del plan de vuelo con el programa Mission Planner (versión 1.3.48) para cada una de las alturas objeto de estudio (15 m, 30 m, 45 m y 60 m). El procedimiento inicial consistió en ingresar en el menú de plan de vuelo el polígono del área de estudio (Figura 4-1), luego se seleccionó el procedimiento puntos de recorrido automático (“Auto Wp”) en donde se generaron los puntos de recorrido (“waypoints”), las líneas de vuelo, y los sitios de toma de las imágenes (Figura 4-2).

**Figura 4-1:** Polígono del área de estudio para la programación del plan de vuelo.



Una vez generadas las líneas de vuelo se ingresaron los parámetros de cada una de las cámaras (Tabla 4-1) requeridas por el programa, se definió un traslape longitudinal de

60% y lateral de 50% para la cámara Canon, y para la cámara MicaSense (valor sugerido en el manual de la cámara MicaSense, 2015). Posteriormente se seleccionó una velocidad de vuelo de  $5 \text{ m s}^{-1}$  para tomas de imágenes de 1 segundo para las diferentes alturas.

**Figura 4-2:** Generación de las líneas de vuelo y, sitios de toma de las imágenes



**Tabla 4-1:** Parámetros ajustados por el programa *Mission Planner* para la realización del plan de vuelo

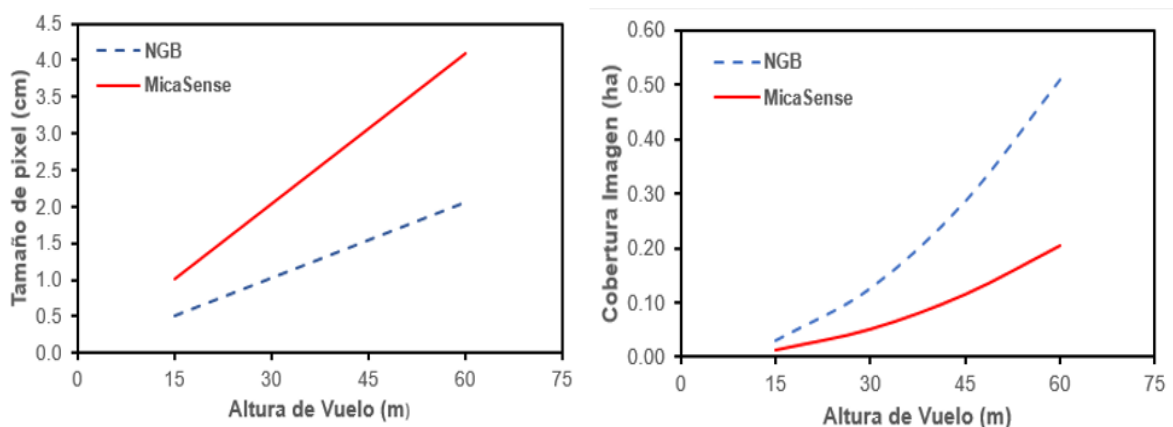
Información	Canon SX260HS	MicaSense Rededge
<b>Cámara</b>		
Longitud Focal (mm)	4.5	5.5
Ancho Imagen (píxeles)	4000	1280
Alto Imagen (píxeles)	3000	960
Ancho Sensor (mm)	6.17	4.8
Alto Sensor (mm)	4.55	3.6
Tiempo obturación (s)	1	1
<b>Area de vuelo</b>		
Traslapo longitudinal (%)	60	60
Traslapo transversal (%)	50	50
<b>Multirotor</b>		
Altura de vuelo (m)	15, 30, 45, 60	15, 30, 45, 60
Velocidad de vuelo ( $\text{m s}^{-1}$ )	5	5

Esta información se integró a la plataforma para dar inicio al plan de vuelo. Después de

realizada la programación, el piloto despegó el multirrotor en modo manual con ayuda del radio controlador y encendió la ruta de vuelo automático ordenando a la aeronave a seguir los puntos de recorrido. Al finalizar el recorrido las imágenes fueron descargadas en el programa Pix4D en donde se realizó el procesamiento inicial del ortomosaico y se estimaron los tamaños de pixeles y coberturas de las imágenes adquiridas por los dos sensores en las 4 alturas de vuelo

La resolución espacial y el área cubierta por cada imagen se vieron afectadas por la altura de vuelo de la plataforma y el tipo de cámara. El tamaño de pixel fue directamente proporcional a la altura de vuelo. La cámara Canon SX260HS (NGB) adquirió imágenes con tamaños de pixel entre 0.51 cm a 2.06 cm; mientras que la cámara multiespectral tomó imágenes con tamaños de pixel de 1.02 cm a 4.09 cm en alturas de vuelo entre 15 y 60 m, respectivamente (Figura 4-3). En estas alturas, el área de cobertura en cada imagen del sensor NGB se incrementó desde 0.03 ha hasta 0.51 ha, mientras que en la cámara multiespectral fluctuó entre 0.01 ha a 0.21 ha, respectivamente. Las diferencias entre los dos tipos de imágenes fueron ocasionadas por las especificaciones técnicas de las cámaras (Tabla 4-1). La longitud focal de la cámara y el tamaño del sensor afectaron el tamaño del pixel y el área cubierta por cada imagen.

**Figura 4-3:** Efecto de la altura de vuelo sobre la resolución espacial (imagen izquierda) y sobre el área cubierta (imagen derecha)



Resultados similares fueron reportados por Torres-Sánchez *et al.* (2013) quienes estudiaron el efecto de tres alturas de vuelo (30 m, 60 m y 100 m) y la resolución de dos cámaras (RGB y multiespectral) sobre la distancia mínima de muestreo y el área de

cobertura de imágenes adquiridas con una plataforma multirrotor. De acuerdo con Metternicht (2007) la mayoría de estudios exitosos en la detección de malezas con sensoramiento remoto utilizaron imágenes de alta resolución (< 5 m) en las regiones del espectro del VNIR.

Gómez-Candón *et al.* (2014) en un estudio realizado para discriminar malezas en un cultivo de trigo encontraron que la altura de vuelo determinaba la resolución espacial de la imagen y el número de imágenes por hectárea. Por otra parte, Torres, *et al.* (2013) requirieron de un tamaño de pixel entre 1 a 4 cm para discriminar malezas en un cultivo de girasol, resoluciones logradas con una altura de vuelo de 27 m a 105 m con una cámara RGB y de 19 m a 74 m en el caso de la cámara multiespectral Tetracam mini-MCA-6.

Para la determinación del tamaño óptimo del pixel requerido para la discriminación de malezas en estados iniciales de crecimiento se consideró, como ya se dijo, el tamaño del parche de malezas, la distancia entre surcos y el follaje del cultivo de soya. Las malezas en estados de desarrollo tempranos (3-6 hojas) son muy pequeñas, por lo que Hengl (2006) estableció que para discriminar las malezas era necesario tener mínimo 4 píxeles, para detectar los objetos más pequeños, y como mínimo 2 píxeles eran necesarios para detectar objetos angostos, coincidentes con los estudios reportados por Zhang y Kovacs, (2012); López, (2011); Xiang y Tian (2011).

Por lo anterior, las alturas de vuelo de 30 m y 60 m fueron consideradas apropiadas para lograr con el sensor multiespectral MicaSense distancias de muestreo (GSD) entre 2 cm y 4 cm, respectivamente.

## **4.2 Adquisición de imágenes.**


En la toma de las imágenes se trabajó con un traslapo longitudinal y lateral del 75% siguiendo el programa de configuración de la cámara para lograr imágenes de alta resolución. Darwin *et al.* (2014), indicaron que las fotografías aéreas tomadas con los RPAS deberían tener como mínimo un traslapo frontal del 60% y lateral del 30% para garantizar ortomosaicos de alta calidad. Mesas-Carrascosa *et al.* (2017) encontraron que



traslapos de 70% longitudinal y 40% transversal generaban ortomosaicos de alta calidad para discriminar malezas con una cámara multiespectral.

Para sobrevolar el área de estudio de 3.97 ha a una altura de 30 m con la cámara MicaSense y traslapos de 75% el programa Mission Planner estimó que se requería de un tiempo de vuelo de 25 minutos, lo cual excedía el tiempo de duración de las baterías, por lo que fue necesario realizar dos vuelos (Figura 4-4).

**Figura 4-4:** Líneas de vuelo y puntos de ruta. Para el vuelo de 30 m de altura fue necesario realizar 2 vuelos.

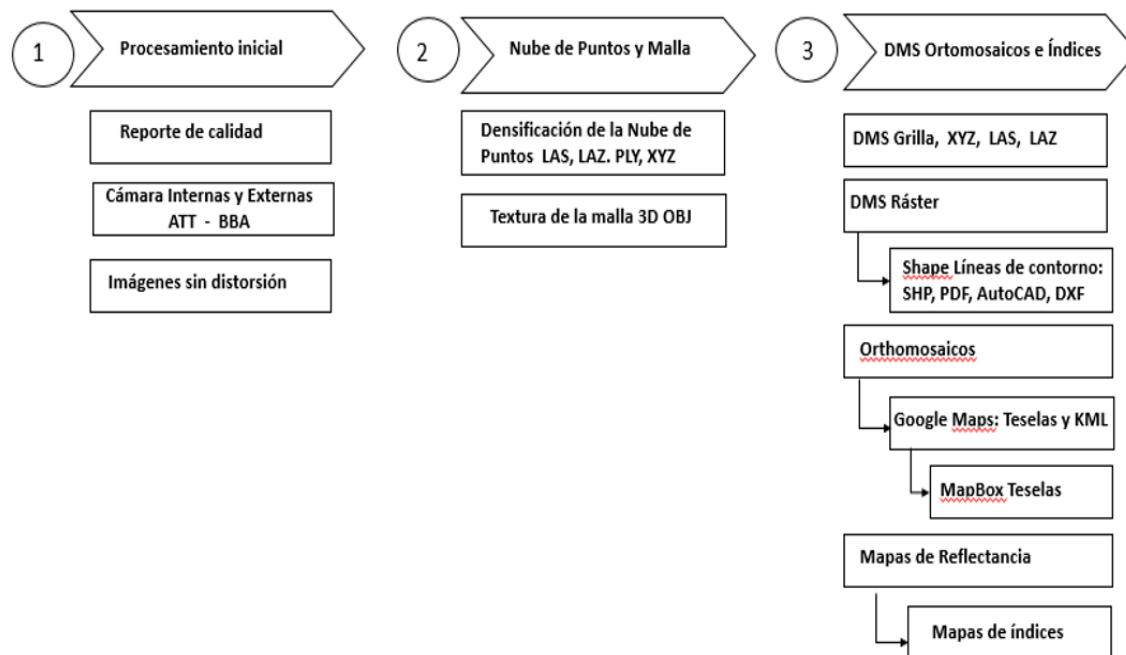


Considerando las alturas de vuelo y traslapos señalados, se tomaron 1134 imágenes de tamaño de 26.2 m x 19.6 m para cada uno de los sensores de la cámara MicaSense, para un total de 5670 fotogramas. Para la altura de 60 m, se realizó un único vuelo con una duración de 13.0 minutos y cada sensor de la cámara registro un total de 575 imágenes con una cobertura por imagen de 52.4 m x 39.3 m. En cada imagen adquirida se registra (en el EXIF) la información de la sensibilidad del sensor, el viñeteado, el ruido ocasionado al sensor por la corriente oscura (*“dark current”*), el tiempo de apertura/exposición y el posicionamiento de la imagen, la cual se almacenó en formato RAW.

El proceso fotogramétrico fue realizado por separado utilizando el programa

Pix4Dmapper Pro® (“*processed with pix4dmapper Pro by Pix4D*”) en 3 etapas, calibración de las imágenes individuales y triangulación aérea, generación de la nube de puntos y malla y construcción del Modelo Digital de Superficie, para finalmente obtener el ortomosaico de reflectancia para cada una de las bandas (Figura 4-5).

**Figura 4-5:** Flujograma usado en el programa Pix4D para la generación de ortomosaicos



Durante el proceso de triangulación aérea se realizó la alineación de las imágenes utilizando el método de apareamiento (“*matching*”), y la ubicación geográfica de las imágenes. Para la identificación de píxeles comunes en pares de imágenes se utilizó el algoritmo SIFT (*Scale Invariant Feature Transform*), el cual identifica características en cada imagen que son invariantes en la resolución, la rotación y los cambios en las condiciones de iluminación. De esta manera, los puntos de interés son identificados automáticamente en todas las localizaciones en cada imagen (Lowe, 2004).

Las estadísticas de correlación de imágenes se emplearon para identificar píxeles comunes en un conjunto de imágenes, píxeles que pasan a denominarse puntos de interés. En fotogrametría, los puntos de interés se usan principalmente en aplicaciones de orientación de imágenes o reconstrucción 3D. La eficacia de un detector se establece

en función de la precisión con que identifica el punto, su estabilidad frente a transformaciones geométricas, e invariancia frente a cambios de iluminación y contraste (Remondino, 2006).

En la reconstrucción de la escena 3D el programa Pix4Dmapper utilizó el método de ajuste de bloque (Nissen *et al.* 2014). Durante esta etapa se calcularon los parámetros de posición de la cámara, orientación y posición relativa con la utilización de los puntos de apareamiento en dos o más fotografías. En el proceso de calibración se optimizaron los parámetros internos y externos de la cámara (Tabla 4-2). Los ángulos Omega, Phi y Kappa se utilizaron para girar el sistema de coordenadas geodésicas (X, Y, Z) y alinearlo con el sistema de coordenadas de la imagen. La etapa de optimización consistió en ejecutar los pasos de Auto-Calibración Automática de la Triangulación Aérea (AAT), Ajuste del Bloque de Bloqueo (BBA) y autocalibración de la cámara en varias etapas, hasta lograr una reconstrucción óptima. Para este procedimiento se escogió el método de calibración “Alternativo” para imágenes nadir aéreo con geolocalización precisa y bajo contenido de textura y para terrenos relativamente planos.

**Tabla 4.2:** Vuelo realizado en el mes de septiembre a 30 m de altura. Parámetros de calibración externos de la cámara

Parámetro	X (m)	Y (m)	Z (m)	Omega (grados)	Phi (grados)	Kappa (grados)
Promedio	0.082	0.094	0.212	0.603	0.313	0.137
Desviación estándar	0.029	0.024	0.101	0.286	0.14	0.049

La orientación interna (OI) busca reconstruir los haces de luz que convergen en el centro de la imagen; esta orientación se compone de la distancia focal ( $f$ ) y los puntos principales de la imagen ( $X_p$  y  $Y_p$ ). Por otra parte, la orientación externa (OE), busca posicionar correctamente los haces de luz de la imagen, respecto a un sistema de referencia en el terreno. Los parámetros de esta orientación son: los centros ópticos de la posición espacial de la cámara (X, Y y Z) y la orientación espacial del plano focal de la imagen (Omega, Phi y Kappa) (Wolf y Dewitt, 2000).

En el proceso inicial se ingresaron las coordenadas de los puntos de control con

precisión centimétrica obtenida después del posprocesamiento (Tabla 4-3). En promedio el error alcanzado en los puntos de control fue de 1.3 cm en X y 2.6 cm en Y, valores bastante aceptables como lo reporta Wolf y Dewitt, (2000)


**Tabla 4-3:** Puntos de Control Posprocesados Proyección: MAGNA CENTRAL, Datum: WGS84

Nombre	dN (m)	dE (m)	dHt (m)	Horz RMS (m)	Vert RMS (m)
P1-VIVI	1406.578	-14851	68.487	0.008	0.016
P2-VIVI	1407.425	-14956.38	69.059	0.019	0.055
P3-VIVI	1464.07	-14950.36	68.843	0.008	0.025
P4-VIVI	1531.381	-14940.26	68.617	0.013	0.025
P5-VIVI	1541.893	-14840.35	68.428	0.013	0.024
P6-VIVI	1553.821	-14726.24	67.888	0.012	0.024
P7-VIVI	1491.522	-14733.24	67.250	0.013	0.022
P8-VIVI	1414.769	-14741.28	67.691	0.010	0.017
P9-VIVI	1408.797	-14832.94	68.166	0.014	0.024
P10-VIVI	1544.942	-14815.57	68.270	0.019	0.029
P11-VIVI	1442.555	-14804.72	67.994	0.019	0.027
P12-VIVI	1517.976	-14794.68	67.881	0.012	0.023
P13-VIVI	1503.694	-14863.67	68.803	0.016	0.028
P14-VIVI	1471.105	-14868.14	68.386	0.017	0.031
P15-VIVI	1432.853	-14872.64	68.392	0.016	0.031

Horz = horizontal, Vert = vertical, dN = dirección Norte dE = dirección Este dHt = altura

En la segunda fase se generó la nube de puntos y la malla texturizada. La georreferenciación de la nube de puntos se realizó por medio de los puntos de control que fueron identificados en al menos cinco imágenes (Figura 4-6)

**Figura 4-6:** Nube de puntos (generación de cientos de puntos), puntos de control y de chequeo (GCP y ChP), sobre el área de estudio.



la raíz del error cuadrático medio (RSME) obtenida en los puntos de control en el vuelo de septiembre 29 a 30 m de altura, fue de 0.13 cm en X, 0.11 cm en Y y de 0.3 cm en Z (Tabla 4-4). En el vuelo de 60 m de altura los RSME obtenidos en los puntos de control, fueron de 8.4 cm en X, 8.4 cm en Y y de 13.2 cm en Z (Tabla 4-5). Los resultados indicaron que el RSME se incrementó con la altura de vuelo. Resultados similares fueron reportados por Jacobsen (2011). Mesas-Carrascosa *et al.* (2017) reportaron disminuciones de los RSME en los vuelos con UAV realizados en alturas de 60 m y 90 m.

**Tabla 4-4:** Precisión de localización de los GCP y errores medios en las tres coordenadas en el vuelo de 30 m de altura, estado de desarrollo del cultivo 11

Nombre de GCP	Precisión en X/Y/Z (m)	Error X (m)	Error Y (m)	Error Z (m)	Proyección del Error (pixel)	Marca / Verificada
8 (3D)	0.008/ 0.016	-0.000	0.000	-0.001	0.023	20/20
10 (3D)	0.008/ 0.016	0.002	-0.002	-0.004	0.113	25/25
Promedio Sigma (m)		0.000847	-0.000747	-0.002675		
Desviación standard (m)		0.000971	0.000805	0.001324		
RMS Error		0.001288	0.001098	0.002984		

**Tabla 4-5:** Precisión de localización por los GCP y errores medios en las tres coordenadas en el vuelo de 60 m de altura, estado de desarrollo del cultivo 11

Nombre de GCP	Precisión en X/Y/Z (m)	Error X (m)	Error Y (m)	Error Z (m)	Proyección del Error (pixel)	Verificada /Marca
1 (3D)	0.008/ 0.016	-0.18	0.016	-0.040	0.281	25/25
5 (3D)	0.008/ 0.016	-0.132	0.023	-0.074	0.229	35/35
6 (3D)	0.008/ 0.016	-0.114	-0.004	-0.301	0.195	15/15
7 (3D)	0.008/ 0.016	0.068	-0.001	0.147	0.272	14/14
8 (3D)	0.008/ 0.016	0.011	0.003	0.041	0.335	19/19
9 (3D)	0.008/ 0.016	0.018	0.004	0.018	0.319	26/26
10 (3D)	0.008/ 0.016	0.114	-0.043	0.004	0.21	36/36
Promedio Sigma (m)		-0.007461	-0.007461	-0.029245		
Desviación standard (m)		0.083321	0.083321	0.128471		
RMS Error		0.083655	0.083655	0.131757		

Los Ortomosaicos generados después del procedimiento para los vuelos realizados a 30 m y 60 m de altura, en el estado de desarrollo 11 de la soya, presentaron un RSME de 0.001 m y 0.077 m, respectivamente. Los Ortomosaicos generados en el estado de desarrollo 6 de la soya, en el mes de octubre a 30 m y 60 m de altura alcanzaron RSME de 0.002 m y 0.062 m, respectivamente. Los resultados alcanzados después de la corrección geométrica fueron apropiados al considerar lo reportado por Laliberte *et al.* (2010) quienes indicaron que en fotografía aérea, un RSME de 1 pixel o menos es lo más adecuado, pero estos valores no son fáciles de alcanzar con imágenes adquiridas en plataformas RPAS. Por ello también indicaron que errores de 1.5 a 2.0 pixeles de la triangulación aérea serían considerados como aceptables.

A partir de la georreferenciación del proyecto, se realizó la triangulación del terreno, mediante la información 2D de todos los puntos. Se construyó el Modelo Digital de Superficie (ráster DMS) utilizando algoritmos de suavizado (como la distancia inversa). Con el ráster del DMS se obtuvieron las líneas de contorno y se construyó el Modelo Digital de Terreno (MDT). Este proceso, dio como resultado la recreación del bloque de área de estudio, en una visión 3D. Finalmente, el DSM se generó con base en los resultados de la nube de puntos y la triangulación del terreno, con una resolución de 4 cm pixel<sup>-1</sup> y una nube densa de 206.2 puntos por m<sup>3</sup>.

En el proceso de calibración radiométrica de las imágenes, el programa Pix4D utiliza un modelo polinómico de 6<sup>to</sup> orden para corregir el viñeteado, considerando la información suministrada por el panel de reflectancia. El efecto viñeteado (difuminación) en una imagen se refiere al desvanecimiento gradual del contraste espectral en puntos cercanos a la periferia, debido al bloqueo de una serie de rayos incidentes por el tamaño de la apertura de la lente. Los efectos del viñeteado se incrementaron a medida que la apertura se aumentó.

Para la conversión de los números digitales de la imagen a valores de reflectancia, el programa Pix4D (2016) utilizó la información de las características del sensor y las condiciones de iluminación prevalentes durante el vuelo. Se utilizó un panel de reflectancia para corregir los datos en las imágenes de los efectos de los cambios de condición de luz (debido a los cambios en elevación solar o nubosidad). Las imágenes digitales fueron corregidas espectralmente mediante la aplicación de una relación

empírica lineal en la cual los coeficientes de la ecuación fueron derivados del ajuste de los números digitales de los píxeles de la imagen localizados en el panel con relación a los valores del panel en tierra.

Como resultado de los procesos de corrección geométrica y radiométrica se generaron cuatro ortomosaicos de reflectancia para cada una de las 5 bandas las que fueron almacenadas con formato Tiff.


### **4.3 Índices de Vegetación.**

La reflectancia del cultivo de soya en cada una de las bandas, en el estado inicial de desarrollo (11, escala BBCH soya), fue baja con valores que fluctuaron entre 0.06 en la banda azul y 0.28 en el infrarrojo cercano, en las dos alturas de vuelo (Tabla 4-6 y 4-7). La menor reflectividad observada en las dos alturas de vuelo en la banda azul (475 nm) se explica probablemente por la absorbancia de los pigmentos foliares (clorofila y carotenos) y por la humedad a capacidad de campo del suelo en el momento de toma de la imagen.

En este estado de desarrollo del cultivo y la maleza se observó una mayor reflectancia de la banda asociada al rojo (668 nm) comparada con la verde (560 nm). Los mayores valores de reflectividad fueron presentados por las dos bandas del infrarrojo cercano (borde rojo-717 nm y NIR-840 nm). Este comportamiento espectral se debió principalmente a una mayor presencia de suelo desnudo con una baja cobertura de la vegetación (cultivo + maleza). Como se puede observar en la figura 4-7, el cultivo de soya y la maleza presentaron un bajo desarrollo del dosel lo que probablemente redujo la reflectividad de las bandas asociadas a la clorofila



**Figura 4-7:** Cobertura follaje del cultivo de soya y maleza en estado de desarrollo 11 según escala BBCH para cultivo de soya. Imagen original (Marco de monitoreo) (Izquierda) e imagen procesada con el programa ImageJ (derecha).



La cantidad de radiación reflejada por las plantas es inversamente proporcional a la radiación absorbida por los pigmentos vegetales y varía con la longitud de onda de la radiación incidente. La clorofila absorbe fuertemente la radiación en el espectro visible de 400 nm a 700 nm (Pinter *et al.* 2003; Daughtry *et al.*, 2000; Knipling, 1970) particularmente en las longitudes de onda de 430 nm (azul) y 660 nm (rojo) para la clorofila *a*, y 450 nm (azul) y 650 nm (rojo) para la clorofila *b*. En contraste la reflectancia de la planta es alta en la región del infrarrojo cercano (700 nm - 1300 nm) como resultado de los efectos de la densidad de la hoja y estructura interna de las hojas.

Como se observa en la figura 4-7 la maleza predominante es una gramínea con dos hojas completamente expandidas, en este estado de desarrollo, la maleza no representa aún un problema de competencia para el cultivo y puede ser eficientemente manejada con aplicaciones de dosis variable de herbicidas selectivos al cultivo de la soya. Sin embargo, debido al tamaño tan pequeño de la vegetación se requiere de imágenes de alta resolución espacial y espectral que permitan separar adecuadamente el suelo de la vegetación y el cultivo de la maleza.

Las malezas en estados de desarrollo tempranos (3-6 hojas) son muy pequeñas, por lo que Hengl (2006) estableció que para discriminarlas era necesario tener mínimo 4 píxeles, para detectar los objetos más pequeños, y como mínimo 2 píxeles eran necesarios para detectar objetos angostos, coincidentes con los estudios reportados por Zhang y Kovacs, (2012); López, (2011); Xiang y Tian (2011).

**Tabla 4-6:** Estadísticas centrales y de dispersión (valores de reflectividad) de las banda originales e índices de vegetación evaluados en la etapa 11 de desarrollo del cultivo, mes septiembre a una altura de vuelo de 30 m

<b>Banda</b>	<b>Promedio</b>	<b>Mínimo</b>	<b>Máximo</b>	<b>Std</b>
Azul	0.06	0.01	0.39	0.01
Verde	0.11	0.03	0.54	0.02
Rojo	0.17	0.03	0.72	0.03
Borde Rojo	0.21	0.06	0.76	0.03
Infrarrojo Cercano	0.28	0.10	0.79	0.05
NDVI	0.25	-0.16	0.88	0.12
NDVI2	0.11	-0.16	0.80	0.10
NDRE	0.15	-0.22	0.66	0.05
GNDVI	0.44	0.04	0.83	0.06
MSAVI2	0.51	-0.32	1.77	0.24
ExG	-0.03	-0.70	1.15	0.10
NGRDI	-0.20	-0.77	0.61	0.09

Std=desviación estándar

El cálculo de los índices de vegetación fue realizado con la herramienta Calculadora de Raster ("*Raster Calculator*") del programa Arcgis. La información espectral adquirida en los dos estados de desarrollo del cultivo y a las dos alturas de vuelo fue utilizada para evaluar la capacidad de los índices de vegetación para separar el suelo de la vegetación. El promedio y rangos de los valores espectrales de pixeles de los índices de vegetación se presentan en la tabla 4-6 para las imágenes tomadas a 30 m y en la tabla 4-7 para las tomadas a 60 m. Se encontró que en los índices que involucraron bandas de absorbancia (azul y roja) con bandas de reflectancia (verde, borde rojo y NIR) los valores fluctuaban entre rangos de -1 a 1, mientras que el índice GNDVI que involucra solo bandas de reflectancia su valor fluctuaba entre valores cercanos a 0 y 1 (Tablas 4-6 y 4-7).

Se realizó un mapa de clasificación de suelo y vegetación con cada uno de los índices utilizando el método de ruptura natural de Jenks (2006). El algoritmo se basa en la generación de cortes de clase que se caracterizan por agrupar mejor los valores similares y maximizar las diferencias entre clases. En la figura 4-8 se presenta el mapa de clasificación con el NDVI en donde se observó una buena separación de las fracciones de vegetación (cultivo y maleza) y el

suelo con los umbrales conformados con el algoritmo de Jenks. Resultados similares fueron encontrados para los índices MSAVI2, NDVI2, ExG y NGRDI.

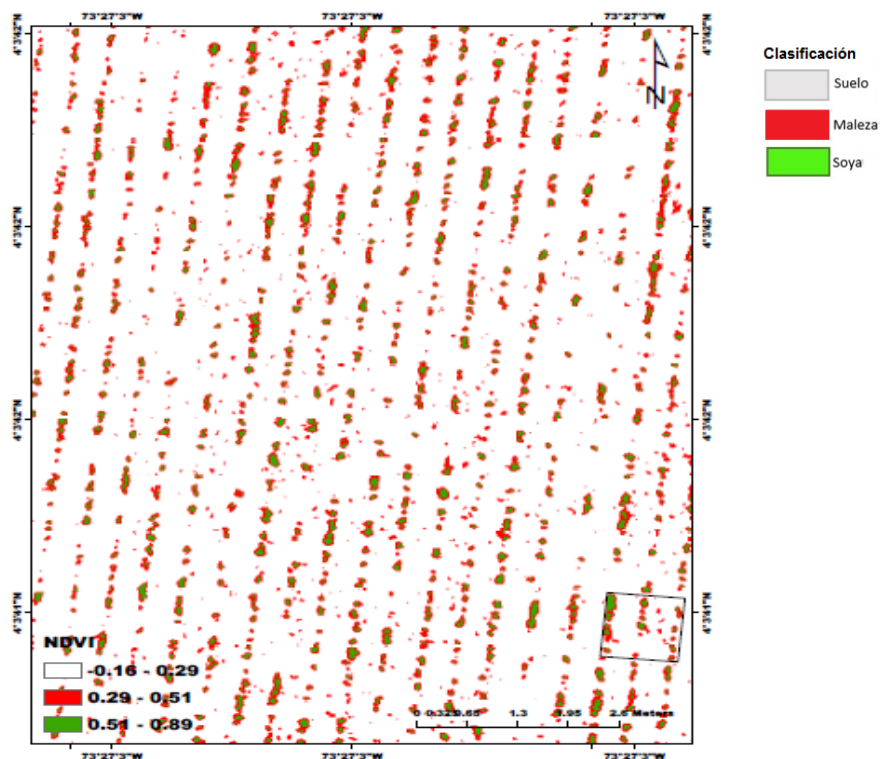
**Tabla 4-7:** Estadísticas centrales y de dispersión (valores de reflectividad) de las banda originales e índices de vegetación evaluados en la etapa 11 de desarrollo del cultivo, mes septiembre a una altura de vuelo de 60 m

<b>Banda</b>	<b>Promedio</b>	<b>Mínimo</b>	<b>Máximo</b>	<b>SD*</b>
Azul	0.06	0.01	0.19	0.02
Verde	0.12	0.02	0.38	0.03
Rojo	0.15	0.02	0.44	0.05
Borde Rojo	0.21	0.04	0.72	0.05
Infrarrojo Cercano	0.28	0.08	1.18	0.08
NDVI	0.28	-0.11	0.94	0.18
MSAVI2	0.56	-0.23	1.87	0.36
NDVI2	0.16	-0.26	0.89	0.14
NDRE	0.14	-0.29	0.84	0.09
GNDVI	0.40	-0.08	0.92	0.10
ExG	0.07	-0.55	1.50	0.14
NGRDI	-0.12	-0.63	0.78	0.13

\* SD=desviación estándar

Al comparar los índices de vegetación con el marco de monitoreo se encontró que los índices que incluyeron en su cálculo el infrarrojo cercano (borde rojo y NIR) y el rojo (NDVI, MSAVI2, NDVI2) y los que se determinaron con las bandas del visible (ExG y NGRDI) fueron los que mejor discriminaron la cobertura vegetal de la del suelo desnudo (Figura 4-9). Los índices NDRE y GNDVI presentaron una sobrestimación de la cobertura de malezas.

Figura 4-8: Mapa cobertura del cultivo de soya, maleza y suelo generado con la aplicación del algoritmo de Ruptura Natural al ortomosaico de NDVI a 30 m.




Torres-Sánchez *et al.* (2013) encontraron, en un estudio para el manejo sitio específico de malezas a partir de imágenes tomadas con una cámara multispectral Tetracam mini-MCA-6 sobre plataformas RPAs, que el NDVI permitía separar apropiadamente la vegetación (cultivo de girasol y maleza) y el suelo. Castillejo-González *et al.* (2014) reportaron exactitudes superiores al 89% en la discriminación de la vegetación, parches de avena silvestre en estados tardíos de crecimiento y trigo, y el suelo con la utilización del NDVI generado de imágenes Quick Bird con resolución espacial de 2.4 m y radiométrica de 11 bits.

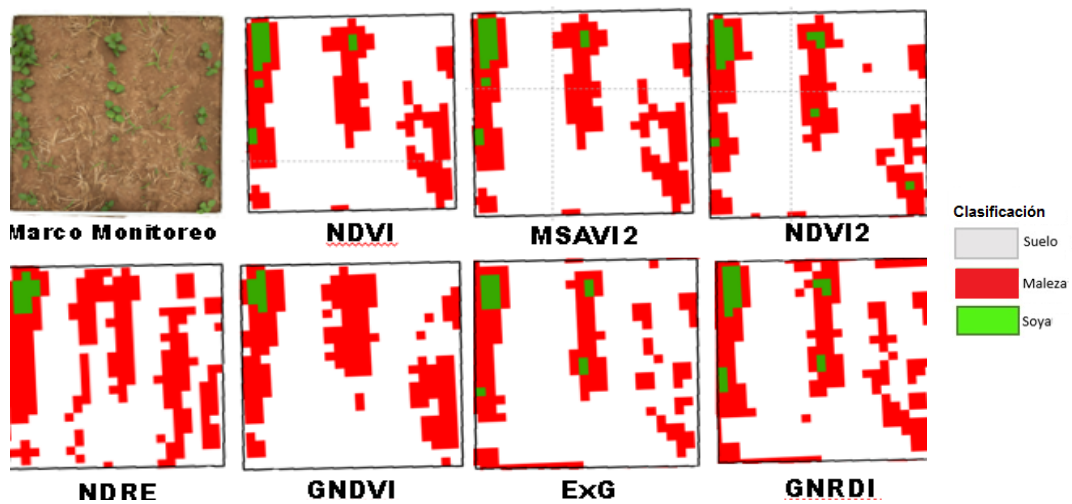
La banda del borde rojo y el rojo son de rango estrecho en la cámara MicaSense por lo que permite una mejor expresión del contenido de clorofila de la planta en estados tempranos de desarrollo. Dado que la banda del borde rojo es sensible al contenido de clorofila, a la estructura de la hoja y el dosel, se espera que esta banda contribuya a la caracterización de los diferentes tipos de cobertura. Schuster *et al.* (2012) probaron la banda de borde rojo en un

proyecto de clasificación de uso del suelo, donde se evaluaron 16 clases de usos de la tierra/cobertura de la tierra, incluyendo dos clases de bosques (deciduos y coníferos). Ellos encontraron que, con la banda de borde rojo, la precisión de la clasificación, en general, fue consistentemente, más alta que con otras bandas.

**Figura 4-9:** Marco de monitoreo y sus correspondientes índices de vegetación; etapa de desarrollo del cultivo 11, altura de vuelo 30 m en el mes de septiembre.



**Figura 4-9:** Marco de monitoreo y sus correspondientes índices de vegetación; etapa de desarrollo del cultivo 11, altura de vuelo 60 m en el mes de septiembre




En el estado de desarrollo del cultivo de soya (61, escala BBCH), la reflectividad del ortomosaico en las 5 bandas fue alta en las bandas del borde rojo, 0.26, y en el infrarrojo cercano 0.45 (Tabla 4-8). Este comportamiento espectral se debió a una menor reflectancia del suelo con una mayor cobertura del cultivo de soya, como se puede observar en la figura 4-10.

**Tabla 4-8:** Estadísticas centrales y de dispersión (valores de reflectividad) de las banda originales e índices de vegetación evaluados en la etapa 61 de desarrollo del cultivo, mes octubre a una altura de vuelo de 30 m

<b>Banda</b>	<b>Promedio</b>	<b>Mínimo</b>	<b>Máximo</b>	<b>SD*</b>
Azul	0.05	0.02	0.42	0.02
Verde	0.12	0.03	0.88	0.03
Rojo	0.12	0.03	0.96	0.06
Borde Rojo	0.26	0.06	1.01	0.05
Infrarrojo Cercano	0.45	0.14	1.00	0.10
NDVI	0.57	-0.25	0.91	0.2
MSAVI2	0.71	-0.32	1.14	0.24
NDVI2	0.38	-0.39	0.84	0.19
NDRE	0.27	-0.42	0.78	0.08
ExG	0.27	-0.71	1.17	0.23
NGRDI	0.03	-0.72	0.68	0.18
GNDVI	0.58	-0.04	0.92	0.10

\* SD= desviación estándar

**Figura 4-10:** Cobertura del cultivo de soya y malezas en estado de desarrollo 61 según escala BBCH para cultivo de soya. Marco de monitoreo e imagen procesada con el programa ImageJ.



En el estado principal de crecimiento 61 del cultivo de soya (10% de las flores abiertas, escala BBCH), los índices NDRE, y GNDVI sobrestimaron la cobertura vegetal. Al aplicar el índice de vegetación NDVI a la imagen adquirida a 60 m en el mes de octubre, se logró una mejor separación del suelo y la cobertura. Durante este estado de desarrollo los valores espectrales de los índices de vegetación fueron más altos. En el estado de desarrollo de floración, el cultivo se encuentra en su máxima expansión foliar y actividad fotosintética lo que conlleva a una mayor absorción de la radiación en las regiones del azul y rojo con alta reflectancia en el infrarrojo cercano.

Al incrementarse el tamaño del píxel de 1.87 cm a 3.97 cm se observó una sobre estimación de la cobertura vegetal Tabla 4-9; donde se muestra como el índice GNDVI y el NDRE, mezclan píxeles de vegetación y no separa suelo, mientras que el NDVI2 presenta una mejor separación sin saturar sus bandas, el NDVI por el contrario aunque separa bien, presenta un valor máximo de 0.93 dejando ver que el índice normalizado de vegetación se satura mucho más rápido (Figura 4-11).




**Tabla 4-9:** Estadísticas centrales y de dispersión (valores de reflectividad) de las banda originales e índices de vegetación evaluados en la etapa 61 de desarrollo del cultivo, mes octubre a una altura de vuelo de 60 m

Banda	Promedio	Mínimo	Máximo	SD*
Azul	0.07	0.02	0.042	0.02
Verde	0.17	0.04	0.57	0.04
Rojo	0.13	0.03	0.57	0.06
Borde Rojo	0.32	0.06	0.78	0.09
Infrarrojo Cercano	0.58	0.16	1.32	0.18
NDVI	0.62	-0.01	0.93	0.21
MSAVI2	0.77	-0.01	1.16	0.26
NDVI2	0.44	-0.21	0.84	0.21
NDRE	0.28	-0.28	0.81	0.09
ExG	0.42	-0.54	1.24	0.227
NGRDI	0.16	-0.63	0.69	0.21
GNDVI	0.54	-0.04	0.89	0.10

\* SD=desviación estándar

Figura 4-11: Mapa cobertura cultivo de soya, maleza y suelo generado con la aplicación del algoritmo de Ruptura Natural al ortomosaico de NDVI2 a 60 m





En los estudios realizados para discriminación de malezas en cultivos no se reporta el índice de vegetación NDVI2 donde se utiliza la región del borde rojo. Los índices más reportados en la literatura son el exceso de verde y el NDVI (Pérez-Ortiz *et al.* 2016; Peña *et al.* 2015; Torres-Sánchez *et al.* 2014 y Torres-Sánchez, 2013).

## 4.4 Clasificación de imágenes

El primer proceso del análisis orientado a objetos fue la segmentación de la imagen para lo que se dispuso de cada uno de los mosaicos ortocorregidos; fueron ingresados en el programa eCognition (ver. 8.7) donde se realizó un proceso de alistamiento de la imagen, haciendo un recorte sobre la imagen y llevándola a falso color, y se dio inicio a la creación del árbol de procesos, se definió cuales algoritmos serían los adecuados para dar inicio a la segmentación de la imagen.

Se decidió usar el algoritmo de segmentación multi-resolución. Este algoritmo es un procedimiento de optimización que minimiza la heterogeneidad promedio y produce imágenes de objetos altamente homogéneos (Torres-Sánchez *et al.* 2015), al ser es una técnica poderosa para tratar imágenes de resolución muy alta.

La segmentación es un proceso complejo, de fusión de regiones basado en el peso de las bandas espectrales y en tres parámetros (escala, color/forma y densificación) definidos por el operador. El parámetro de escala, el cual limita la heterogeneidad del objeto final, el peso color/forma, qué controla el porcentaje de aporte a la segmentación debida a la información espectral de la imagen vs la información de forma del objeto. El suavizado/compactación indica que tanto la forma del objeto tienden a ser espacialmente compacto vs espectralmente homogéneo (suavizado), pero menos compacto.

Con esta segmentación se buscó crear múltiples objetos compuestos por pixeles con características espectrales similares, además de forma y color que representaron los elementos del campo; plantas de soya y malezas (objetos de vegetación), y el suelo (suelo desnudo y residuos de cosecha).

Se inició probando las tres escalas (10, 20 y 30) más reportadas en la literatura para segmentación de la imagen adquirida en los estados iniciales de crecimiento del cultivo y

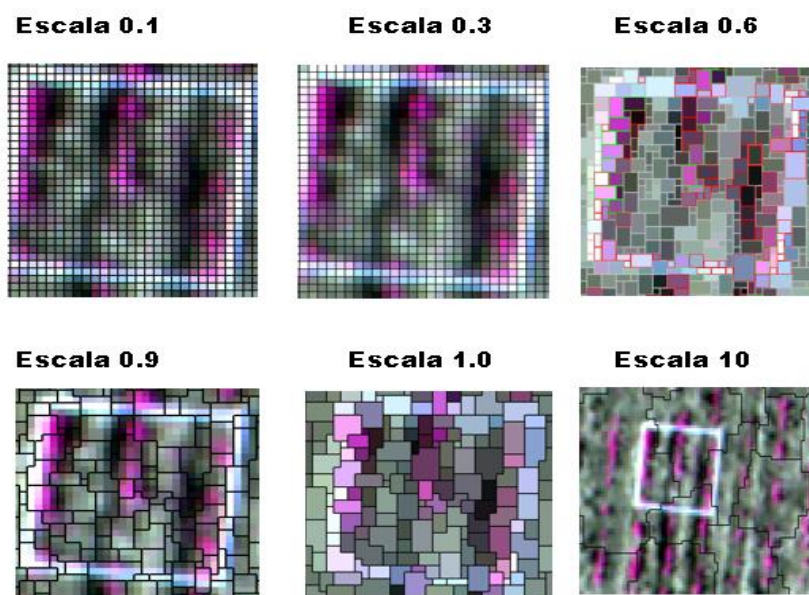
la maleza. Los resultados indicaron que a medida que se incrementaba la escala los objetos aumentaban de tamaño y se perdía sensibilidad en discriminación de parches de malezas y de cultivo.

Torres-Sánchez et al. 2015 recomendaron escalas de segmentación con imágenes provenientes de la Tetracam de 36 (331 cm<sup>2</sup>), 12 (176 cm<sup>2</sup>) y 1 (2 cm<sup>2</sup>).

Moffett y Gorelick, (2013) indicaron que el parámetro de escala presentaba un efecto fuerte en el resultado de la segmentación, mientras que los criterios de forma y compacidad tenían un efecto leve sobre el resultado final

Fue necesario probar otras escalas con valores pequeños; se evaluaron de forma visual varias salidas del proceso de segmentación (1.0, 0.9, 0.6, 0.3, 0.1), se seleccionó el parámetro de escala de 0.6 (tamaño de objetos más adecuados para estas fases tempranas de la vegetación), al igual para el criterio de homogeneidad, 0.3 y 0.5 para forma y densificación, respectivamente (Figura 4-12).

Figura 4-12: Escalas de segmentación de la imagen para definir el tamaño de objetos adecuados para discriminar malezas y cultivo.



El ajuste de los parámetros de segmentación se determinó con varios escenarios de

segmentación y analizando su habilidad para delinear con precisión los parches de malezas dentro del cultivo de soya, lo cual se logró dándole pesos diferentes a las bandas. Se le dio mayor peso a la banda borde rojo seguida por la asignación de peso que se dio a la banda del infrarrojo cercano y a la banda del rojo, estas bandas marcaban diferencias en las respuestas

Es importante resaltar que en este estudio la maleza se presentó en una distribución casi homogénea en el campo, ya que el método químico aplicado en preemergencia del cultivo y la maleza no fue el adecuado para su manejo.

Después de aplicar estos parámetros, la segmentación realizada en las imágenes, ubico objetos espacial y espectralmente homogéneos creados mediante pixeles adyacentes. La escala utilizada en esta segmentación fue adecuada pues dividió la imagen en objetos muy pequeños, mantuvo las líneas del cultivo y discrimino malezas de menos de 2 pixeles; a pesar de estar realizando este proceso de segmentación en una etapa bastante temprana de desarrollo del cultivo. Esto probablemente corresponda, a que se está trabajando con imágenes de alta resolución.

Finalizada la segmentación se evaluó la nueva imagen de objetos probando algunos índices de vegetación. Luego de hacer un reconocimiento de cómo se comportaban cada una de las bandas, se pasó a realizar la discriminación de malezas, cultivo y suelo usando el algoritmo de asignación de clases, y como criterio la clasificación supervisada se usaron los marcos de referencia ubicados en campo en cada fecha de vuelo.

Para clasificar se usaron los umbrales de asignación de clases acudiendo a los construidos con los índices de vegetación que mejor respondieron en la separación de las malezas, cultivo de soya y suelo en Arcgis (Tabla 4-10). Se usaron umbrales (rangos) de valores espectrales del índice de vegetación ExG, NDVI y NDVI2, para soya, maleza y suelo, respectivamente.

Finalizada la clasificación y con el algoritmo de “export vector layer” se construyeron tres capas una por cada fracción y se exportaron como “shapes”. Estas capas se trabajaron en el programa ArcGis con el fin de evaluar el porcentaje de maleza, soya y suelo presentes en los cuadros de referencia y verificar el grado de coincidencia entre la clasificación y el marco real

en campo, de igual forma, se verifico, con el programa ImageJ (Figuras 4-13 y 4-14).

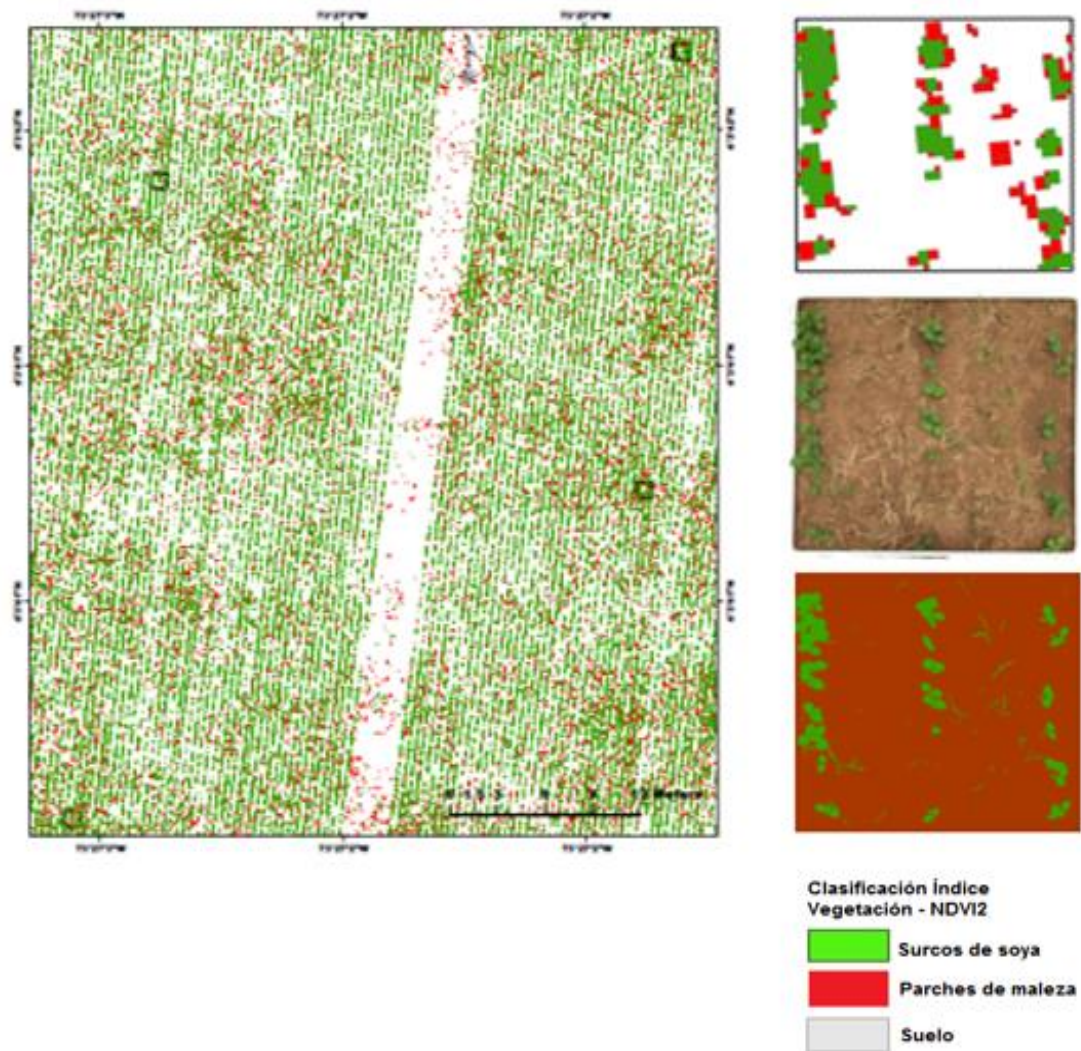
**Tabla 4-10:** Umbrales usados para los tres índices de vegetación, evaluados en los dos estados fenológicos

Fecha y Altura de Vuelo	NDVI		NDVI2		ExG	
	Suelo	Maleza	Suelo	Maleza	Suelo	Maleza
Septiembre 30 m	0.25	0.31	0.129	0.179	0.01	0.04
Septiembre 60 m	0.24	0.27	0.136	0.15	0.16	0.28
Octubre 30 m	0.508	0.579	0.308	0.355	1.099	1.509
Octubre 60 m	0.24	0.27	0.136	0.15	0.16	0.28

Esta clasificación se realizó para los dos estadios de crecimiento del cultivo 11 y 61 con las alturas de vuelos 30 m y 60 m respectivamente, los parámetros de clasificación se ajustaron de acuerdo con el estado fenológico y la altura de vuelo.

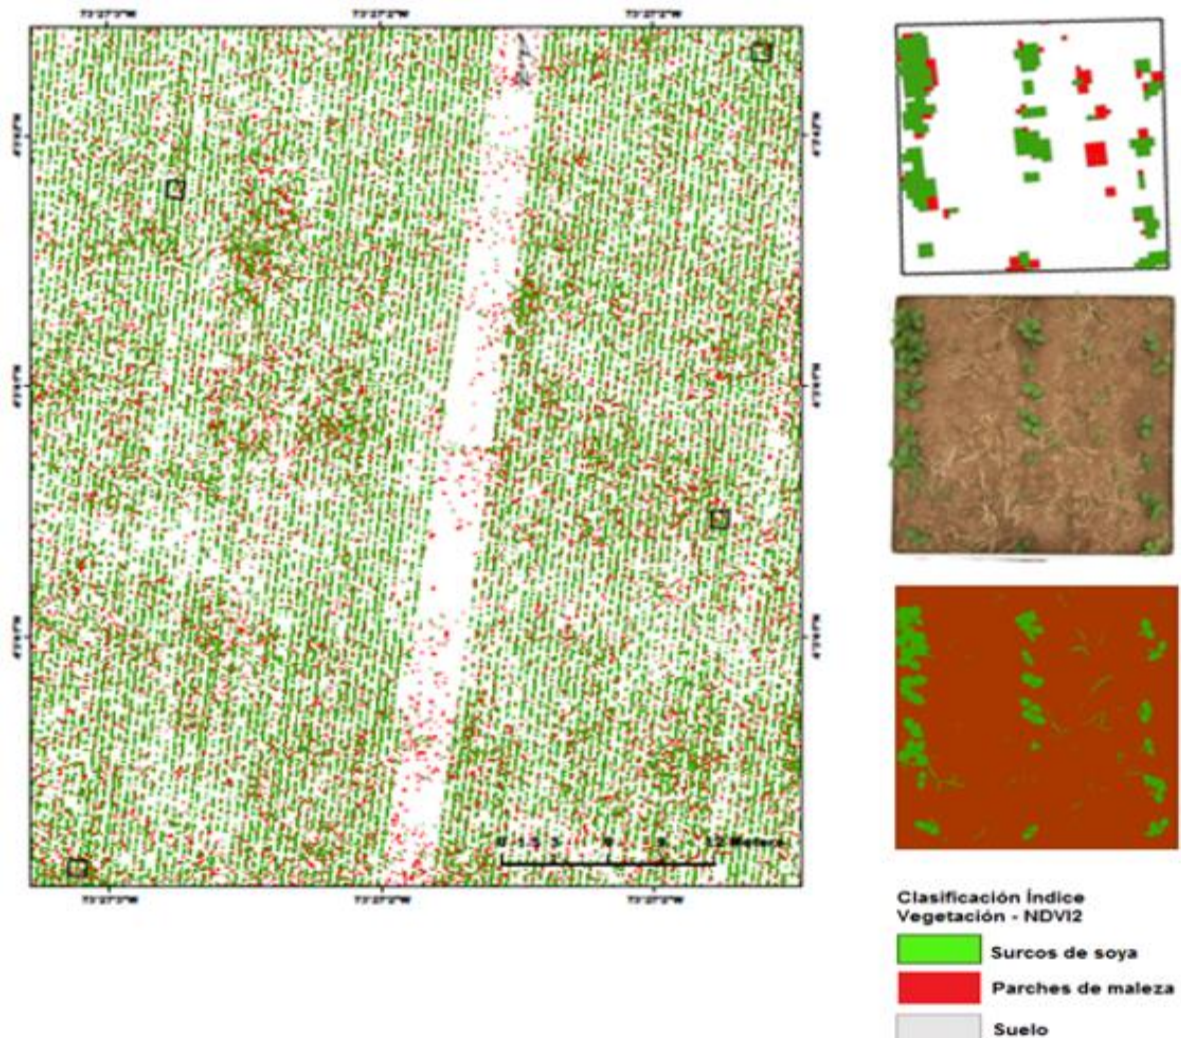
Fue importante, el estado fenológico en que se realizó la clasificación del cultivo de soya, y de la comunidad de malezas; aunque se inició con un estado muy temprano y las malezas que se encontraban en campo eran muy pequeñas (el área de sus hojas, bastante estrechas; solo gramíneas), aun así muchos de los parches lograron ser discriminados con esta metodología de clasificación orientada a objetos Figura 4-15.

**Figura 4-13:** Clasificación parches malezas (plantas de 2 hojas) Estado Desarrollo 11, ortomosaico a 30 m de altura con NDVI2. Parámetros usados en el programa eCognition parámetro de escala 0.6, forma 0.3 y compacidad 0.5

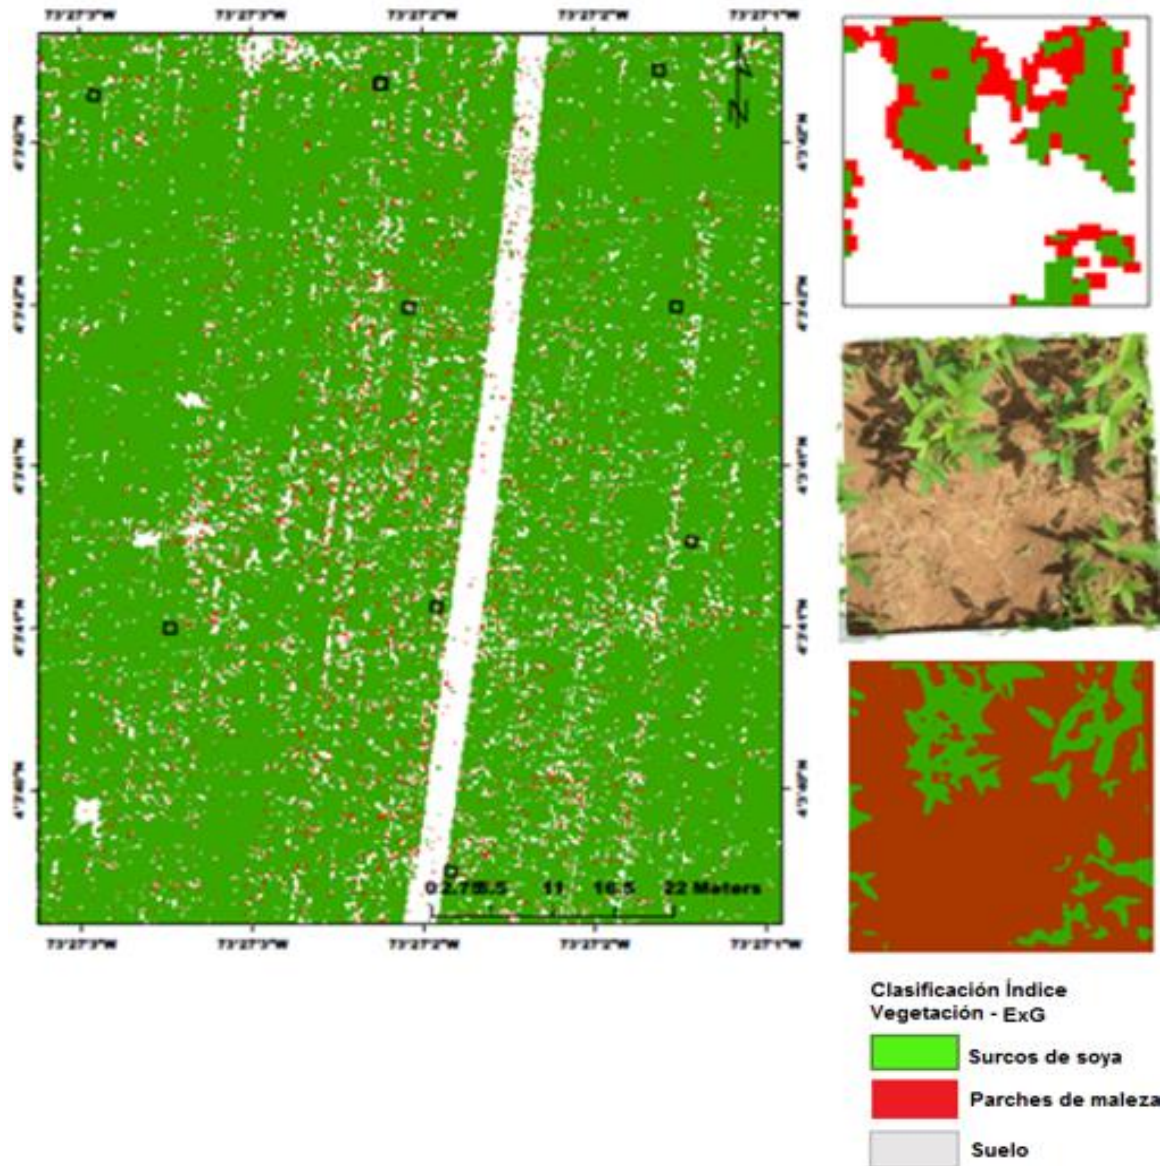




**Figura 4-14:** Clasificación parches malezas (plantas de 2 hojas) Estado Desarrollo 11, ortomosaico a 60 m de altura con NDVI2. Parámetros usados en el programa eCognition parámetro de escala 0.6, forma 0.3 y compacidad 0.5



**Figura 4-15:** Clasificación parches malezas (plantas de 2 hojas) Estado Desarrollo 61, ortomosaico a 30 m de altura. Parámetros usados en el programa eCognition parámetro de escala 0.6, forma 0.3 y compacidad 0.5



La clasificación realizada en eCognition, generó tres capas: una para suelo, una para cultivo de soya y otra para maleza, para cada uno de los índices evaluados. Finalizado el proceso de clasificación estas capas fueron exportadas al programa de arcgis donde se evaluó. Posteriormente se evalúa en SAS: el porcentaje de cobertura por cada capa y se confrontó con la evaluación cuantitativa con imageJ y marco de aforo.

## 4.5 Validación

Torres *et al.* (2014) reportaron valores de exactitud de 91.99% en la estimación de fracción de vegetación total (trigo y maleza) con imágenes tomadas a 30 m y clasificadas con el índice ExG. Este valor se redujo con la altura y en estados tardíos del cultivo.

La exactitud de la fracción vegetal estimada (FVE) con los índices de vegetación después del proceso de clasificación fue comparada con los valores registrados en los cuadros de monitoreo (FVO), Tablas 4-10 y 4-11.

**Tabla 4-11:** Valores de precisión para la fracción de cobertura de maleza, soya y total estimada con tres índices de vegetación, en dos alturas de vuelo, durante el estado de desarrollo del cultivo 11.

Índice	Altura de vuelo (m)	Maleza (%)	Soya (%)	Total (%)
NDVI	30	94.2 ± 1.3*	94.0 ± 0.7	88.2 ± 1.9
NDVI2	30	97.2 ± 1.0	96.3 ± 0.4	93.5 ± 1.3
ExG	30	97.1 ± 1.2	97.4 ± 0.4	97.5 ± 0.8
NDVI	60	88.8 ± 3.2	93.6 ± 2.4	83.4 ± 5.7
NDVI2	60	87.8 ± 2.2	87.9 ± 3.8	75.3 ± 5.4
ExG	60	95.3 ± 0.9	80.2 ± 4.4	76.0 ± 4.9
C.V. (%) 30 m		2.9	2.4	5.4
C.V. (%) 60 m		7.5	11.4	17.5


**Tabla 4-12:** Valores de precisión para la fracción de cobertura de maleza, soya y total estimada con tres índices de vegetación, en dos alturas de vuelo, durante el estado de desarrollo del cultivo 61.

Índice	Altura de vuelo (m)	Maleza (%)	Soya (%)	Total (%)
NDVI	30	89.2 ± 0.8	85.7 ± 2.9	77.2 ± 2.5
NDVI2	30	93.3 ± 0.5	83.4 ± 2.5	78.2 ± 2.5
ExG	30	90.3 ± 0.9	90.7 ± 3.8	83.0 ± 2.4
NDVI	60	94.2 ± 1.2	90.7 ± 1.7	88.5 ± 2.9
NDVI2	60	95.8 ± 1.3	87.4 ± 3.4	83.8 ± 3.8
ExG	60	87.1 ± 1.8	87.4 ± 3.3	78.6 ± 5.2
C.V. (%) 30 m		2.9	9.8	8.5
C.V. (%) 60 m		5.7	8.4	13.1



Los índices de vegetación NDVI y NDVI2 después de la clasificación para el estado de desarrollo 11 Figura 4-16

**Figura 4-16:** Clasificación parches malezas (plantas de 2 hojas) Estado Desarrollo 11, ortomosaico a 30 m de altura. Índices de vegetación NDVI (izquierda) y NDVI2 (derecha)





## 5. Conclusiones y recomendaciones

Se encontró un alto potencial en el uso de la plataforma RPAS, para discriminar parches de malezas en estado temprano de crecimiento del cultivo de soya. Con imágenes con GSD de  $1.87 \text{ cm pixel}^{-1}$  tomados con la cámara multispectral MicaSense, a 30 m de altura fue posible detectar plantas de malezas con una cobertura de  $3.87 \text{ cm}^2$  y parches de maleza de mayor tamaño fueron capturados con GSD de  $3,98 \text{ cm}^2$  en alturas de 60 m.

Los índices de vegetación NDVI2, calculados con el borde rojo, y el ExG fueron eficaces en la detección de las malezas, en los estados fisiológicos 11 y 61 (BBCH) y en la parametrización de la clasificación OBIA.

Se generó una propuesta metodológica para discriminar malezas en cultivos de soya a partir de imágenes multispectrales (MicaSense RedEdge3) adquiridas con RPAS que incluye, calibración de la plataforma, planificación de vuelo, generación de ortomosaicos, clasificación OBIA de imágenes de alta resolución.

Los tamaños de objetos obtenidos con valores de escala de 0.6, forma de 0.3 y compacidad de 0.5 se ajustaron adecuadamente al tamaño de los parches de maleza y cultivo de soya en estados iniciales de crecimiento 11.

Se generaron rutinas de procesamiento para imágenes digitales adquiridas con RPAS con uso de los programas Pix4D e eCognition.

Los resultados de la clasificación fueron validados, con datos de campo, mediante el uso del porcentaje de fracción de vegetación y mostraron una precisión superior al 80% para discriminar malezas con más de 2 hojas en estados tempranos.



## Bibliografía

Agostinetto, D., Galon, L., Piesanti, R. (2008). Weed detection in multi-spectral images of cotton fields. *Computers and Electronics in Agriculture*, 15(1), 1-14. Uruguaiana. Revista da FZVA. Brazil.

Alchanatis, V., Ridel, L., Hetzroni, A., y Yaroslavsky, L. (2005). Weed detection in multi-spectral images of cotton fields. *Computers and Electronics in Agriculture*, 47(3), 243–260. doi:10.1016/j.compag.2004.11.019

Ángel, Y. (2012). Metodología para identificar cultivos de coca mediante análisis de parámetros red edge y espectroscopia de imágenes, Tesis. Universidad Nacional de Colombia, Bogotá. 87 pp.

Bernal, J.H. Peña, A.J., Díaz, N.C., Obando, D. (2013). Condiciones Climáticas de la Altillanura Plana Colombiana en el Contexto de Cambio Climático. En: Amézquita, E., Rao, I.M., Rivera, M., Corrales, I.I., Bernal, J.H. eds. *Sistemas agropastoriles: Un enfoque integrado para el manejo sostenible de Oxisoles de los Llanos Orientales de Colombia*. CIAT, Cali, Colombia. p 14-28.

Bernal, J.H. (2006). Manejo de malezas en el cultivo de soya. Soya (*Glicine max* (L) Merrill) alternativa para los sistemas de producción de la Orinoquía Colombiana. Manual Técnico N° 09, Corpoica-Ministerio de agricultura y Desarrollo Rural-Coagro. Villavicencio, Meta. Colombia. p 173-180.

Berni, J. A. J., Zarco-Tejada, P. J., Suárez, L., Fereres, E. (2009). Thermal and narrowband multispectral remote sensing for vegetation monitoring from an unmanned aerial vehicle. *IEEE Transactions on Geoscience and Remote Sensing*, 47, 722-738.

Bhandari, A. K., Kumar, A., y Singh, G. K. (2012). Feature Extraction using Normalized Difference Vegetation Index (NDVI): A Case Study of Jabalpur City. *Procedia Technology*, 6, 612–621. doi:10.1016/j.protcy.2012.10.074

Blaschke, T. (2010). Object based image analysis for remote sensing. *ISPRS J. Photogramm.* 65, 2–16.

Blaschke, T., Lang, S., Hay, G.J. (2008). Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications. Springer-Verlag, Berlin, p. 817.

Blackburn, G. A. (2007). Hyperspectral remote sensing of plant pigments. *Journal of Experimental Botany*, 58, 855-867.

Breunig, Fabio Marcelo. (2011). Da geometria de aquisicao sobre indices de vegetacao e estimativas de IAF com dados modis, hyperion e simulacoes prosail para a soja. INPE Sao Jose dos Campos. Brazil. Pag: 252

Byun, Y. G., Han, Y. K., y Chae, T. B. (2013). A multispectral image segmentation approach for object-based image classification of high resolution satellite imagery. *KSCE Journal of Civil Engineering*, 17(2), 486–497. <http://doi.org/10.1007/s12205-013-1800-0>

Campbell, J. (2008). Introduction to Remote Sensing. Publishers The Guilford press. 4<sup>th</sup> Edition, october 18 2008, 626 pages.

Carleer, A.P., Wolff, E. (2006). Urban land cover multi-level region-based classification of VHR data by selecting relevant features. *Int. J. Remote Sens.* 27, 1035–1051.

Castillejo-González, I. L., Peña-Barragán, J. M., Jurado-Expósito, M., Mesas-Carrascosa, F. J., y López-Granados, F. (2014). Evaluation of pixel- and object-based approaches for mapping wild oat (*Avena sterilis*) weed patches in wheat fields using QuickBird imagery for site-specific management. *European Journal of Agronomy*, 59(3), 57–66. <https://doi.org/10.1016/j.eja.2014.05.009>

Chen, J., Cui, T., y Lin, C. (2014). An improved SWIR atmospheric correction model: A cross-calibration-based model. *IEEE Transactions on Geoscience and Remote Sensing*, 52(7), 3959–3967.

Chubey, M.S., Franklin, S.E., Wulder, M.A. (2006). Object-based analysis of Ikonos-2 imagery for extraction of forest inventory parameters. *Photogramm. Eng. Remote Sens.* 72, 383–394

Chunyuan, D. y Wang, Le. (2014). Development of an invasive species distribution model with fine-resolution remote sensing *International Journal of Applied Earth Observation and Geoinformation* 30 65–75.

Chuvieco, E. (2008). Earth observation of global change the role of satellite remote sensing in monitoring the global environment. (S. Department of Geography, University of Alcalá, Ed.) (p. 228). Alcala de Henares, Spain: Springer.

Chuvieco, E. y Huete, A. (2010). Fundamental of satellite remote sensing. CRC Press. Taylor and Francis Group. EE: UU. 488pp.

- Colomina, I., y Molina, P. (2014). ISPRS Journal of Photogrammetry and Remote Sensing Unmanned aerial systems for photogrammetry and remote sensing : A review. *Isprs Journal of Photogrammetry and Remote Sensing*, 92, 79–97. <https://doi.org/10.1016/j.isprsjprs.2014.02.013>
- Comar, A. (2014). Green area index from an unmanned aerial system over wheat and rapeseed crops. *Remote Sensing of Environment*, 152(September), 654–664. <https://doi.org/10.1016/j.rse.2014.06.006>
- Commission of the European Communities OPOCE (Office for Official Publications of the European Communities) © ECSC-EEC-EAEC.
- Coordination of Information on the Environment, C.L.C. (2000). CORINE Land Cover. In Area (Vol. TH-62–04–1, p. 16). Commission of the European Communities OPOCE (Office for official publications of the european communities) © ECSC-EEC-EAE.
- Da Silva J, M. C. (2010). Mapeamento da cobertura de plantas daninhas utilizando imagens digitais e geoestatística. Universidade Federal de Viçosa.
- Daughtry, C. S. T., C. L. Walthall, Kim, M. S., De Colstoun, E. B., McMurtrey III, J. E. (2000). "Estimating Corn Leaf Chlorophyll Concentration from Leaf and Canopy Reflectance." *Remote Sensing of Environment* 74: 229-239.
- De Castro Mejía, A. I. (2013). Discriminación de infestaciones de malas hierbas crucíferas en cultivos anuales de invierno utilizando imágenes de alta resolución espacial mediante métodos basados en píxeles, objetos y redes neuronales para su control de precisión. Universidad de Córdoba España.
- Dehaan, R. (2016). Evaluation of Unmanned Aerial Vehicle (UAV) -Derived imagery for the detection of Wild Radish in Wheat. <https://doi.org/10.13140/RG.2.1.1106.3925>
- Demetriades-Shah, T. H., Steven, M. D., y Clark, J. A. (1990). High resolution derivative spectra in remote sensing. *Remote Sensing of Environment*, 33, 55e-56.0
- Dille, J. A. (2014). Morphology and Critical Period of Weed Control. In S:L Young and J.F. Pierce (Eds). *Automation: the future on weed control in cropping systems* (pp. 51-69). Manhattan, USA: Springer Science +Business Media Dordrecht. [Doi:.org/10.1007/978-94-007-7512-1](https://doi.org/10.1007/978-94-007-7512-1).
- Dowman, I. J., Coyle, J., and Ward, N. (1984). Geometric Correction of airborne MSS data. NERC Contract Report G60/66/09 NERC Scientific Services, Swindon, U.K.
- Fuentes, C.L, y Romero, C.E. (1991). Una visión Del problema de las malezas en Colombia. *Agronomía Colombiana*, 8(2): 364-378.
- Gates, D. M., H. J. Keegan, Schleiter, J. C., Weidner, V. R. (1965). "Spectral Properties of Plants." *Applied Optics* 4(1): 11-20.

Gómez-Casero, M.T., Castillejo-González, I.L., García-Ferrer, A., Peña, J.M., Barragán, M., Jurado-Expósito, García-Torres, L., López-Granados, F. (2010). Spectral discrimination of wild oat and canary grass in wheat fields for less herbicide application. *Agron. Sustain. Dev.* 30. pp. 689–699

Gómez-Candón, D., Castro, A. I., y López-Granados, F. (2013). Assessing the accuracy of mosaics from unmanned aerial vehicle (UAV) imagery for precision agriculture purposes in wheat. *Precision Agriculture*, 15(1), 44–56. doi:10.1007/s11119-013-9335-4

Haboudane, D., Miller, J. R., Pattey, E., Zarco-Tejada, P. J., Strachan, I. B. (2004). Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: modeling and validation in the context of precision agriculture. *Remote Sensing of Environment*, 90, 337-352.

Hengl, T. (2006). Finding the right pixel size. *Computers & Geosciences*, 32(August), 1283–1298. <https://doi.org/10.1016/j.cageo.2005.11.008>

Hernández, H. y Orduña, J.A. (2013). Comparación de la clasificación orientada a objetos y basada en pixel para la delimitación de bosques de galería en una imagen satelital. Tesis, Universidad Nacional de Colombia. Bogotá. 94 pp.

IDEAM. (2010). Leyenda nacional de coberturas de la tierra. Metodología CORINE Land Cover adaptada para Colombia, escala 1:100.000. Instituto de hidrología, meteorología y Estudios Ambientales, In Área (Vol. TH-62-04-1, p. 16).

IGAC - CORPOICA. (1973). Reconocimiento semi detallado de suelos del Centro de Investigación “La Libertad”, departamento del Meta. *Instituto Geográfico Agustín Codazzi*, p.1-67.

IGAC - CORPOICA. (2002). Uso adecuado y conflictos de uso de las tierras en Colombia. *Subdirección de Agrología, IGAC. Subdirección de Investigación en Sistemas de Producción, CORPOICA. Bogotá, D. C. v.4, p.1-99.*

IGAC. (2005). Estudio general de suelos y zonificación de tierras del departamento del Meta. *Instituto Geográfico Agustín Codazzi. Archivo Digital.*

IGAC. (2016). Especificaciones Técnicas Cartografía Básica. CIAF - GIT Infraestructura de Datos Espaciales y Gestión de la Información Geográfica. Pag. 1-1215

Jacobsen, (2011). “Geometric Property of Large Format Digital Camera DMC II 140.” *Photogrammetrie-Fernerkundung-Geoinformation*, 2011 (2): 71–79.

Jenks, George F. (1967). "The Data Model Concept in Statistical Mapping", *International Yearbook of Cartography* 7: 186–190. *International Yearbook of Cartography* 7: 186–190.



Joshi, C., Leeuw, de J., y Duren, I. (2002). Remote sensing and GIS applications. International Institute for Geo-Information Science and Earth Observation (ITC), (Graph 1), 1–9.

Jurado-Expósito, M., López-Granados, Atenciano, F., García-Torres, S., González-Andújar, J.L. (2003). Discrimination of weed seedlings, wheat (*Triticum aestivum*) stubble and sunflower (*Helianthus annuus*) by near-infrared reflectance spectroscopy (NIRS). *Crop Protection*, (22) (19), 1177–1180.

Kelly, M. (2012). Object-Based Approach for Crop Row Characterization in UAV Images for Site-Specific Weed Management, (May 2011), 426–430.

Knezevic, S. Z. 2014. *Recent Advances in Weed Management. Recent Advances in Weed Management*. Publisher, Springer New York. Editors, Bhagirath S. Chauhan, Gulshan Mahajan. Pag. 223-237

Knipling, E.B. (1970). Physical and physiological basis for the reflectance of visible and near-infrared radiation from vegetation. *Remote Sensing of Environment*, 1(3): 155-159.

Laliberte, A. S., Rango, A., and Herrick, J. E. (2007). Unmanned Aerial Vehicle for Rangeland mapping and monitoring: A comparison of two systems, Proceedings of the ASPRS 2007. Annual Convention, 07-11 May, Tampa, Florida (American Society for Photogrammetry and remote sensing, Bethesda, Maryland).

Laliberte, A. S., Herrick, J. E., Rango, A., y Winters, C. (2010). Acquisition Orthorectification, and Object-based Classification of Unmanned Aerial Vehicle (UAV) Imager y for Rangeland Monitoring. *Photogrammetric Engineering Remote Sensing*, 76(6), 661–672. <http://doi.org/10.14358/PERS.76.6.661>

Laliberte, A. S., Browning, D. M., & Rango, A. (2012). A comparison of three feature selection methods for object-based classification of sub-decimeter resolution UltraCam-L imagery. *International Journal of Applied Earth Observation and Geoinformation*, 15, 70–78. <https://doi.org/10.1016/j.jag.2011.05.011>

Lamb, D. W., y Brown, R. B. (2001). PA-Precision Agriculture. *Journal of Agricultural Engineering Research*, 78(2), 117-125. doi:10.1006/jaer.2000.0630

Lee, W., Alchanatis, V., Yang, C., Hirafuji, M., Moshou, D., Li, C., 2010. Sensing technologies for precision specialty crop production. *Comput. Electron. Agric.* 74, 2–33.

López-granados, F. (2013). Uso de Vehículos Aéreos no tripulados (UAV) para la evaluación de la producción agraria. *Ambienta, Agricultura de Precisión*, 40–52.

López-Granados, F., Torres-Sánchez, J., De Castro, A.I., Serrano-Pérez, A., Mesas-Carrascosa, F.J., & Peña, J.M. (2016). Object-based early monitoring of a grass weed in a grass crop using high resolution UAV imagery. *Agronomy for Sustainable Development*, 36(4), 67. <https://doi.org/10.1007/s13593-016-0405-7>

Lowe, D., (2004). Distinctive Image Features from Scale-Invariant Keypoints. *IJCV* 20(2), pp. 91–110.

Martín, I., Ruíz, B., y Gallastegui, F. (2005). Teledetección y agricultura de precisión: un ejemplo de aplicación a la cartografía de malas hierbas en cultivos de cereal. Madrid.

Mesas-Carrascosa, F.J., Clavero Rumbao, I., Torres-Sánchez, J., García-Ferrer A., Peña, J.M., López Granados, F. (2017). Accurate ortho-mosaicked six-band multispectral UAV images as affected by mission planning for precision agriculture proposes. *Intern. J. Remote Sensing*, 38(8-10), 2161-2176.

Meroni, M., L. Busetto, Colombo, R., Guanter, L., Moreno, J. Verhoef, W. (2010). Performance of Spectral Fitting Methods for vegetation fluorescence quantification." *Remote Sensing of Environment* 114: 363–374.

Metternicht, G. (2007). Geospatial technologies and the management of noxious weeds in agricultural and rangelands areas of Australia. In, 12th Congress of the Spanish Association of Remote Sensing (pp- 87-94). Mar del Plata. Argentina.

Moffett, Kevan y Gorelick, Steven. (2013). Distinguishing wetland vegetation and channel features with object-based image segmentation. *International Journal Remote Sensing*, volumen 34, issue 4. Pg,1332-1354  
<http://dx.doi.org/10.1080/01431161.2012.718463>

Moreira, M.A., 2011. *Remote Sensing Fundamentals and Applications Methodologies*. 4th Edn., Editora UFV, Vicoso, Pages: 422.

Mulla, D. J. (2013). Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosystems Engineering*, 114(4), 358–371.  
<http://doi.org/10.1016/j.biosystemseng.2012.08.009>

Ngouajio, M, Leroux, G. D., y Lemieux, C. (1999). Influence of images recording height and crop growth stage on leaf cover estimates and their performance in yield prediction models. *Crop protection*, 18(18) (pp. 501–508)

Noble, S. D., Brown, R. B., y Crowe, T. G. (2005). The Use of Spectral Properties for Weed Detection and Identification – A Review The Use of Spectral Properties for Weed Detection and Identification – A Review Reflectance properties of plants. In *CSAE/SCGR* (pp. 0–17).

Ollinger, S. V. (2011). Sources of variability in canopy reflectance and the convergent properties of plants. *The New Phytologist*, 189(2), 375–94. doi:10.1111/j.1469-8137.2010.03536.x

Peña, J., Torres-Sánchez, J., Serrano-Pérez, A., de Castro, A., y López-Granados, F. (2015). Quantifying Efficacy and Limits of Unmanned Aerial Vehicle (UAV) Technology for Weed Seedling Detection as Affected by Sensor Resolution. *Sensors*, 15(3), 5609–5626. <http://doi.org/10.3390/s150305609>

Peña-Barragán, J. M., López-Granados, F., Jurado-Expósito, M., y García-Torres, L. (2007). Mapping *Ridolfia segetum* patches in sunflower crop using remote sensing. *Weed Research*, 47(2), 164–172. <http://doi.org/10.1111/j.1365-3180.2007.00553.x>

Pérez-Ortiz, M., Peña, J. M., Gutiérrez, P. A., Torres-Sánchez, J., Hervás-Martínez, C., López-Granados, F. (2016). Selecting patterns and features for between- and within-crop-row weed mapping using UAV-imagery. *Expert Systems with Applications*, 47, 85–94. <https://doi.org/10.1016/j.eswa.2015.10.043>

Pinter, P. J., Jr., Hatfield, J. L., Schepers, J. S., Barnes, E. M., Moran, M. S., Daughtry, C. S. T. (2003). Remote sensing for crop management. *Photogrammetric Engineering and Remote Sensing*, 69, 647-664.

Pudelko, R., Kozyra, J., y Nieróbca, P. (2008). Identification of the intensity of weeds in maize plantations based on aerial photographs. *Zemdirbyste-Agriculture*, 95(3), 130–134.

Ramos, A. 2016. Método para estimar el contenido de Nitrógeno en cultivos de maíz. Universidad Nacional de Colombia. Tesis de maestría

Remondino, F., Barazzetti, L., Nex, F., Scaioni, M., Sarazzi, D. (2012). UAV Photogrammetry for Mapping and 3D Modelling. In: *Current Status and Future Perspectives*. ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XXXVIII, 25-31.

Rodríguez, A. F. (2011). Metodología para detectar cambios en el uso de la tierra utilizando los principios de la clasificación orientada a objetos, estudio de caso piedemonte de Villavicencio, Meta. Universidad Nacional de Colombia.

Rodríguez, Andrés; Rubiano S., Yolanda; Gutiérrez V., Albert J.; Bernal R., Jaime H.; Rodríguez H., Nubia Stella; Arguello, Orlando; Pulido C., Sandra X. (2013). Cobertura vegetal y usos del suelo de la altillanura plana de los municipios de Puerto López y Puerto Gaitán, Meta: escala 1:25.000. Villavicencio (Colombia): CORPOICA. 32 p.

Rodríguez, A. M. (2016). Stock de carbono del suelo, a escala local, en ocho sistemas de uso agrícola del piedemonte llanero. Doctorado tesis Universidad Nacional de Colombia. Sede Palmira

Ruzgienė, B., Beteska, T., Gecyte, S., Jakubauskienė, E., y Akasamitauskas, V. C. (2015). The surface modelling based on UAV photogrammetry and qualitative estimation. *Measurement*, 73, 619627.

Sartori, L. R., Imai, N. N., & Galo, M. de L. B. T. (2005). Utilização da resposta espectral para discriminação de plantas daninhas em áreas de plantação de café (pp. 4303–4310). Goiania, Brasil.

Schmidt, K. S. and Skidmore, A. K., (2002). Mapping saltmarsh vegetation using principal component and canonical analysis on HyMap imagery. In *Prep.: ISPRS Journal of Photogrammetry and Remote Sensing*

Shi, J., Wang, J., Xu, Y. (2011). Object-based change detection using georeferenced UABV images. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XXXVIII-1/C22, ISPRS Zurich, Workshop, 14-16 September 2011, Zurich, Switzerland

Sripada, R. P., Heiniger, R. W., White, J. G., Weisz, R. (2006). Aerial color infrared photography for determining late-season nitrogen requirements in corn. *Agronomy Journal*, 97, 1443-1451.

Streibig, J.C., Rasmussen, J., Andújar, D., et al., 2014. Sensor-based assessment of herbicide effects. *Weed Res.* 54, 223–233.

Tahar, K.N. (2013). An evaluation on different number of ground control points. In.pdf. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences-ISPRS Archive, XL-2/W2(november), 2729

Tamouridou, A. A., Alexandridis, T. K., Pantazi, X. E., Lagopodi, A. L., Kashefi, J., & Moshou, D. (2016). Evaluation of UAV imagery for mapping *Silybum marianum* weed patches. *International Journal of Remote Sensing*, (November), 1–14. <https://doi.org/10.1080/01431161.2016.1252475>

Thorp, K.R., L. R., Tian, L. F. (2004a). Performance Study of Variable-rate Herbicide Applications based on Remote Sensing imagery. *Biosystems Engineering*, 88(1), 35–47. doi:10.1016/j.biosystemseng.2004.01.012

Thorp, K.R., L. R., Tian, L. F. (2004b). A Review on Remote Sensing of Weeds in Agriculture. *Precision Agriculture*. 5(5), pp. 477–508.

Torres-Sánchez, J., Castro, A. I. De, López-Granados, F. (2016). Object-based early monitoring of a grass weed in a grass crop using high resolution UAV imagery Object-based early monitoring of a grass weed in a grass crop using high resolution UAV imagery. *Agronomy for Sustainable Development*, (January 2017). <https://doi.org/10.1007/s13593-016-0405-7>

Torres-Sánchez, J., Peña, J. M., de Castro, A. I., y López-Granados, F. (2014). Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV. *Computers and Electronics in Agriculture*, 103, 104–113. <http://doi.org/10.1016/j.compag.2014.02.009>

Van Coillie, F.M.B., Verbeke, L.P.C., De Wulf, R.R. (2007). Feature selection by genetic algorithms in object-based classification of IKONOS imagery for forest mapping in Flanders, Belgium. *Remote Sens. Environ.* 110, 476–487.

Vioix, J-B. Douzals, J-P. Truchetet, F. Assemat, L. Guillemain, J-P. (2002). Spatial and Spectral Methods for Weed Detection and Localization Fr. ed. EURASIP, 7, 679-685.

Wijesingha, J. (2016). Geometric quality assessment of UAV-borne Remote Sensing (RS) products for Precision Agriculture (PA), (401), 44.

Wolf, P.R, and B.A. Dewitt: 2000. Elements of Photogrammetry - with Applications in GIS, 3rd ed, McGraw-Hill, New York, 608 pp.

Xiang, H., y Tian, L. 2011. Method for automatic georeferencing aerial remote sensing (RS) images from an unmanned aerial vehicle (UAV) platform. Biosystems Engineering. <http://doi.org/10.1016/j.biosystemseng.2010.11.003>

Yeganehpoor, F., Salmasi, S. Z., Abedi, G., Samadiyan, F., y Beyginiya, V. 2014. Effects of cover crops and weed management on corn yield. Journal of the Saudi Society of Agricultural Sciences, 1–4. <http://doi.org/10.1016/j.jssas.2014.02.001>.

Yu, Q., Gong, P., Clinton, N., Biging, G., Kelly, M., Schirokauer, D. 2006. Object-based detailed vegetation classification with airborne high spatial resolution remote sensing imagery. Photogramm. Eng. Remote Sens. 72, 799–811.

Zarco-Tejada, P.J., J.R. Miller, D. Haboudane, N. Tremblay, S. Apostol.2003. Detection of chlorophyll fluorescence in vegetation from airborne hyperspectral CASI imagery in the red edge spectral region. IEEE International Geoscience and Remote Sensing Symposium. Proceedings (IEEE Cat. No.03CH37477)

Zhang, C., y Kovacs, J. M. 2012. The application of small unmanned aerial systems for precision agriculture: A review. Precision Agriculture, 13(6), 693–712. <http://doi.org/10.1007/s11119-012-9274-5>

Zwiggelaar, R. 1998. A review of spectral properties of plants and their potential use for crop/weed discrimination in row-crops. Crop Protection, 17(3), 189–206. doi:10.1016/S0261-2194(98)00009-X

<http://www.aerocivil.gov.co/AIS/AIC/PaginasIDAICVigentes.aspx>