IDENTIFICACIÓN DEL VOLCAMIENTO EN UN CULTIVO EXPERIMENTAL DE MAÍZ (*Zea mays* L.) A PARTIR DE IMÁGENES RGB ADQUIRIDAS CON UNA AERONAVE REMOTAMENTE TRIPULADA, EN EL DEPARTAMENTO DE CALDAS

INGRID NATALIA MAZO ZULUAGA

UNIVERSIDAD CATÓLICA DE MANIZALES
FACULTAD DE INGENIERÍA Y ARQUITECTURA
MAESTRÍA EN TELEDETECCIÓN
MANIZALES - CALDAS
2020

IDENTIFICACIÓN DEL VOLCAMIENTO EN UN CULTIVO EXPERIMENTAL DE MAÍZ (*Zea mays* L.) A PARTIR DE IMÁGENES RGB ADQUIRIDAS CON UNA AERONAVE REMOTAMENTE TRIPULADA, EN EL DEPARTAMENTO DE CALDAS

INGRID NATALIA MAZO ZULUAGA
Ingeniera Forestal

TRABAJO DE GRADO PRESENTADO COMO REQUISITO PARCIAL PARA OPTAR AL TÍTULO DE MAGÍSTER EN TELEDETECCIÓN

Tutora
GLORIA YANETH FLÓREZ YEPES
Administradora Ambiental, M.Sc., Ph.D.

UNIVERSIDAD CATÓLICA DE MANIZALES
FACULTAD DE INGENIERÍA Y ARQUITECTURA
MAESTRÍA EN TELEDETECCIÓN
MANIZALES - CALDAS
2020

A Dios, tu bendición, amor y bondad me acompañan en todo momento. Gracias Señor.

A mi mamá, Luz Estella, eres un pilar fundamental en mi vida y mi formación.

A Martín, el amor, la ternura y la alegría que irradias iluminan cada día.

Nati

AGRADECIMIENTOS

Quiero expresar mis agradecimientos a la Universidad Católica de Manizales por facilitar las imágenes que se emplearon para la ejecución de este estudio. Agradezco a mi tutora, la profesora Gloria Yaneth Flórez Yepes, MSc, Ph.D., por la revisión y aportes durante la elaboración de la tesis, igualmente al profesor Óscar Cardona Morales, MSc., Ph.D., gracias por su revisión y comentarios para mejorar el trabajo presentado. A Sarah Weber, por su apoyo e interés para que completáramos satisfactoriamente la maestría.

Infinitas gracias a mi familia por el apoyo y acompañamiento incondicionales, por la paciencia y comprensión ante las ausencias. Agradezco a Edgar Alberto Agudelo, amigo, compañero, colega, por la amistad, el apoyo y acompañamiento. De igual forma, a mis compañeros de maestría, gracias por compartir cada sesión de clases en Manizales y por los lazos de amistad forjados. Gracias a mis amigos Alejandra María Ramírez, Héctor Iván Restrepo, Carlos Alberto Gutiérrez, por su compañía y presencia, y brindarme palabras de ánimo. Y, a mis familiares y amigos que de una u otra manera me alentaron y animaron para el logro de esta meta, ¡Gracias!

CONTENIDO

Pág.

1. INTRODUCCIÓN 11
1.1 DEFINICIÓN DEL PROBLEMA 12
1.2 JUSTIFICACIÓN 14
2 OBJETIVOS 17
2.1 OBJETIVO GENERAL 17
2.2 OBJETIVOS ESPECÍFICOS 17
3 MARCO TEÓRICO 18
3.1 MAÍZ 18
3.2 VOLCAMIENTO 19
3.3 TELEDETECCIÓN Y SENSORES REMOTOS 21
3.4 ART Y AGRICULTURA DE PRECISIÓN 26
3.5 SENSORES REMOTOS Y VOLCAMIENTO 29
3.6 ANÁLISIS DE IMÁGENES 31
3.6.1 Interpretación de imágenes 31
3.6.2 Transformaciones de la imagen: Índices espectrales 32
3.6.3 Transformaciones de la imagen: Análisis de Componentes Principales (ACP) 34
3.6.4 Clasificación digital de imágenes 35
3.6.5 Verificación de resultados 38
4 MATERIALES Y MÉTODOS 41
4.1 ÁREA DE ESTUDIO 41
4.2 ADQUISICIÓN DE IMÁGENES 42
4.3 PREPROCESAMIENTO 43
4.4 INTERPRETACIÓN VISUAL 43
4.3 ÍNDICES ESPECTRALES 44
4.4 ANÁLISIS DE COMPONENTES PRINCIPALES 45
4.5 CLASIFICACIÓN Y VERIFICACIÓN DE RESULTADOS 46
5 RESULTADOS Y DISCUSIÓN 48

5.1 IMÁGENES / ORTOFOTOMOSAICOS 48
5.2 INTERPRETACIÓN VISUAL 50
5.3 MUESTRAS DE ENTRENAMIENTO Y VERIFICACIÓN 53
5.3 GENERACIÓN DE ÍNDICES ESPECTRALES 55
5.4 ANÁLISIS DE COMPONENTES PRINCIPALES 58
5.4.1 ACP de bandas espectrales RGB 58
5.4.2 ACP de índices espectrales 59
5.4.3 ACP de bandas espectrales e índices espectrales 59
5.5 CLASIFICACIÓN Y VERIFICACIÓN DE RESULTADOS 60
CONCLUSIONES 71
RECOMENDACIONES 73
BIBLIOGRAFÍA 75

LISTA DE TABLAS

Pág.

Tabla 1. Descripción de bandas en el espectro electromagnético. 23

Tabla 2. Clases de resolución espacial para sensores aerotransportados y satelitales. 25

Tabla 3. Algunas escalas de interpretación de coeficiente Kappa. 40

Tabla 4. Índices espectrales aplicados a la imagen. 44

Tabla 5. Estadísticos básicos de la imagen RGB para el 5 de noviembre. 49

Tabla 6. Área preliminar de cada clase de cobertura identificada en el cultivo de maíz para la fecha de interés. 52

Tabla 7. Cantidad de pixeles para las muestras de entrenamiento y verificación. 54

Tabla 8. Estadísticos de los índices calculados. 55

Tabla 9. Vectores y valores propios para los componentes principales de las bandas RGB. 58

Tabla 10. Vectores y valores propios para los componentes principales de los índices espectrales. 59

Tabla 11. Vectores y valores propios para los componentes principales de las bandas del espectro visible y los índices espectrales. 60

Tabla 12. Área de las diferentes categorías de coberturas en las diferentes clasificaciones efectuadas. 63

Tabla 13. Matriz de confusión para la clasificación de la imagen RGB. 63

Tabla 14. Matriz de confusión para la clasificación de componentes principales de la imagen RGB. 65

Tabla 15. Matriz de confusión para la clasificación de componentes principales de los cuatro índices espectrales calculados. 66

Tabla 16. Matriz de confusión para la clasificación de componentes principales de las tres bandas RGB y los cuatro índices espectrales empleados. 67

LISTA DE FIGURAS

Pág.

Figura 1. Diagrama esquemático de maíz con diferentes ángulos de volcamiento. 20

Figura 2. Espectro electromagnético con bandas de importancia para la teledetección. 22

Figura 3. Componentes de un sistema de teledetección. 24

Figura 4. Localización del área de estudio en la Granja Montelindo, municipio de Palestina (Caldas). 42

Figura 5. Flujo de trabajo establecido para la identificación del volcamiento de maíz a partir de imágenes RGB. 47

Figura 6. Ortoimágenes en color verdadero obtenidas para el cultivo de maíz de la granja Montelindo, segundo semestre - 2018. 48

Figura 7. Ortoimagen en color verdadero del cultivo de maíz para el 5 de noviembre del 2018. 49

Figura 8. Visualización en color verdadero (RGB) de cada categoría de cobertura. 51

Figura 9. Identificación de categoría de cobertura en la imagen RGB obtenidas por interpretación visual. 52

Figura 10. Distribución de muestras de entrenamiento y de verificación. 53

Figura 11. Características espectrales de las muestras de entrenamiento para cada categoría de cobertura. 54

Figura 12. Comportamiento de las coberturas (muestras de entrenamiento) en cada índice. 56

Figura 13. Índices espectrales obtenidos a partir de la imagen RGB. 57

Figura 14. Resultados de clasificación supervisada. 62

LISTA DE ANEXOS

Pág.

Anexo 1. Valores promedio y desviaciones estándar de las bandas RGB para cada cobertura de las muestras de entrenamiento en el ortofotomosaico obtenido. 85

Anexo 2. Valores promedio y desviaciones estándar de los índices en espectro visible calculados, para cada cobertura en las muestras de entrenamiento. 85

RESUMEN

El volcamiento del maíz es un fenómeno que afecta la calidad y productividad (rendimiento) del cultivo, su identificación a tiempo permite tomar medidas tendientes a minimizar los efectos de las pérdidas. El presente estudio tuvo como objetivo identificar el volcamiento en un cultivo de maíz en el departamento de Caldas, a partir de imágenes RGB adquiridas con una aeronave remotamente tripulada (ART), las cuales pueden ser de bajo costo, permiten altas resoluciones espaciales y temporales, además permiten la captura de imágenes en el momento deseado y/o necesario. Se realizaron doce vuelos a 60 metros de altura y se obtuvieron ortofotomosaicos con pixel de 1,6 – 1,7 cm. Los vuelos se llevaron a cabo en el período 9 de septiembre – 23 de noviembre del 2018; para analizar el maíz volcado se seleccionó la imagen correspondiente al 5 de noviembre, dado que es la primera imagen en la cual se identificó el fenómeno de volcamiento en el cultivo. Haciendo uso de técnicas de interpretación visual de imágenes, se obtuvieron muestras que permitieron extraer características para cada cobertura, se obtuvieron índices de vegetación y se generaron análisis de componentes principales, posteriormente se generaron proceso de clasificación supervisada por el método de máxima verosimilitud para: imagen RGB, índices de vegetación en el espectro visible y clasificación a partir de análisis de componentes principales, (a) para las bandas espectrales RGB y (b) para el conjunto de las bandas espectrales RGB y los índices obtenidos. Se obtuvieron imágenes clasificadas en las cuales se identifican: maíz no volcado (maíz en pie), maíz volcado, así como otras tres coberturas identificables en la imagen: sombra, suelo y malas hierbas (maleza). La exactitud de las clasificaciones se evaluó utilizando la matriz de confusión basada en muestras de verificación localizadas al azar abarcando los diferentes sectores de la imagen, se obtuvieron además los valores de exactitud global y coeficiente Kappa. Los resultados mostraron que la clasificación de la imagen RGB y su ACP tuvieron los mejores indicadores de exactitud del productor y del usuario, así como de exactitud total de la clasificación, el ACP empleando la imagen RGB y todos los índices de vegetación generados no arrojó resultados muy satisfactorios para el caso de la imagen analizada, en la cual se presentaron importantes valores de sobreestimación del maíz volcado.

PALABRAS CLAVE: maíz, volcamiento, aeronave remotamente tripulada, índices de vegetación de bandas en el espectro visible, análisis de componentes principales, clasificación de imágenes, máxima verosimilitud, matriz de confusión

1. INTRODUCCIÓN

Los avances tecnológicos que se han dado en materia de sensores remotos, permiten que en el momento se cuente con plataformas como las aeronaves remotamente tripuladas (ART), las cuales son versátiles, pueden ser de bajo costo y se pueden equipar con amplia diversidad de sensores como son cámaras RGB, multiespectrales, hiperespectrales, entre otros. Estas aeronaves, por su misma versatilidad, permiten capturar información en el momento que se requiera, proporcionan información muy detallada por las altas resoluciones que se pueden obtener, esto puede ser de gran relevancia cuando se desea desarrollar actividades en áreas pequeñas donde los sensores de imágenes satelitales podrían no ser tan convenientes.

La Universidad Católica de Manizales, a través del grupo de investigación GIDTA, ha enfocado esfuerzos en el desarrollo y aplicación de metodologías para el procesamiento de imágenes provenientes de aeronaves remotamente tripuladas para el análisis de la calidad del aire, la gestión del riesgo y la agricultura de precisión. Uno de los objetivos de la agricultura de precisión es el monitoreo continuo de las actividades agrícolas, lo cual permite mejorar las prácticas de manejo tendientes a predecir el rendimiento, evitar pérdidas y mejorar los niveles de productividad para los agricultores. Uno de los cultivos más importantes en Colombia es el de maíz (*Zea mays* L.), el cual ocupa el tercer puesto después del café y el arroz, cultivándose en condiciones altamente contrastantes de clima, altitud y precipitación, en sistemas de cultivo tradicional o tecnificado.

El maíz, como muchos otros cultivos, se encuentra expuesto a enfermedades o condiciones que afectan su productividad, una de ellas es el volcamiento, también conocido como acame, éste es un fenómeno que afecta directamente la calidad de la cosecha y en consecuencia la productividad del cultivo, los métodos tradicionales para su identificación se basaban en evaluaciones *in situ*, que pueden ser inexactas e ineficientes debido a la gran superficie que pueden cubrir los territorios agrícolas.

El seguimiento y monitoreo del cultivo de maíz es viable mediante técnicas de agricultura de precisión (AP). Es en este contexto que surge la propuesta de identificar el volcamiento de maíz, a partir de imágenes en el espectro visible adquiridas con una ART, con el fin de proporcionar información confiable al manejador del cultivo y así éste pueda actuar de forma oportuna con el fin de evitar

grandes pérdidas en la producción. El cultivo analizado en el estudio hace parte de la Granja Montelindo, en la cual se implementan diferentes programas agrícolas y pecuarios, incluyendo cultivo de maíz para investigación y producción comercial. La granja se encuentra en predios de la Universidad de Caldas en el municipio de Palestina (departamento de Caldas).

El documento se estructura de la siguiente manera, en el primer capítulo se realiza la introducción al tema que se desea tratar, y se presentan los correspondientes planteamiento del problema y justificación. El segundo capítulo presenta los objetivos planteados. En el tercer capítulo se incorpora el marco teórico, donde se presentan los fundamentos teóricos de las técnicas aplicadas. En el cuarto capítulo se relaciona el proceso metodológico seguido en la investigación. En el quinto capítulo se incorporan los resultados obtenidos y la discusión de los mismos. Finalmente se presentan las conclusiones y se plantean algunas recomendaciones.

1.1 DEFINICIÓN DEL PROBLEMA

El maíz, como muchos otros cultivos, se encuentra expuesto a enfermedades o condiciones que afectan su productividad, una de ellas es el volcamiento o acame, éste fenómeno se refiere a la inclinación o desplazamiento del tallo sobre el suelo desde la posición vertical, en este caso se denomina volcamiento del tallo (Chu et al., 2017) o puede ser una falla estructural en el sistema de anclaje de una planta al suelo, y en este caso es volcamiento de raíces (Brune et al., 2018) y debido a esto, los brotes de cereales de grano pequeño se desplazan permanentemente de su posición vertical y generalmente solo ocurre después de que ha emergido la espiga o la panícula, esta situación es importante porque las cosechadoras mecánicas no pueden recuperar los tallos quebrados o caídos del suelo (Poehlman & Sleper, 1995), esto puede reducir el rendimiento hasta en un 80% y causa varios efectos colaterales entre los que se incluyen una calidad de grano reducida, mayores costos de secado, una cosecha más lenta, aumento en los costos de producción y disminución de las ganancias de los productores (Nielsen & Colville, 1988), (García & Watson, 2003), (P. Berry et al., 2004), (P. M. Berry, 2013), (Campuzano D. et al., 2014).

En la revisión llevada a cabo por (Chauhan et al., 2019), los autores encontraron que la respuesta del rendimiento de grano al volcamiento o acamado ha sido explorada en diversos estudios, pero solo a escalas de campo o laboratorio. Los estudios analizados indican que la extensión del volcamiento, la etapa o desarrollo

del mismo (entendido como el ángulo de inclinación del cultivo) y la etapa fenológica o momento de ocurrencia, son los factores que determinan la severidad y por lo tanto la extensión de la pérdida de rendimiento.

Las estrategias tradicionales de detección del volcamiento se basan principalmente en métodos convencionales a partir de la recopilación de datos en tierra, la cual es laboriosa y subjetiva (Chu et al., 2017), el método más empleado para evaluar el fenómeno es el visual y consiste en contar el número de plantas erectas en el momento de la cosecha, y de esta forma se reconoce como un método de evaluación directa (García et al., 2001). Es probable que dichos métodos se vean limitados por una cobertura limitada, un alto consumo de mano de obra, poca accesibilidad y condiciones climáticas desfavorables, además puede ser poco confiable, ya que puede estar determinada por la habilidad y experiencia del evaluador (Chauhan et al., 2019).

Es en estos contextos que los métodos que emplean sensores remotos de alta resolución espacial y que además permiten alta resolución temporal de acuerdo con las necesidades de los usuario, como las aeronaves remotamente tripuladas (ART), pueden generar un gran aporte y garantizar un apropiado monitoreo de los recursos y así obtener mejoras en la productividad. De acuerdo con (Barbosa et al., 2019) el uso de ART tiene un potencial creciente para el monitoreo agrícola mediante la obtención de datos con técnicas de teledetección. Algunas de las ventajas que presentan estos sistemas incluyen despliegue rápido y repetido, menos costosos y más seguros que los aviones piloteados, flexibilidad en términos de altura de vuelo y tiempo de las misiones y se pueden obtener imágenes de muy alta resolución (Xiang & Tian, 2011), (Zhang & Kovacs, 2012).

Teniendo en cuenta que el volcamiento genera cambios en las características del dosel de los cultivos es posible emplear sensores remotos para evaluar dicho fenómeno dado que el volcamiento cambia la estructura y la forma de los cultivos, provocando cambios en la respuesta espectral del dosel, cuanto más grave es el volcamiento, hay más exposición del tallo y la reflectancia del tallo es mayor que la de la hoja (Sun et al., 2019). Los estudios del volcamiento se han enfocado más en cultivos de trigo, cebada, arroz y en menor medida en otros cereales (Chauhan et al., 2019). Específicamente en maíz se reportan pocos estudios para monitoreo o identificación del volcamiento (Chu et al., 2017), (Wang et al., 2018), (Acorsi et al., 2019), (Sun et al., 2019), por citar algunos, han empleado diferentes sensores (espectro visible, multiespectral o radar) y enfoques para la identificación o cuantificación del volcamiento, obteniendo resultados fiables, pero aún no existe

consenso sobre el método o la forma más apropiada para evaluar el volcamiento de cultivos, así como para producir y validar mapas del mismo.

Se plantea entonces la siguiente pregunta de investigación ¿Cómo pueden contribuir las imágenes espectrales tomadas con una aeronave remotamente tripulada en la identificación del volcamiento en un cultivo de maíz?

1.2 JUSTIFICACIÓN

El maíz (*Zea mays*) es el cereal más cultivado en el mundo, en Colombia es el tercer cultivo más importante, después del café y el arroz (CIMMYT & CIAT, 2019). En muchos países en desarrollo, el maíz es un alimento básico importante y el consumo per cápita es muy alto, se estima que un colombiano consume en promedio 30 kg de maíz al año. Los usos del maíz se agrupan principalmente en alimento para humanos, alimento para animales, forraje y para el procesamiento industrial y obtención de productos derivados. En Colombia los principales tipos de maíz que se consumen son el amarillo y el blanco.

El maíz, como muchos otros cultivos, se encuentra expuesto a enfermedades o condiciones que afectan su productividad, una de ellas es el volcamiento, del tallo (Chu et al., 2017) o de las raíces (Brune et al., 2018). El cultivo de maíz implica altos costos de producción por lo que la información precisa sobre la ubicación y extensión del daño, así como el momento en el que se presenta o evidencia el volcamiento en un cultivo, es valiosa para los agricultores y agrónomos en la medida que permitan la toma de decisiones con relación al manejo del cultivo, con el fin de minimizar las consecuentes pérdidas en la cosecha.

La pronta valoración y cuantificación de las afectaciones producidas por el volcamiento en un cultivo es importante en la medida que se podrían establecer las causas, identificar e implementar las estrategias para un mejor manejo del cultivo, así como cuantificar las potenciales pérdidas en producción. De acuerdo con (Chauhan et al., 2019) el monitoreo adecuado del volcamiento, así como su impacto y evaluación de riesgos estacionales es de gran interés e importancia para agricultores, agrónomos, ajustadores de seguros, incluso para los encargados de proponer y formular políticas.

Chauhan et al., (2019) revisaron las tendencias en los estudios de campo / laboratorio y de sensores remotos para la evaluación del volcamiento de cultivos

teniendo en cuenta las fortalezas y debilidades de los enfoques actuales. La revisión reveló que el uso de técnicas de sensores remotos en la evaluación del volcamiento de cultivos todavía está en una etapa experimental, sin embargo se evidencia un creciente interés en la comunidad científica de los sensores remotos, para la detección del volcamiento de cultivos y el mapeo de los riesgos. Los autores establecieron que los estudios existentes de evaluación del volcamiento basados en satélites son muy pocos, por lo que el mayor desafío se encuentra en la aplicación operativa de los enfoques actuales para grandes extensiones. De esta forma se identifican oportunidades para estudios que pueden desarrollar modelos cuantitativos para estimar la gravedad del volcamiento y mapear el riesgo del mismo aprovechando los datos provenientes de sensores remotos.

Las imágenes que se obtienen a partir de los ART ofrecen algunas ventajas sobre las tomadas a partir de sensores satelitales, relacionadas con mayores resoluciones espacial y temporal, lo cual facilita el monitoreo continuo de los recursos, de esta manera permite evaluar las etapas más críticas del crecimiento de un cultivo y así apoya la toma de decisiones permitiendo aplicar los tratamientos más apropiados para los diferentes problemas identificados (Ballesteros et al., 2014), (Pádua et al., 2017). Adicionalmente, existen alternativas para el análisis de imágenes obtenidas con ART, y que se encuentran en rangos de longitudes de onda del espectro visible (Rojo, Verde, Azul – RGB por su sigla en inglés), ya que no siempre se puede contar con imágenes multiespectrales que incluyan bandas en los rangos del infrarrojo o hiperespectrales.

La revisión conducida por (Chauhan et al., 2019) identifica que los estudios del volcamiento basados en sensores remotos se han enfocado mayormente en trigo y cebada, mediante el desarrollo de modelos de volcamiento y la identificación de diferentes bandas /índices/ longitudes de onda/ ángulos de incidencia sensibles al volcamiento. Por otro lado existen pocos estudios para la detección del volcamiento en otros cultivos como maíz, avena, arroz, canola y caña de azúcar.

Por lo anteriormente expuesto, el uso de los sensores remotos y en este caso particular de las aeronaves remotamente tripuladas, resulta de interés para la aplicación en un cultivo de maíz con el fin de identificar y cuantificar el fenómeno del volcamiento dadas las pérdidas que éste puede ocasionar, además porque el acceso a evaluar cada planta puede hacerse difícil dado el tamaño que éstas pueden alcanzar en cierto momento de desarrollo del cultivo (Portero et al., 2015), de esta forma tener una imagen desde una perspectiva aérea puede ser de utilidad para evaluar el cultivo y así ofrecer información adecuada y fundamental al agricultor

o manejador del cultivo, de manera eficaz y oportuna, de los sitios donde se pueden presentar dificultades o variaciones en el campo para que se establezcan acciones anticipadas de manejo.

2 OBJETIVOS

2.1 OBJETIVO GENERAL

Identificar el volcamiento en un cultivo de maíz (*Zea mays* L.) en el Departamento de Caldas a partir de imágenes en el espectro visible tomadas con una aeronave remotamente tripulada.

2.2 OBJETIVOS ESPECÍFICOS

1. Realizar una interpretación visual preliminar sobre imágenes obtenidas con una aeronave remotamente tripulada, con el fin de separar el maíz volcado del maíz en pie, empleando los criterios de brillo, color, textura, forma, patrón, tamaño, contraste, sombra, posición geográfica, sitio topográfico,.

2. Generar procesos de clasificación supervisada sobre la imagen RGB e índices espectrales, con el fin de examinar los más apropiados para distinguir el volcamiento en un cultivo de maíz en el departamento de Caldas.

3. Evaluar la exactitud de las clasificaciones obtenidas, con el fin de identificar la más conveniente para el cultivo analizado.

3 MARCO TEÓRICO

3.1 MAÍZ

El maíz (*Zea mays* L.) es el cereal más cultivado en el mundo, en el año 2018 se cosecharon unas 236 millones de hectáreas (FAOSTAT[1]), es además el tercer cultivo más importante en Colombia, después del café y el arroz (CIMMYT & CIAT, 2019). De acuerdo con (Gómez Mejía, 1986) las cualidades alimentarias del maíz se presentan por el contenido de los tres elementos fundamentales en la nutrición: proteínas, grasas y carbohidratos. De acuerdo con (FAO, 2003) debido a su distribución mundial y al precio relativamente más bajo que otros cereales, el maíz tiene más usos que cualquier otro cereal. En muchos países en desarrollo, el maíz es un alimento básico importante y el consumo per cápita es muy alto.

Los usos del maíz se agrupan principalmente en alimento para humanos, alimento para animales, forraje y para el procesamiento industrial y obtención de productos derivados. Los principales tipos de maíz que se consumen en Colombia son el amarillo y el blanco, el blanco se utiliza esencialmente para consumo humano y el amarillo se usa principalmente para consumo animal e industrial, solo una pequeña parte se destina para el consumo humano. (Cardona Alzate, 2009) manifiesta que es posible obtener biocombustibles a partir de almidón proveniente de maíz y yuca para producir alcohol carburante; según (Fenalce, 2011) se usa también como materia prima para la elaboración de biocombustibles, además en “pegantes, pañales desechables, bolsas biodegradables, antibióticos, analgésicos y otros medicamentos”.

El maíz es muy adaptable a diferentes climas (FAO, 2003) de acuerdo con (Fenalce, 2011) dada su especial adaptación a diversas condiciones agroclimáticas y socioeconómicas el maíz se encuentra en todas las regiones naturales del país; cultivándose en todo el territorio nacional incluyendo territorios en La Guajira, el Amazonas, la Costa Pacífica y los Llanos Orientales; en condiciones desde el nivel del mar hasta 3.000 metros de altitud y con precipitaciones desde menos de 300 mm/año en la Guajira, hasta 10.000 mm en el Chocó, sus siembras se realizan en dos grandes temporadas del año, coincidiendo con las épocas de lluvia de cada

[1] http://www.fao.org/faostat/es/#data/QC

semestre, por lo que se puede decir que Colombia produce maíz durante todo el año.

Dependiendo del grado de tecnificación, se tienen dos sistemas: tecnificado y tradicional. El sistema tecnificado se desarrolla generalmente en terrenos planos, se emplea sistema de mecanización y se establece en lotes superiores a 5 has, además se utiliza semilla mejorada, se aplican fertilizantes y plaguicidas químicos; los sistemas tradicionales generalmente se dan en zonas de ladera con suelos relativamente pobres y ambientes con déficit de precipitación, son lotes de minifundio y de colonización reciente, ocupando áreas inferiores a 5 has, no se hace uso de la mecanización, no se emplea semilla mejorada ni se aplican fertilizantes, y muy pocos pesticidas químicos (Quintero, 1999), (Fenalce, 2011). En Colombia, para el año 2020, los cultivos tradicionales representaron un total de 46,81% y los tecnificados el 53,19% del total de área cultivada.

Fenalce, (2019) resalta que para el año 2019 se tenían en Colombia 386.440 ha con una producción de 1.604.792 Ton representadas en cultivos de maíz en sistemas de producción tecnificado y tradicional, con rendimientos promedio de 5,78 T/ha y 2,17 respectivamente, con un promedio global de 4,15 T/ha, inferiores al promedio mundial de 5,8 Ton/ha y de 11 Ton/ha de Estados Unidos. A la par se importaron 5.812.437 Ton de maíces blanco y amarillo, con el fin de satisfacer la demanda nacional. En contraste, para el año 2020, (Fenalce, 2020) relaciona que en Colombia se tuvieron 363.628 ha con una producción de 1.439.451 Ton, con rendimientos promedio de 5,77 T/ha en sistema de producción tecnificado y 1,90 T/ha en sistema tradicional, con un promedio global de 4,07 T/ha, denotando por tanto disminución en área cultivada, así como en producción y rendimiento. Con respecto a las importaciones de maíz, en el período enero-marzo del 2020 se habían importado un total de 5.430.679 Ton.

3.2 VOLCAMIENTO

El maíz, como muchos otros cultivos se encuentra expuesto a enfermedades o condiciones que afectan su productividad, uno de ellos es el volcamiento o acame, estudios han demostrado que el volcamiento ocurre por dos mecanismos, volcamiento del tallo y volcamiento de raíces (P. M. Berry, 2013), el volcamiento de tallo se refiere a la inclinación o desplazamiento del tallo sobre el suelo desde la posición vertical, (Chu et al., 2017) el volcamiento de raíz es una falla estructural en el sistema de anclaje de una planta al suelo (Brune et al., 2018) y se define como la

deformación mecánica, de carácter irreversible que se presenta en la estructura de soporte subterráneo de una planta (Niklas, 1992), por cualquiera de los dos mecanismo los brotes de cereales de grano pequeño se desplazan permanentemente de su posición vertical y esto generalmente solo ocurre después de que ha emergido la espiga o la panícula, esto es importante porque las cosechadoras mecánicas no pueden recuperar los tallos quebrados o caídos del suelo (Poehlman & Sleper, 1995), se constituye en una de las principales causas de pérdida de rendimiento de la cosecha, hasta en un 80% y causa varios efectos colaterales entre los que se incluyen una calidad de grano reducida, mayores costos de secado y una cosecha más lenta, dificulta e incrementa los costos de producción, y disminuye las ganancias de los productores (Nielsen & Colville, 1988), (García & Watson, 2003), (P. Berry et al., 2004), (P. M. Berry, 2013), (Campuzano D. et al., 2014). En la Figura 1 se muestra un esquema de visualización del volcamiento en una planta de maíz, con diferentes ángulos de desplazamiento con respecto a la vertical.

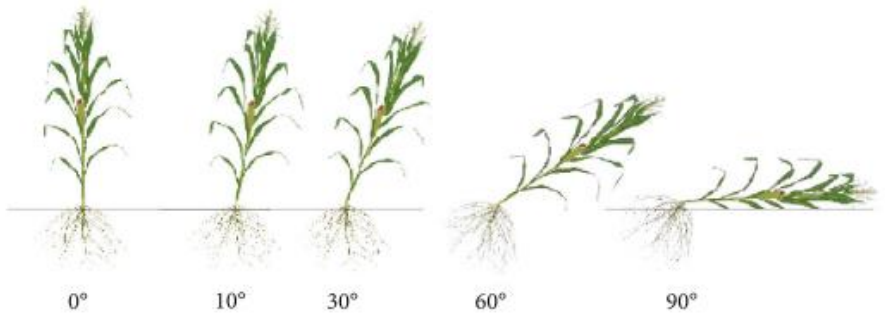

Figura 1. Diagrama esquemático de maíz con diferentes ángulos de volcamiento.
Fuente: (Sun et al., 2019).

El acame puede incidir en la aparición de otras enfermedades del maíz, como la pudrición rosada por fusarium (en la mazorca) (Fenalce, 2011). El fenómeno es difícil de controlar porque es un proceso complejo que está influenciado por muchos factores, incluidos el viento, la lluvia, la humedad, la topografía, el tipo de suelo, el cultivo anterior, el manejo del cultivo y enfermedades (P. M. Berry, 2013). Los factores que pueden causar estrés ambiental y aumentar el potencial de volcamiento en un cultivo de maíz incluyen altas poblaciones de plantas, alta humedad del suelo, deficiencias y/o desequilibrios de nutrientes, el nitrógeno, daños por insectos, enfermedades del tallo, débil anclaje de raíces, secuencia de cultivo y la susceptibilidad intrínseca de la variedad de híbrido plantado (Karthikeyan et al., 2020). Estos factores pueden aumentar la incidencia de volcamiento directa o indirectamente al influir en la cantidad de pudrición del tallo (Nielsen & Colville,

1988). En un cultivo de cereales volcado, se ha informado una disminución en la capacidad fotosintética y la producción de biomasa en varios estudios debido a la supresión en el transporte de agua y nutrientes a través del xilema y de asimilaciones fotosintéticas a través del floema (P. Berry et al., 2004).

Fenalce, (2011) refiere además que la batatilla (nombre común con el que se conocen géneros de la familia Convolulaceae), es una maleza anual de desarrollo agresivo que se puede presentar en diferentes etapas de desarrollo del cultivo (desde antes de la germinación o en forma tardía más de 30 días), los tallos envuelven completamente el cultivo, lo que ocasiona volcamiento total o parcial, esto dificulta las labores de cosecha, sea esta manual o mecanizada.

Las estrategias tradicionales de detección del volcamiento se basan principalmente en la recopilación de datos en tierra, lo cual es laborioso y subjetivo (Chu et al., 2017), el método más empleado para evaluar el volcamiento es el visual y consiste en contar el número de plantas erectas en el momento de la cosecha, y de esta forma se reconoce como un método de evaluación directa (García et al., 2001), es probable que dichos métodos se vean condicionados o restringidos por una cobertura limitada, un alto consumo de mano de obra, poca accesibilidad y condiciones climáticas desfavorables (Chauhan et al., 2019)

En (Bock et al., 2010) se presenta una revisión de las diferentes calificaciones visuales para determinar o cuantificar la severidad de una enfermedad en un cultivo. Los métodos convencionales para evaluar la severidad se basan en clasificaciones en escalas de 0 – 5, 1 – 9 o 0 – 100 donde 5, 9 o 100 se refieren a los casos en los que el cultivo en toda la parcela se encuentra totalmente afectado, en el caso del cultivo de interés sería donde todo el maíz se encuentra horizontalmente en el suelo. Dichas evaluaciones son (i) escasas y puede que no cubran todas las áreas volcadas, (ii) sesgadas y subjetivas, ya que dependen de la habilidad o la consistencia del evaluador y la complejidad del evento de alojamiento, y (iii) consumen tiempo e implican costos para su implementación (Chauhan et al., 2020).

3.3 TELEDETECCIÓN Y SENSORES REMOTOS

El desarrollo de la tecnología en las últimas décadas ha permitido la aparición de técnicas innovadoras que permiten el control y seguimiento de diferentes recursos naturales como el recurso hídrico y la cubierta vegetal, así como la clasificación y cartografía del uso del suelo y la vegetación (Govender et al., 2007), (Escribano et

al., 2008), (Casal et al., 2011), dichos avances tecnológicos se refieren a los datos de teledetección, los cuales son fuente primaria para la cartografía temática de la cubierta terrestre (Petropoulos et al., 2012), la teledetección consiste en adquirir información proviene de la reflectancia medida en el dominio visible e infrarrojo del espectro electromagnético para luego ser procesada, analizada y utilizada en alguna aplicación específica (De Backer et al., 2004).

De acuerdo con (Chuvieco, 2008), la teledetección se define como “la técnica que permite adquirir imágenes de la superficie terrestre desde sensores aéreos o espaciales”, y por tanto se asume que “entre el suelo y el sensor existe una interacción energética, ya sea por reflexión de la energía solar o de un haz energético artificial (por emisión propia)”.

Campbell & Wynne, (2011) expresan que los sensores remotos (teledetección) es la práctica que consiste en derivar información de la superficie terrestre y las superficies de agua empleando imágenes adquiridas desde una perspectiva aérea, empleando la radiación electromagnética reflejada o emitida desde la superficie de la Tierra.

La radiación electromagnética se define como toda la energía que se mueve con la velocidad de la luz en un patrón de onda armónica (es decir, todas las ondas están espaciadas en el tiempo por igual y repetidamente), las diferentes formas de radiación electromagnética varían a lo largo del espectro (Figura 2) en términos de longitud de onda y frecuencia. La longitud de onda es la distancia entre una posición en un ciclo de onda y la misma posición en la siguiente onda, mientras que la frecuencia es el número de ciclos de onda que pasan por el mismo punto en un período de tiempo determinado (Khorram et al., 2012).

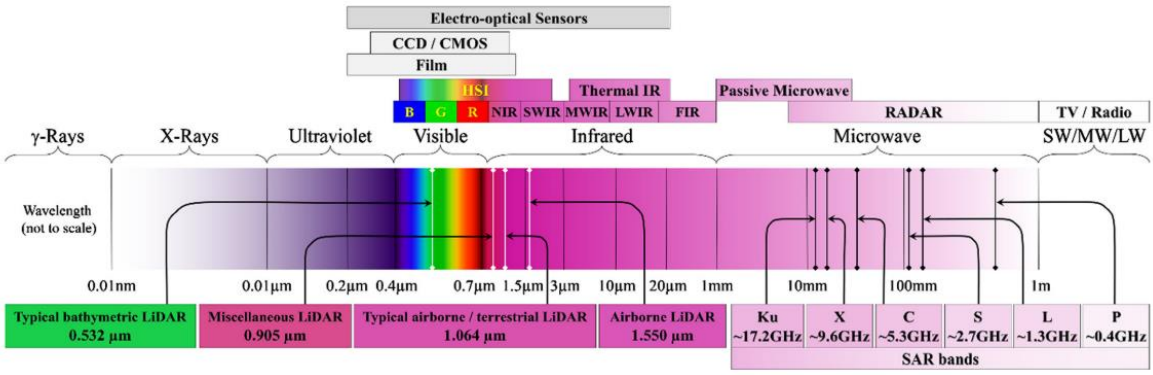

Figura 2. Espectro electromagnético con bandas de importancia para la teledetección. Fuente: (Toth & Jóźków, 2016).

Cuando la radiación electromagnética entra en contacto con la materia (es decir, cualquier objeto o material, como árboles, agua o gases atmosféricos), son posibles las siguientes interacciones: absorción, reflexión, dispersión o emisión de radiación por la materia, o transmisión de radiación a través de la materia. La teledetección se basa principalmente en la detección y el registro de radiación electromagnética reflejada y emitida. Básicamente, lo que hace posible la teledetección es que cada objeto o material tiene propiedades particulares de emisión y/o reflectancia, conocidas colectivamente como su firma o perfil espectral, que lo distingue de otros objetos y materiales (Khorram et al., 2012). En la teledetección se resalta el uso de unas bandas espectrales que son las más empleadas (Tabla 1).

Tabla 1. Descripción de bandas en el espectro electromagnético.

BANDA	CARACTERÍSTICA
Azul - B (0,4 a 0,5 µm)	Espectro visible. Suelen distinguirse tres bandas elementales.
Verde - G (0,5 a 0,6 µm)	
Rojo - R (0,6 a 0,7 µm)	
Infrarrojo cercano - IRC (0,7 a 1,3 µm)	De importancia por la capacidad para discriminar vegetación y concentraciones de humedad.
Infrarrojo medio (1,3 - 8 µm),	En esta región se entremezclan los procesos de reflexión de la luz solar y de emisión de la superficie terrestre.
Infrarrojo lejano o térmico - IRT (8 - 14 µm)	Incluye la porción emisiva del espectro terrestre.
Microondas (a partir de 1 mm)	Energía bastante transparente a la cubierta nubosa.

Fuente: (Chuvieco, 1995)

De acuerdo con (Chuvieco, 2008) “la teledetección no sólo engloba los procesos que permiten obtener una imagen, sino que también involucra su posterior tratamiento e interpretación, de esta forma un sistema de teledetección incluye los siguientes elementos” (Figura 3):

- Fuente de energía, que supone el origen de la radiación electromagnética que detecta el sensor.
- Cubierta terrestre, formada por distintas masas de vegetación, suelos, agua o construcciones humanas.
- Sistema sensor, compuesto por el sensor y la plataforma que lo alberga. Capta la energía procedente de las cubiertas terrestres, las codifica y graba o envía directamente al sistema de recepción.

- Sistema de recepción-comercialización, en donde se recibe la información transmitida por la plataforma, se graba en formato apropiado, y, tras las oportunas correcciones, se distribuye a los interesados.
- Intérprete, que convierte esos datos en información temática de interés, de cara a facilitar la evaluación del problema en estudio.
- Usuario final, encargado de analizar el documento fruto de la interpretación, así como de dictaminar las conclusiones que de él se deriven.

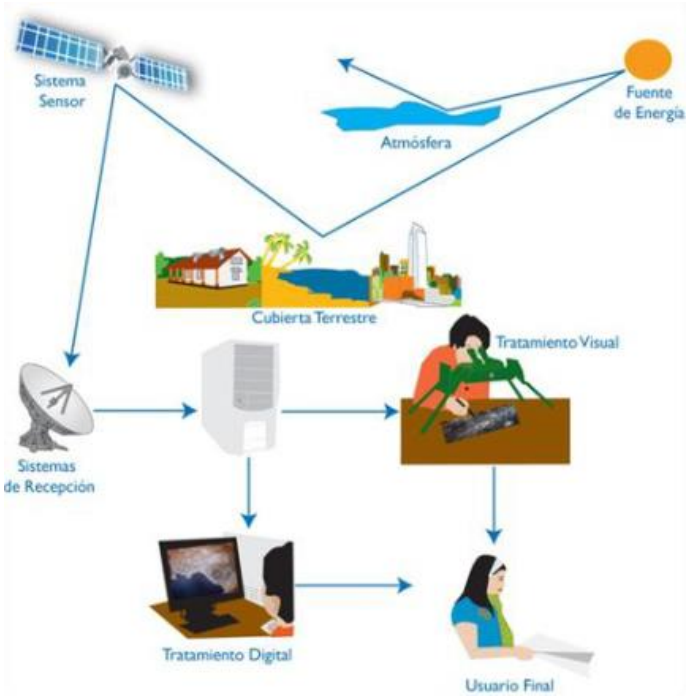

Figura 3. Componentes de un sistema de teledetección.
Fuente: (Chuvieco, 2008).

Un sensor remoto capta la radiación electromagnética en forma análoga (fotografía aérea, por ejemplo) o digital (en forma de matriz compuesta de pixeles). Existen dos grandes tipos de sistemas óptico-electrónicos: los sensores pasivos y los sensores activos. Los sensores pasivos dependen de una fuente externa de energía, por lo general el Sol, o reciben la radiación emitida o reflejada desde áreas y objetos de interés, sólo pueden usarse para detectar energía cuando la energía natural está disponible, las imágenes de satélite y las fotografías aéreas son ejemplos de productos obtenidos a partir de sensores pasivos. En contraste, los sensores activos tienen su propia fuente de energía, sus mediciones son más controladas, ya que no dependen de las variaciones de las condiciones de iluminación. Entre las ventajas de los sensores activos se incluye la capacidad de

obtener mediciones en cualquier momento, independientemente de la hora del día o la temporada, RADAR y LiDAR son ejemplos de sensores activos (Canada Centre for Remote Sensing, 1998), (Parra, 2014).

Los datos obtenidos a partir de sensores remotos se pueden describir mediante cuatro tipos de resolución: espacial, espectral, temporal y radiométrica.

La resolución espacial es una medida de la precisión del detalle de una imagen. Para imágenes digitales, se refiere al área del suelo capturada por un solo pixel; debido a que los pixeles son típicamente cuadrados, la resolución generalmente se expresa como la longitud lateral de un pixel. Designa al objeto más pequeño que puede ser identificado en la imagen. El tamaño de pixel influye en la resolución de los detalles de la escena y está relacionado con la distancia del sistema de adquisición, las características del sensor y el tipo de operación (Chuvieco, 1995), (Gomarasca, 2009), (Khorram et al., 2012).

Tabla 2. Clases de resolución espacial para sensores aerotransportados y satelitales.

CLASE DE RESOLUCIÓN	RESOLUCIÓN ESPACIAL (M)	DESCRIPCIÓN
1	0,1 – 0,5	Extremadamente alta
2	0,5 – 1	Muy alta
3	1 – 4	Alta
4	4 – 12	Media
5	12 – 50	Media baja
6	50 – 250	Baja
7	250 – 1000	Muy baja
8	>1000	Extremadamente baja

Fuente: (Gomarasca, 2009)

La resolución espectral, está relacionada con el número de bandas y su correlación o amplitud registradas por el sensor. Define entonces el almacenamiento de energía electromagnética registrada y la capacidad del sensor para detectar diferencias de longitud de onda entre objetos o áreas de interés. Un sensor será más idóneo en la medida que ofrezca mayor cantidad de bandas ya que facilita la caracterización de las diferentes coberturas (Chuvieco, 1995), (Khorram et al., 2012).

La resolución radiométrica: o sensibilidad radiométrica, se refiere al número de niveles digitales que se utilizan para expresar los datos recopilados por el sensor. Con frecuencia se expresa en términos del número de dígitos binarios, o bits, necesarios para representar el rango de valores de brillo disponible. La profundidad

de bits binaria se expresa normalmente en los siguientes rangos de niveles de escala de grises: 8 bits (0-255), 10 bits (0-1.023), 11 bits (0-2.047), 12 bits (0-4.095) y 16 bits (0–65.535) (Gomarasca, 2009), (Khorram et al., 2012) (Parra, 2014).

La resolución temporal: se relaciona con la cantidad de tiempo que tarda un sensor en volver a visitar una ubicación geográfica, es decir que determina su periodicidad (Khorram et al., 2012). Una alta resolución temporal es importante para el monitoreo de eventos o características que tienen alta dinámica o variabilidad en lapsos de tiempo relativamente cortos.

3.4 ART Y AGRICULTURA DE PRECISIÓN

La planificación urbana, la vigilancia del medio ambiente, la gestión de cultivos, la prospección petrolífera, la explotación minera, entre otras, son objeto para la adquisición de datos provenientes de sensores remotos desde hace varios años, convirtiendo la imagen satelital en la forma más rápida, precisa y económica para llevar a cabo el monitoreo y estudios de gran escala (Govender et al., 2007). Los atributos de rapidez, precisión, economía, sincronización, capacidad de monitoreo dinámico y repetitivo, de la teledetección, hacen que esta sea una técnica ideal para el monitoreo y manejo agrícola (Chen Z. et al., 2008).

Actualmente, se cuenta con sensores remotos como las aeronaves remotamente tripuladas (ART), de bajo costo y facilidad de uso para generar imágenes de la superficie terrestre, estas tienen el potencial para incrementar la eficiencia en la captura de datos (Tang & Shao, 2015), brindan ventajas sofisticadas en comparación con cualquier otro sistema, como facilidad de uso, monitoreo preciso de aquellas áreas que son difíciles de alcanzar por el hombre, rastreo de actividades ilegales, observaciones de incendios forestales y vigilancia de los rendimientos de cultivos de grandes granjas agrícolas (Puri et al., 2017). Con las imágenes adquiridas con estos sistemas, es posible aplicar procesos fotogramétricos para generar ortofotos a escalas 1:15.000 y mayores, y de esta forma contribuir a la solución de problemas territoriales o de desarrollo sustentable. Hay una amplia gama de posibles aplicaciones para estos dispositivos, incluyendo la topografía, la minería, la agricultura, la vigilancia del medio ambiente y la gestión y la conservación (Gonçalves & Henriques, 2015).

Las ART se han convertido en una herramienta rápida, sencilla y de bajo costo para la obtención de datos, especialmente imágenes de alta resolución y productos

derivados. En contraste con las imágenes satelitales o las imágenes de sensores aerotransportados, las imágenes obtenidas con estos vehículos ofrecen mayor resolución espacial y temporal lo que permite fácilmente el monitoreo de los recursos, y son poco dependientes de la nubosidad o de las condiciones climáticas (Grenzdörffer et al., 2008), (Tang & Shao, 2015). Una de las grandes ventajas de estos elementos es la alta flexibilidad y los relativos bajos costos. Además las ART pueden ser una alternativa cuando se requiere volar en un momento determinado (Mesas-Carrascosa et al., 2014). (Sotier, 2014) relaciona que algunas de las principales limitaciones, especialmente en zonas montañosas, se relacionan con las condiciones climáticas como el viento, la visibilidad, la disponibilidad/existencia de sitios de aterrizaje, la señal de los sistemas GNSS, y las restricciones legales que puedan presentarse.

Estos sistemas pueden volar a bajas altitudes y permiten grandes traslapes entre las imágenes, lo que permite la adquisición de imágenes de muy alta resolución espacial, en el rango de pocos centímetros, y permiten la generación de modelos digitales de superficie (DSM) empleando métodos que estén basados en reconstrucciones tridimensionales (Jorge Torres-Sánchez et al., 2015).

De acuerdo con (Puri et al., 2017) las ART se pueden clasificar en dos categorías: aviones de ala fija y multirrotores. Cada una de estas ART tiene sus propias ventajas y limitaciones. Las aeronaves de ala fija pueden volar a velocidades más altas que oscilan entre 25 y 45 mph (40-70 km/h) y pueden cubrir el rango de 500 a 750 acres por hora (200 – 300 ha por hora), dependiendo de la batería. Las ART de motor rotativo, por otro lado, pueden flotar y enfocarse en un problema específico en el mundo real y pueden volar a velocidad constante. Experimentan una duración limitada de la batería y pueden despegar y aterrizar de manera segura en áreas pequeñas y confinadas y son más convenientes para que los principiantes aprendan a volar con drones.

Para los análisis de vegetación, las ART, son equipados con cámaras digitales de alta resolución con sensores en el espectro visible o multiespectrales que capten longitudes de onda en el infrarrojo (NIR; CIR), térmicas y/o hiperespectrales. Otros sensores que pueden incluirse en una ART son los sensores de radar de apertura sintética (SAR) y de escáner laser (LiDAR) (Colomina & Molina, 2014), (Tang & Shao, 2015).

Las aplicaciones de las ART en la agricultura incluyen, entre otras, la identificación de fenotipos de plantas, manejo de fertilizantes (Abd-Elrahman et al., 2019),

detección de malezas (Louargant et al., 2017), identificación de deficiencias nutricionales (Barbedo, 2019), monitoreo de biomasa (Jannoura et al., 2015), manejo de plagas y enfermedades (Abd El-Ghany et al., 2020), (Dhingra et al., 2018), estrés hídrico (Zarco-Tejada et al., 2012), (Zhuang et al., 2017), también se ha combinado información agroclimática con imágenes de alta resolución para el monitoreo de cultivos (Ballesteros et al., 2018).

En (Radoglou-Grammatikis et al., 2020) se presentan y analizan 20 aplicaciones de ART relacionadas con el dominio agrícola. Más específicamente, estas aplicaciones se dividieron en tres categorías, a saber: a) Aplicaciones de monitoreo, b) Aplicaciones de pulverización (pesticidas, herbicidas, fertilizantes) y c) Aplicaciones multi-UAV.

Mukherjee et al., (2019) exploraron varias áreas de aplicación de ART, incluyendo tipos, sensores, dominios de investigación y arquitecturas de implementación. (Zhang & Kovacs, 2012) realizan una revisión del uso de los ART pequeños en la agricultura de precisión, (Sishodia et al., 2020) proporcionan una descripción general de los sistemas, técnicas e índices de vegetación de teledetección junto con sus aplicaciones recientes (2015-2020) en agricultura de precisión.

Sugiura et al., (2005) diseñaron un sistema de ala giratoria que pudiera generar un mapa de un cultivo, adoptando un sistema de posicionamiento global cinemático en tiempo real (GPS-RTK) y se instaló un sensor de momento inercial que proporcionara los valores de ángulos de balanceo y cabeceo, el mapa resultante, luego de realizar las correcciones de GDS tuvo un error espacial de 38 cm.

Reinecke & Prinsloo, (2017) analizan los beneficios de los drones en agricultura y sus limitaciones, ilustrando a partir de ejemplos cómo operan los drones en las granjas. Se discuten diferentes características de los drones, específicamente cómo ayudan a los agricultores a maximizar su cosecha mediante la detección temprana de problemas y la gestión de los cultivos mediante el uso de cámaras específicas para detectar plagas y escasez de agua. Los autores recomiendan que más agricultores inviertan en tecnología de drones para mejorar sus resultados agrícolas.

3.5 SENSORES REMOTOS Y VOLCAMIENTO

Con relación al fenómeno del volcamiento, el cual afecta no solamente al maíz, sino a otros cereales, se tienen los estudios realizados por (Chu et al., 2017), quienes estudiaron el potencial de imágenes multiespectrales de alta resolución obtenidas a partir de aeronaves remotamente tripuladas, emplearon estructuras a través de movimiento (*Structure from motion*) y algoritmos de computación geoespacial con el fin de detectar y evaluar la severidad del volcamiento en un cultivo experimental de maíz en Texas, los resultados de volcamiento basados en ART fueron generalmente comparables en precisión a los medidos por un recolector de datos en campo.

Empleando una ART de bajo costo equipada con una cámara RGB, (Wang et al., 2018), para discriminar el trigo volcado del trigo no volcado en la granja Experimental de la Universidad Yangzhou, ciudad Yangzhou, Provincia Jiangsu, China. Los autores compararon características de color así como texturas, y emplearon clasificación no supervisada, encontraron que la media de la relación G/B fue un discriminador óptimo alcanzando niveles de precisiones del productor 81,23% y 93,62%, mientras que las precisiones del usuario fueron 86,15% y 91,08%.

Con la combinación de imágenes infrarrojas térmicas y visibles obtenidas con un vehículo aéreo no tripulado, (T. Liu et al., 2018) reconocieron el volcamiento en dos cultivos de arroz en China, empleando métodos de optimización de partículas y máquinas de soporte vectorial. Los resultados obtenidos mostraron que las características de color y textura eran diferentes entre las plantas de arroz volcadas y no volcadas. Además, la temperatura fue distinta entre las áreas de volcamiento y no volcamiento, siendo más alta la temperatura del dosel en el arroz volcado. El modelo validado tuvo una tasa de falsos positivos y una tasa de falsos negativos de menos del 10%, y una tasa de volcamiento estimada con un R^2 superior a 0,9.

Sun et al., (2019) analizaron la capacidad de monitoreo de imágenes multiespectrales obtenidas con un sensor Sequoia Parrot instalado en una aeronave remotamente tripulada para determinar el grado de volcamiento en un cultivo de maíz en Gaocheng, ciudad de Shijiazhuang, Provincia Hebei, China, los autores combinaron características de textura e índices de vegetación, y clasificaron varias imágenes por el método de máxima verosimilitud (MLC por su sigla en inglés) y así identificar cuatro grados o niveles de volcamiento (sin volcamiento, ligero, moderado y severo). Los resultados obtenidos mostraron que los componentes principales, las

características de la textura y la combinación de las características de la textura, y los índices de vegetación mejoraron en comparación con las imágenes multiespectrales.

En un contexto geográfico más cercano a Colombia, se tiene el estudio de caso llevado a cabo en Brasil por (Acorsi et al., 2019) en el área experimental de la Universidad Tecnológica de Paraná, ciudad Dois Vizinhos, estado de Paraná, los investigadores generaron modelos de superficie derivados de imágenes capturadas con una ART. Las estimaciones de volcamiento mostraron una correlación muy alta con los datos de referencia. Se observaron altas correlaciones para el umbral fijo al 60% (R^2 = 0,93, RSME = 8,72%) el estudio demostró el potencial del uso de esta técnica, reduciendo la subjetividad de la evaluación basada en los muestreos directos en campo.

Shu et al., (2020) propusieron un método basado en el cambio en la altura de la planta antes y después del volcamiento del maíz para calcular el ángulo de alojamiento y monitorear el grado de volcamiento mediante el uso de datos Sentinel-1A de polarización dual. La precisión general de la clasificación del grado de volcamiento de maíz que obtuvieron fue del 67%.

Empleando sensores de radar, (Chauhan et al., 2020) realizaron una investigación en la granja Bonifiche Ferraresi, ubicada en Jolanda di Savoia, Ferrara, Italia, en un cultivo de trigo con área de 600 ha, para evaluar el rendimiento de los datos de RADARSAT-2 y Sentinel-1 con el fin discriminar y clasificar la gravedad del volcamiento según el puntaje de severidad medido en el campo. Los resultados mostraron la gravedad del volcamiento se clasificó mejor utilizando datos de ángulo de incidencia bajo R-FQ8 (precisión general 72%), y modelo de clasificación basado en datos de Sentinel-1 pudo identificar correctamente el 60% de los casos de gravedad del volcamiento en el estudio.

Li et al., (2021) emplearon imágenes en el espectro visible obtenidas con una ART para analizar el volcamiento en un cultivo de caña de azúcar, evaluaron tres métodos. Los resultados mostraron que el marco de análisis propuesto proporcionó una alta precisión (94,0%) para la identificación del volcamiento de la caña de azúcar.

3.6 ANÁLISIS DE IMÁGENES

3.6.1 Interpretación de imágenes

Las técnicas de interpretación de visual de imágenes emplean criterios similares a los que se emplean en la fotointerpretación clásica, dichos criterios incluyen brillo, color, textura, forma, patrón, tamaño, contraste, sombra, posición geográfica, sitio topográfico.

> El brillo y color son los criterios más elementales, permiten caracterizar espectralmente a una cobertura. La forma, tamaño, patrón y textura se relacionan con las propiedades espaciales de los objetos. La sombra y emplazamiento, se identifican con relación a los objetos circundantes. En la interpretación visual se pueden incorporar criterios complejos, estos criterios permiten diferenciar categorías que pueden tener un comportamiento espectral similar, pero su significado temático es diferente (Chuvieco, 1995).

A continuación, se definen cada uno de los criterios:

Tono: “hace referencia a la intensidad de energía recibida por el sensor, se relaciona estrechamente con el comportamiento espectral de las distintas cubiertas, para la banda particular del espectro sobre la que se trabaje” (Chuvieco, 1995).

Color: es resultado de la reflectividad selectiva de los objetos a distintas longitudes de onda. Si el sensor recoge información sobre bandas del espectro azul, verde y rojo, puede obtenerse una composición en color natural (Chuvieco, 1995).

Textura: “se refiere a la aparente rugosidad o suavidad de una región en la imagen, procede de la relación entre el tamaño de los objetos y la resolución del sensor. Es importante para discriminar determinadas coberturas que pueden ofrecer un comportamiento espectral uniforme” (Chuvieco, 1995).

Situación espacial: se refiere a la localización de las cubiertas y su relación con los elementos vecinos en la imagen. La clasificación digital no considera el contexto geográfico, dada la complejidad de definir este en términos numéricos (Chuvieco, 1995).

Otros criterios: se pueden considerar además las sombras, el patrón espacial, el contorno y las formas.

3.6.2 Transformaciones de la imagen: Índices espectrales

Los Índices de Vegetación (VI) basados en sensores remotos son algoritmos bastante simples y efectivos para evaluaciones cuantitativas y cualitativas de la cobertura vegetal, el vigor y la dinámica de crecimiento, entre otras aplicaciones (Xue & Su, 2017). Un índice espectral se utiliza para combinar o filtrar múltiples conjuntos de datos espectrales en un solo valor para cada punto de una imagen. Por lo general, se puede expresar como una fórmula matemática. Comúnmente, a la salida del índice se le asigna un color de una escala de colores y se usa para generar una imagen en falso color del terreno analizado. La imagen resultante puede mostrar rápidamente las regiones del campo donde el índice arrojó valores bajos y aquellas donde se obtuvieron valores altos (McKinnon & Hoff, 2017).

Muchos índices, pero no todos, requieren datos de un sensor que opere en la longitud de onda del infrarrojo cercano (NIR), los mapas de índices de vegetación facilitan la búsqueda de áreas problemáticas en un campo, como la falta de nutrientes o el suelo pobre. A menudo, la misma información se puede ver en la imagen RGB es más sutil y difícil de identificar claramente (McKinnon & Hoff, 2017). La recopilación de imágenes RGB por ART es simple, rentable y los índices de vegetación en RGB pueden ser calculados fácilmente a partir de dichas imágenes (Bendig et al., 2015). (Xue & Su, 2017) manifiestan que se han desarrollado y probado algoritmos personalizados para diferentes aplicaciones de acuerdo con expresiones matemáticas específicas que combinan la radiación de luz visible, principalmente la región del espectro verde, y regiones no visibles del espectro para obtener cuantificaciones proxy de la superficie de la vegetación.

Bendig et al., (2015) calcularon índices de vegetación de bandas en el espectro visible: el índice de vegetación verde rojo (GRVI), el GRVI modificado (MGRVI) y el índice de vegetación rojo verde azul (RGBVI), donde el MGRVI y el RGBVI son índices recientemente desarrollados, de acuerdo con los datos obtenidos, los autores concluyen que los índices de banda visible tienen potencial para la predicción de biomasa, la principal limitación es que los índices de vegetación de banda visible funcionan sólo para las primeras etapas de crecimiento.

Kataoka et al., (2003) propusieron el índice denominado CIVE (Índice de color de extracción de vegetación), el cual se expresa como una combinación lineal de las tres bandas RGB y adiciona una constante, con éste las imágenes segmentadas de

las plantas verdes se convirtieron fácilmente a partir de imágenes en color en lugar de imágenes NIR. (Gitelson et al., 2002) propusieron emplear el espectro visible para estimar cuantitativamente la fracción de vegetación, encontraron que el Índice de vegetación resistente a la atmósfera (VARI) es mínimamente afectado por la atmósfera y permitió calcular la fracción de vegetación con un error inferior al 10%.

J. Torres-Sánchez et al., (2014) calcularon y evaluaron seis índices espectrales (CIVE- Índice de color de extracción de vegetación, ExG-Exceso de verde, ExGR-Exceso de verde menos exceso de rojo, Índice Woebbecke, NGRDI-Índice deferencia normalizada verde-rojo, VEG-Índice vegetativo) y dos combinaciones de estos índices con el fin de identificar la fracción de vegetación en un cultivo de trigo, y obtuvieron que ExG y VEG arrojaron las mejores precisiones. (Louhaichi et al., 2001) realizaron un ejercicio práctico de combinación de técnicas de análisis de imágenes aéreas y al nivel del suelo, observaciones espectrales y sistemas de posicionamiento global para cuantificar condiciones de campo en un cultivo de trigo, el interés era determinar cobertura de trigo (definida como la proyección vertical del área de copa sobre la superficie del suelo) y si había ocurrido pastoreo por gansos, clasificaron las imágenes obtenidas determinando si el promedio de los números digitales rojos y azules era mayor o menor que el número digital verde (lo cual equivale a la expresión del índice GLI-Índice de hoja verde), éste genera una imagen con valores entre -1 y +1. Los valores negativos tendieron a ser suelo, mientras que los valores positivos fueron hojas y tallos verdes. En la mayoría de los casos, pudieron establecer un umbral con un valor cercano a 0 para catalogar la imagen en dos clases: hojas verdes y suelo/inerte.

Hunt et al., (2011) desarrollaron y propusieron el índice TGI-Índice triangular de verdor que fuera sensible a las diferencias en el contenido de clorofila foliar a escalas de hojas y dosel, dada la estrecha relación de ésta con el contenido de Nitrógeno (N). El índice se correlacionó con datos de reflectancia obtenidos de hojas, las correlaciones fueron iguales o superiores a los índices de banda ancha, cuando el índice de área foliar (LAI) fue> 2. Los autores proponen que el TGI podría usarse con sensores de bajo costo, para la gestión de nitrógeno mediante sensores remotos. Las longitudes de onda empleadas por los autores para la expresión matemática del índice corresponden a las bandas 1, 2 y 3 del sensor Landsat TM, (McKinnon & Hoff, 2017) emplearon la sensibilidad de un sensor CMOS típico y lo normalizaron por la banda verde. En este mismo sentido, (De Ocampo et al., 2019) proponen un método para compensar la falta de información sobre la sensibilidad máxima de las longitudes de onda de sensores CMOS genéricos, de manera tal que se permita el uso de cualquier cámara digital disponible aunque no se conozcan la

sensibilidad de la longitud de onda en el espectro visible del sensor CMOS empleado, la expresión obtenida también se encuentra normalizada por la banda verde, ambas expresiones son muy similares y sólo difieren en los coeficientes.

Wang et al., (2018) emplearon un vehículo aéreo no tripulado (UAV) de bajo costo equipado con una cámara RGB con el objetivo de discriminar el trigo volcado del trigo no volcado empleando técnicas de clasificación no supervisada. Después de comparar diversas características de color, así como sus características de textura, determinaron que la característica de textura de la media de G/B (relación numérica digital de la banda verde a la banda azul) derivada de las medidas de ocurrencia era el discriminador óptimo de trigo volcado y trigo no volcado. Este discriminador seguía siendo efectivo, aunque las variaciones espectrales espaciales en el área de estudio eran mucho más complejas que en estudios previos.

Marcial-Pablo et al., (2019) realizaron vuelos a 52 m sobre el terreno, obteniendo imágenes RGB de pixel de 1,25 cm e imágenes multiespectrales de pixel de 2,10 cm. Calcularon tres índices espectrales en la región visible, Exceso de verde (ExG), Índice de color de la vegetación (CIVE) e Índice de vegetación verde (VIg), y tres índices de vegetación basados en NIR, Índice de vegetación de diferencia normalizada (NDVI), NDVI verde (GNDVI) y Verde Normalizado (NG), estos índices fueron evaluados para la estimación de fracción de vegetación. Los resultados sugieren que ExG puede ser una opción muy adecuada para monitorear la fracción de vegetación en la etapa de crecimiento del cultivo al comienzo de la temporada, mientras que las etapas posteriores podrían requerir índices basados en NIR. Así, la selección del índice dependerá de los objetivos del estudio y de la capacidad del equipo.

3.6.3 Transformaciones de la imagen: Análisis de Componentes Principales (ACP)

Dado el carácter digital y matricial de las imágenes provenientes de sensores remotos, estas permiten generar nuevas imágenes producto de aplicar transformaciones lineales a una o varias imágenes. En la imagen transformada se pueden destacar algunas características que de pronto no fueran identificables a partir de la imagen original, o también conservar la información de la imagen pero en un número menor de dimensiones. Las transformaciones pueden aplicarse con el fin de mejorar la imagen o como un paso intermedio a un proceso de clasificación. (Ferrero et al., 2002)

El análisis de componentes principales (ACP) es un método general de análisis para conjuntos de datos de múltiples variables correlacionadas (J. G. Liu & Mason, 2016).

> El Análisis de componentes principales - ACP tiene como objetivo resumir un grupo amplio de variables en un nuevo conjunto, más pequeño, sin perder una parte significativa de la información original. El ACP permite sintetizar las bandas originales creando unas nuevas. Esta síntesis resulta muy conveniente cuando se pretende abordar un análisis multitemporal o cuando se intentan seleccionar las tres bandas más adecuadas para una composición en color (Chuvieco, 1995).

De acuerdo con (J. G. Liu & Mason, 2016), las imágenes multiespectrales de sensores remotos son parte típicamente de esos conjuntos de datos para los que el ACP es una técnica eficaz para la mejora espectral y la manipulación de la información. Se basa en operaciones de matrices algebraicas lineales y estadísticas multivariada. El ACP puede concentrar eficazmente la información máxima de muchas bandas espectrales de imágenes correlacionadas en unos pocos componentes principales no correlacionados (CP) y, por lo tanto, puede reducir el tamaño de un conjunto de datos y permitir una visualización de información RGB de manera eficaz. (Ferrero et al., 2002) resaltan que el ACP incrementa la eficiencia del proceso computacional de la clasificación al reducir la dimensionalidad de los datos.

3.6.4 Clasificación digital de imágenes

El proceso de clasificación de imágenes consiste en asignar cada pixel o celda de la matriz, a una categoría específica a partir de un conjunto de categorías de interés. Para esto se tienen dos enfoques diferenciados: clasificadores rígidos o de lógica estricta, en los cuales el pixel se asigna a una única clase del esquema de clasificación, y los clasificadores suaves o de lógica difusa, en estos expresan el grado en el que un pixel pertenece a cada una de las clases consideradas (Khorram et al., 2012), (Parra, 2014). Los métodos de clasificación rígidos pueden ser de dos tipos, clasificación supervisada y clasificación no supervisada.

Clasificación supervisada

Presupone cierto conocimiento previo del área de estudio para la selección de áreas de entrenamiento que representan a cada una de las clases, sobre cada una de

ellas el sistema de cómputo calcula los niveles digitales que definen cada una de las clases y asigna el píxel a la mejor clase de coincidencia. Las muestras deben ser representativas y homogéneas de las clases a representar, deben distribuirse de forma aleatoria o sistemática por toda la imagen, el número de sitios de entrenamiento debe ser al menos tres veces mayor que el número de categorías de interés, además se considera más conveniente identifica varios campos pequeños que uno solo de tamaño más grande (Chuvieco, 1995), (Khorram et al., 2012), (Parra, 2014), (J. G. Liu & Mason, 2016). También pueden emplearse datos recolectados en campo como muestras de la realidad del terreno, siendo aconsejable que sean tomadas de forma simultánea a la adquisición de las imágenes, dados los cambios temporales. Este método a menudo se ve limitado por errores en los datos de campo, accesibilidad limitada o irrelevancia temporal (J. G. Liu & Mason, 2016)

Algoritmos de uso en clasificación supervisada incluyen:

Clasificador de Máxima Verosimilitud o probabilidad (*Maximum likelihood*): se basa en el supuesto de que la distribución de pixeles en una clase o grupo determinado puede describirse mediante una distribución de probabilidad en el espacio espectral, considera que los niveles digitales en cada clase se distribuyen como una normal, lo cual permite describir la clase por una función de probabilidad a partir del vector de medias y de la matriz de covarianza que representa la variación de los valores tanto dentro como entre las bandas de la imagen, el pixel se asigna a la clase en la que tiene la mayor probabilidad, o máxima probabilidad, de pertenencia. El método recibe el nombre general de procedimiento paramétrico. Es de amplio uso, altamente intensivo en uso de recursos computacionales (Chuvieco, 1995), (Khorram et al., 2012), (Richards, 2013).

Clasificador de Mínima Distancia: el criterio que emplea para asignar un pixel a una de las categorías consiste en incluirlo en la más cercana; que corresponde con la distancia espectral consecuencia de comparar los niveles digitales de cada pixel con los del centroide de clase. No calcula matriz de covarianzas ya que no considera la dirección de la distribución de los datos (Chuvieco, 1995), (Parra, 2014).

Clasificador de Paralelepípedos: para cada categoría se fija un área de dominio, en donde se tienen en cuenta los valores de centralidad y dispersión, el pixel se asigna a la clase si sus niveles digitales están dentro del área de dominio definida en todas las bandas consideradas. Es común que algunos de los grupos sean ambiguos en

el sentido de que aparentemente representan una mezcla de las clases (Chuvieco, 1995), (Khorram et al., 2012)

El proceso de clasificación y los resultados están influenciados por una variedad de factores, incluida la disponibilidad de datos de sensores remotos, la complejidad del paisaje, la selección de las bandas de la imagen, el algoritmo de clasificación utilizado, el conocimiento del analista sobre el área de estudio y la experiencia del analista con los clasificadores utilizados (Al-doski et al., 2013).

Clasificación no supervisada

No implica conocimiento previo del área de estudio. Los grupos son identificados por un algoritmo matemático que evalúa el comportamiento espectral homogéneo, dichas categorías espectrales no siempre podrán compararse con categorías o clases de información. El usuario estará entonces encargado de interpretar y asignar un significado temático a cada clase basado en algún conocimiento de la realidad del terreno. El método para definir los grupos o *cluster* espectrales se basa en tres parámetros: 1. Las variables que intervienen en el análisis o bandas espectrales, 2. Criterio para medir la similitud o distancia entre casos, y 3. Criterio para realizar el agrupamiento de los casos similares (algoritmo de clasificación). Los algoritmos más empleados para la clasificación no supervisada son *K-Means* e ISODATA (*Iterative Self-Organizing Data Analysis Techniques*) (Al-doski et al., 2013), (Parra, 2014). Es particularmente adecuado para imágenes de áreas donde no hay conocimiento de la realidad sobre el terreno o donde dicha información no está disponible, como en el caso de imágenes globales (J. G. Liu & Mason, 2016).

Otras técnicas o métodos de clasificación son:

Máquinas de Soporte Vectorial (*Support Vector Machines*): método de aprendizaje de máquinas (*machine learning*), no paramétrico, desarrollado por (Cortes & Vapnik, 1995) que surgió para problemas de clasificación de dos grupos, que diferencia y divide las clases determinando los límites en el espacio de características y maximiza el margen entre las clases. La superficie a menudo se denomina hiperplano óptimo y los puntos de datos más cercanos al hiperplano se denominan vector de soporte (Al-doski et al., 2013).

Árboles de decisión (*Decision Tree*): son uno de los algoritmos de aprendizaje automático más aplicables. La simplicidad e interpretabilidad, la capacidad de ser representado gráficamente y el bajo costo computacional son las características

responsables de su creciente uso. Los bosques aleatorios (*Random forest*), son una combinación de diferentes algoritmos de árboles de decisión para predecir o clasifica el valor de una variable; estimando la importancia de miles de variables en una clasificación. Por lo que el bosque aleatorio de cada árbol de decisión ayuda a asignar la importancia a la clase más frecuente. En un algoritmo de bosques aleatorios, el error de generalización se reduce debido a la utilización un subconjunto aleatorio de variables predictivas o características de entrada en la división de cada nodo, en lugar de utilizar las mejores variables (Hemmati-Sarapardeh et al., 2020).

3.6.5 Verificación de resultados

Posterior a la obtención de los resultados de clasificación, se hace necesario ejecutar el proceso de verificación de los mismos, en la medida que se tengan medidas de exactitud significativas se tendrán resultados coherentes para el usuario final y en función del uso particular de la información producida. Una evaluación o una estimación de la precisión relativa de la clasificación proporciona un conocimiento valioso para aceptar o rechazar un resultado de clasificación con un cierto nivel de confianza (J. G. Liu & Mason, 2016).

Datos de referencia: se emplea una muestra seleccionada de forma similar a las muestras de entrenamiento que se emplean en una clasificación supervisada, de esta forma se obtiene para cada pixel la cobertura real en el terreno y la predicha por el método de clasificación, esto permite obtener una estimación realista del error. Esta información se almacena en una matriz de datos denominada matriz de confusión, la cual almacena en su diagonal principal los pixeles en los cuales hay acuerdo entre la realidad y la predicción, los elementos marginales suponen los errores de asignación (Parra, 2014). A pesar del hecho de que la precisión de la clasificación derivada de la matriz de confusión es en gran medida una autoevaluación y de ninguna manera es la verdadera precisión de la clasificación, proporciona una medida útil de la precisión de la clasificación. La información en una matriz de confusión depende en gran medida de la calidad de las áreas de entrenamiento y/o de los datos recopilados en camp, este método proporciona una estimación de la exactitud de clasificación de toda la imagen (J. G. Liu & Mason, 2016).

Análisis de datos: corresponde al cálculo de índices que permiten determinar la probabilidad de que una clase de referencia haya sido bien clasificada en el mapa,

y la probabilidad de que un mapa en su conjunto haya sido bien clasificado, y represente realmente la realidad verificada. La matriz permite así calcular la exactitud de usuario y de productor y a su vez los errores de comisión u omisión, la exactitud del mapa y el coeficiente Kappa (Congalton, 1991), (Chuvieco, 1995), (Parra, 2014).

Exactitud de usuario: comprende los pixeles de clasificación que representan realmente la misma categoría en la referencia.

Exactitud del productor: comprende los pixeles de referencia que han sido correctamente clasificados.

Error de comisión consiste en los pixeles de clasificación que no se ajustan a la realidad.

Error de omisión comprende los pixeles de cubertura real que no se incluyeron en el proceso de clasificación.

Exactitud global de la clasificación, como medida de la fiabilidad de la clasificación, corresponde con la relación entre los pixeles correctamente clasificados frente al total de pixeles analizados en la muestra.

Coeficiente Kappa: “mide la diferencia entre el acuerdo mapa clasificado-realidad observada y el que cabría esperar simplemente por el azar” (Parra, 2014). De acuerdo con (Foody, 2020) no es un índice de precisión, de hecho, no es un índice de acuerdo general, sino de acuerdo más allá del azar. Está diseñado para su aplicación a datos que surgen de dos evaluadores independientes y proporciona una medida del grado en que coinciden en el etiquetado. La magnitud de un coeficiente kappa refleja no solo el acuerdo en la clasificación o etiquetado, sino también las propiedades de las poblaciones en estudio.

Existen diversas escalas de interpretación para calificar el coeficiente en función de rangos (Landis & Koch, 1977), (Fleiss et al., 2013), (Monserud & Leeman, 1992). Valores de 1 se entenderían como una concordancia perfecta (Tabla 3).

Tabla 3. Algunas escalas de interpretación de coeficiente Kappa.

AUTOR	KAPPA	INTERPRETACIÓN
(Landis & Koch, 1977)	< 0,00	Pobre
	0,00 – 0,20	Leve
	0,20 - 0,40	Regular
	0,40 – 0,60	Moderada
	0,60 – 0,80	Sustancial
	0,80 – 1,00	Casi perfecta
(Fleiss et al., 2013)	< 0,00	Pobre
	0,00 – 0,40	
	0,40 – 0,75	Regular a buena
	0,75 – 1,00	Excelente
(Monserud & Leeman, 1992)	< 0,00	Ninguna
	0,00 – 0,05	
	0,05 – 0,20	Muy pobre
	0,20 - 0,40	Pobre
	0,40 – 0,55	Regular
	0,55 – 0,70	Buena
	0,70 – 0,85	Muy buena
	0,85 – 1,00	Excelente a perfecta

4 MATERIALES Y MÉTODOS

4.1 ÁREA DE ESTUDIO

La zona de estudio se encuentra dentro de la Granja Montelindo – Universidad de Caldas, (75°40' 26” W, 5°4'48” N), ubicada en zona rural del municipio de Palestina (departamento de Caldas), en la vereda Santágueda, se encuentra ubicada a 38 kilómetros de la ciudad de Manizales, en el flanco oeste de la Cordillera Central de Colombia, la granja cuenta con una extensión de 67,1 hectáreas, de topografía plana y terrenos totalmente mecanizables en suelos francos de origen volcánico. Las condiciones climáticas están dadas por una altura sobre el nivel del mar de 1.010 metros, temperatura media de 22,8°C, una precipitación media anual de 2.200 mm y una humedad relativa de 76%.

En la granja se llevan a cabo diferentes programas agrícolas y pecuarios con fines docentes, investigativos, productivos y/o comerciales[2].

Programas Agrícolas
Brevo, frutales (limón tahití, mandarina oneco, maracuyá, naranja tangelo, naranja valencia, papaya, zapotes), guadua, maíz y soya para investigación y producción comercial, maquinaria agrícola, investigación en labranza cero, plátano, promisorios.
Rotaciones IX Semestre: investigación en cultivos como ajonjolí, algodón, fríjol, maíz, maní y sorgo.

Programas Pecuarios
Avicultura, ganado de carne, piscicultura

El área del presente estudio se localiza en un terreno de 4,1 ha de cultivo de maíz (Figura 4).

[2] https://cienciasagropecuarias.ucaldas.edu.co/granja-montelindo/

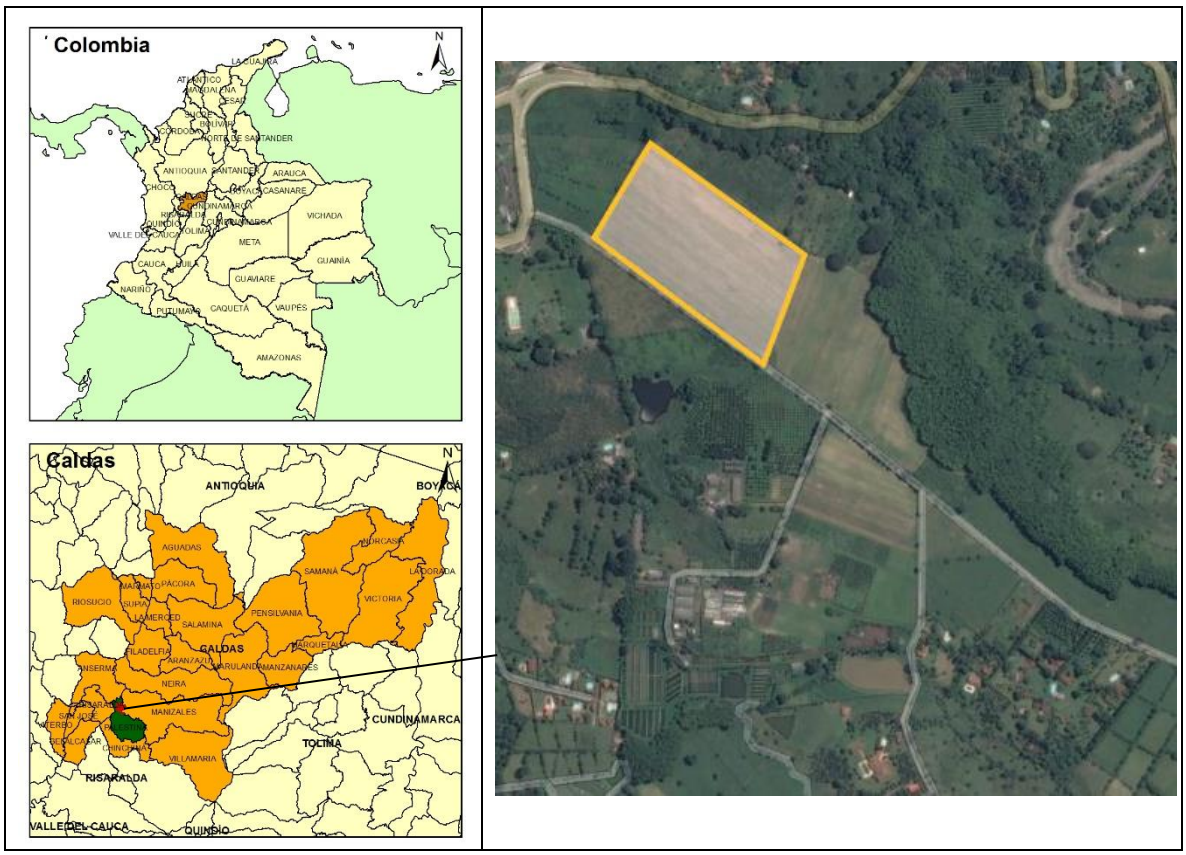

Figura 4. Localización del área de estudio en la Granja Montelindo, municipio de Palestina (Caldas).

4.2 ADQUISICIÓN DE IMÁGENES

La aeronave remotamente tripulada empleada en este estudio corresponde a un vehículo de cuatro hélices *DJI Phantom 4 Advanced*, equipado con el sistema *FlightAutonomy* de DJI compuesto por dos sensores de visión estéreo y dos sensores ultrasónicos, cuenta con posicionamiento satelital de doble banda GPS y GLONASS, cuenta con una autonomía de vuelo de hasta 30 minutos aproximadamente. La cámara integrada está equipada con un sensor RGB, cámara digital de 1”CMOS marca Sony de 20 megapixeles, objetivo FOV: 84° con apertura de f/2,8 - 11, que se conecta a la ART con un *gimbal*, el cual compensa los movimientos de cabeceo y balanceo (*pitch* y *roll*) durante el vuelo garantizando que las imágenes capturadas se acercan al nadir. Los modos de disparo de imagen incluyen ráfaga, continuo y a intervalos (DJI, 2017).

Las imágenes fueron obtenidas y procesadas por parte de la Universidad Católica de Manizales. Se realizaron 12 vuelos entre el 3 de septiembre y el 23 de noviembre del año 2018 de forma tal que se incluyeran diferentes estados de desarrollo del cultivo: etapa inicial de crecimiento, etapa de desarrollo del cultivo, etapa intermedia y etapa final. Se estableció una altura de vuelo de 60 metros sobre el nivel del suelo, Las imágenes se registraron durante condiciones de radiación homogénea y estable. Las misiones de vuelo se programaron y ejecutaron con el software *Pix4D Capture* cubriendo el cultivo de maíz de interés y áreas circundantes, las líneas de vuelo tuvieron traslape longitudinal de 80% y traslape transversal entre 60% - 70%. Los vuelos se realizaron entre las 10:30 a. m. y 12:00 m. El balance de blancos se configuró en modo soleado.

4.3 PREPROCESAMIENTO

Posterior a la adquisición de las imágenes se generaron los mosaicos ortorrectificados para las imágenes capturadas utilizando Agisoft PhotoScan Professional Edition (Versión 1.4) (Agisoft LLC, Saint Petersburg, Russia). De acuerdo con el flujo de trabajo y la configuración de parámetros presentados en (Agisoft LLC, 2018) los principales pasos del procesamiento de imágenes incluyeron: cargue de fotos en PhotoScan, inspección de imágenes cargadas, exclusión de imágenes innecesarias, alineación de fotos, construcción de nubes densas de puntos, construcción de mallas, generación de texturas, generación de DEM y obtención de ortofotomosaico, cada uno de estos se exportó posteriormente a formato TIFF.

Las imágenes procesadas no se redujeron de tamaño durante el proceso de mosaico, en consecuencia, se conservó la resolución original al igual que los niveles digitales (ND).

4.4 INTERPRETACIÓN VISUAL

La identificación preliminar de las diferentes categorías se hizo empleando el programa computacional ArcGIS Desktop versión 10.2, realizando la interpretación en pantalla directamente. Para la identificación de las categorías de interés: maíz volcado, maíz en pie, suelo o sombras en el área delimitada, se aplicaron técnicas de interpretación visual, empleando los criterios de brillo, color, textura, forma, patrón, tamaño, contraste, sombra, posición geográfica, sitio topográfico. El brillo y

color permiten caracteriza las coberturas espectralmente a partir de su comportamiento espectral. La forma, el tamaño, el patrón y la textura están relacionadas con las propiedades espaciales de los objetos. La sombra y emplazamiento, con su relación a los objetos circundantes. Además se pueden integrar otros criterios que permitan diferenciar categorías que pueden tener un comportamiento espectral parejo, pero significado temático diferente (Chuvieco, 1995). La finalidad de la interpretación visual preliminar fue facilitar la obtención de las muestras de entrenamiento que se emplearán para ejecutar el proceso de clasificación, obtener las muestras de verificación del proceso de clasificación (Parra, 2014), así como tener los estimativos de área afectada por volcamiento.

4.3 ÍNDICES ESPECTRALES

Los índices de vegetación en el espectro visible se utilizan típicamente para aprovechar las propiedades de color inherentes de la vegetación verde (Lee et al., 2020), estos índices pueden ser calculados fácilmente a partir de las imágenes (Bendig et al., 2015) como una función matemática de los valores rojo (R), verde (G) y azul (B) en una paleta de colores (o sus valores normalizados denotados por r, g y b para cada pixel de la imagen (Lee et al., 2020), en la Tabla 4 se presentan los índices aplicados en la imagen de estudio.

Tabla 4. Índices espectrales aplicados a la imagen.

ÍNDICE	NOMBRE	FÓRMULA	REFERENCIA
GRVI	Índice de Vegetación Verde-Rojo. Relación de vigor fotosintético (*Green Red Vegetation Index - Modified Photochemical Reflectance Index*)	$GRVI = \frac{R_G - R_R}{R_G + R_R}$	(Tucker, 1979), (Metternicht, 2003), (Yang et al., 2008)
PPR	Proporción de pigmentos de plantas – Índice de vegetación verde-azul (*Plant pigment ratio – Green –blue vegetation index*)	$PPR = \frac{R_G - R_B}{R_G + R_B}$	(Metternicht, 2003)
GLI	Índice de hoja verde (*Green Leaf Index)*	$GLI = \frac{2R_G - R_R - R_B}{2R_G + R_R + R_B}$	(Louhaichi et al., 2001)
VARI	Índice visible de resistencia a la atmósfera (*Visible Atmospherically Resistant Index*)	$VARI = \frac{R_G - R_R}{R_G + R_R - R_B}$	(Gitelson et al., 2002)

Los índices se obtuvieron empleando el programa computacional ArcGIS Desktop versión 10.2, aprovechando las ventajas ofrecidas por la ventana de análisis de imágenes *Image Analysis* y la función de aritmética de bandas (*Band Arithmetic Function*, aplicando el método definido por el usuario), previo a recurrir a este programa computacional, se realizaron pruebas para obtener los diferentes índices ejecutando las opciones de modelos de ERDAS Imagine 2014 en su módulo *Model maker*, y álgebra de mapas de ArcGIS (*Raster calculator*), en los cuales no se obtuvieron resultados congruentes para los archivos raster de salida de los índices.

Para la obtención de los índices de vegetación de bandas en el espectro visible se emplearon los valores de niveles digitales (ND) obtenidos en el ortofotomosaico dada la consideración manifestada por (Chuvieco, 1995) así que cada índice se considera de forma relativa en el mosaico. El autor además sugiere realizar este proceso al obtener los resultados finales, ya que de esta forma solo es necesario corregir la imagen final de resultado y no todas las bandas o capas originales que intervienen en el proceso, además la clasificación se realiza con los valores originales de tal forma que se evita realizar la clasificación empleando los valores de promedio de remuestreo que se genera durante el proceso de corrección, dadas estas consideraciones la corrección geométrica no se realizó al inicio del estudio.

4.4 ANÁLISIS DE COMPONENTES PRINCIPALES

Una vez obtenidos los índices espectrales, se generaron tres análisis de componentes principales (ACP), el primero en el cual se incluyeron las tres bandas correspondientes con el espectro visible RGB, y se obtuvieron tres componentes principales (CP), el segundo ACP se generó con los cuatro índices calculados y se obtuvieron cuatro CP, el tercer ACP se realizó con las tres bandas en el espectro visible y los cuatro índices calculados, se obtuvieron 7 CP, para este tercer ACP las bandas e índices fueron estandarizadas antes de ingresar al ACP. A partir de los valores propios (autovalores) y vectores propios (autovectores) de cada ACP se determinó con cuántos y cuáles componentes realizar los análisis posteriores de clasificación de imágenes. Los componentes principales son, de todas las combinaciones lineales posibles, aquellas que no están correlacionadas y que además explican el mayor porcentaje de variabilidad (Ferrero et al., 2002).

Los ACP se ejecutaron en el programa computacional ArcGIS 10.2, empleando la extensión de Análisis Espacial (*Spatial Analysis*) y la caja de herramientas de ArcToolbox “Multivariada”, las bandas se ingresaron en orden, primero el espectro

visible RGB y posteriormente los índices calculados, conservando la secuencia que se presenta en la Tabla 4. El programa generó un archivo TXT en el cual se presentan los siguientes datos: matriz de covarianza, matriz de correlación, así como los correspondientes valores propios o autovalores (*eigenvalues*) y vectores propios o autovectores (*eigenvectors*). Los valores propios corresponden a la longitud de cada componente y los vectores propios corresponden a los coeficientes por los cuales se pondera cada banda y/o índice.

4.5 CLASIFICACIÓN Y VERIFICACIÓN DE RESULTADOS

Para la identificación automatizada de las categorías presentes en cada imagen, se siguió el siguiente esquema (Parra, 2014):

- Identificación de categorías o clases temáticas.
- Selección de áreas representativas en la imagen – muestras de entrenamiento.
- Análisis de separabilidad entre clases.
- Fase de asignación.
- Verificación de resultados.

Las clases temáticas se identificaron y definieron a partir de la interpretación preliminar.

Posteriormente se seleccionaron áreas representativas y homogéneas para cada clase. Estas muestras se seleccionaron siguiendo lo expresado por (Parra, 2014), en cuanto al número de pixeles mínimo por categoría así como a la distribución de las muestra abarcando las variaciones espaciales que puedan presentarse en cada categoría.

La fase de asignación donde cada pixel será asignado a una clase *i*, si sus niveles digitales se encuentran dentro del dominio identificado para esa clase, con base en criterios estadísticos. En este estudio se empleó el algoritmo de Máxima verosimilitud (*Maximum Likelihood*), muy empleado en teledetección dada la robustez y ajuste riguroso a la disposición original de los datos (Parra, 2014).

La verificación de resultados se realizó a partir de la matriz de confusión, que almacena los conflictos entre clases. La diagonal de la matriz expresa el acuerdo entre la realidad y la imagen clasificada, los marginales (celdas por fuera de la

diagonal) corresponden con los errores de asignación. Se utilizaron seis indicadores para evaluar la exactitud de la clasificación: exactitud del productor, exactitud del usuario, error de omisión, error de comisión, exactitud general, coeficiente Kappa (Khorram et al., 2012), (Parra, 2014).

En la Figura 5 se muestra el flujo de trabajo establecido para el desarrollo del estudio que se presenta.

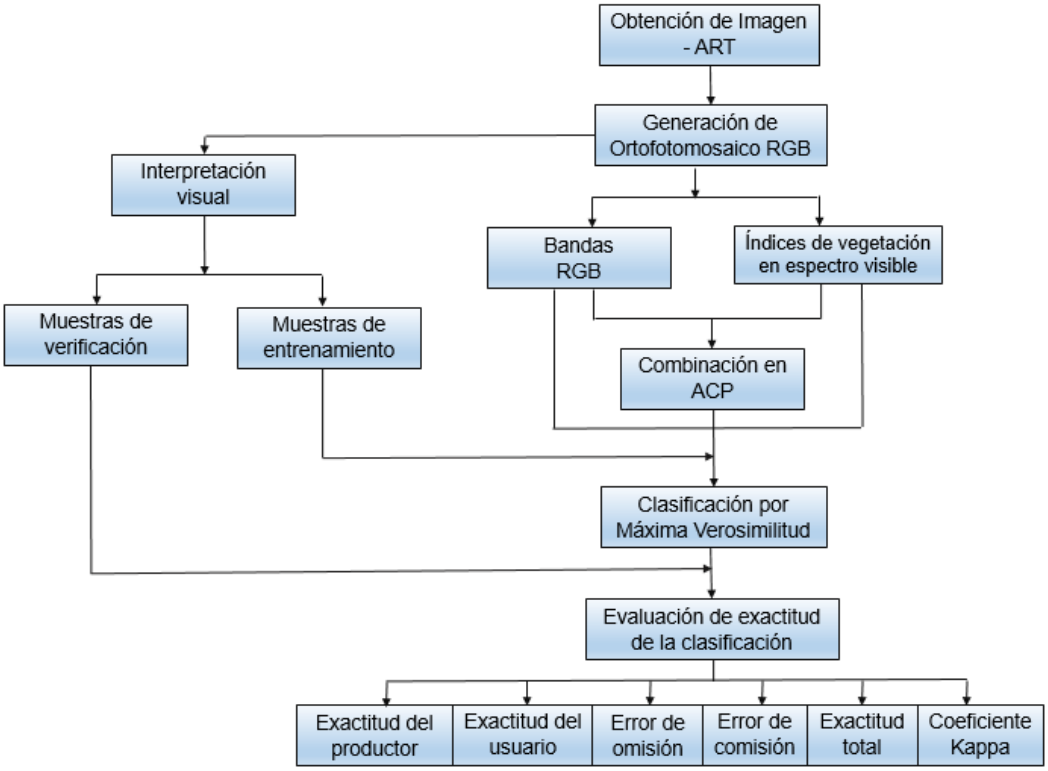

Figura 5. Flujo de trabajo establecido para la identificación del volcamiento de maíz a partir de imágenes RGB.

5 RESULTADOS Y DISCUSIÓN

5.1 IMÁGENES / ORTOFOTOMOSAICOS

Se obtuvo un total de 12 ortofotomosaicos con una temporalidad entre el 3 de septiembre y el 23 de noviembre del año 2018 (Figura 6), los cuales cuentan con bandas en el rango del espectro visible (RGB), el tamaño de pixel resultante varía entre 1,6 - 1,7 cm. Se seleccionó la imagen del 5 de noviembre por ser la primera imagen en la cual se identificó la presencia del fenómeno de volcamiento del maíz (Figura 7).

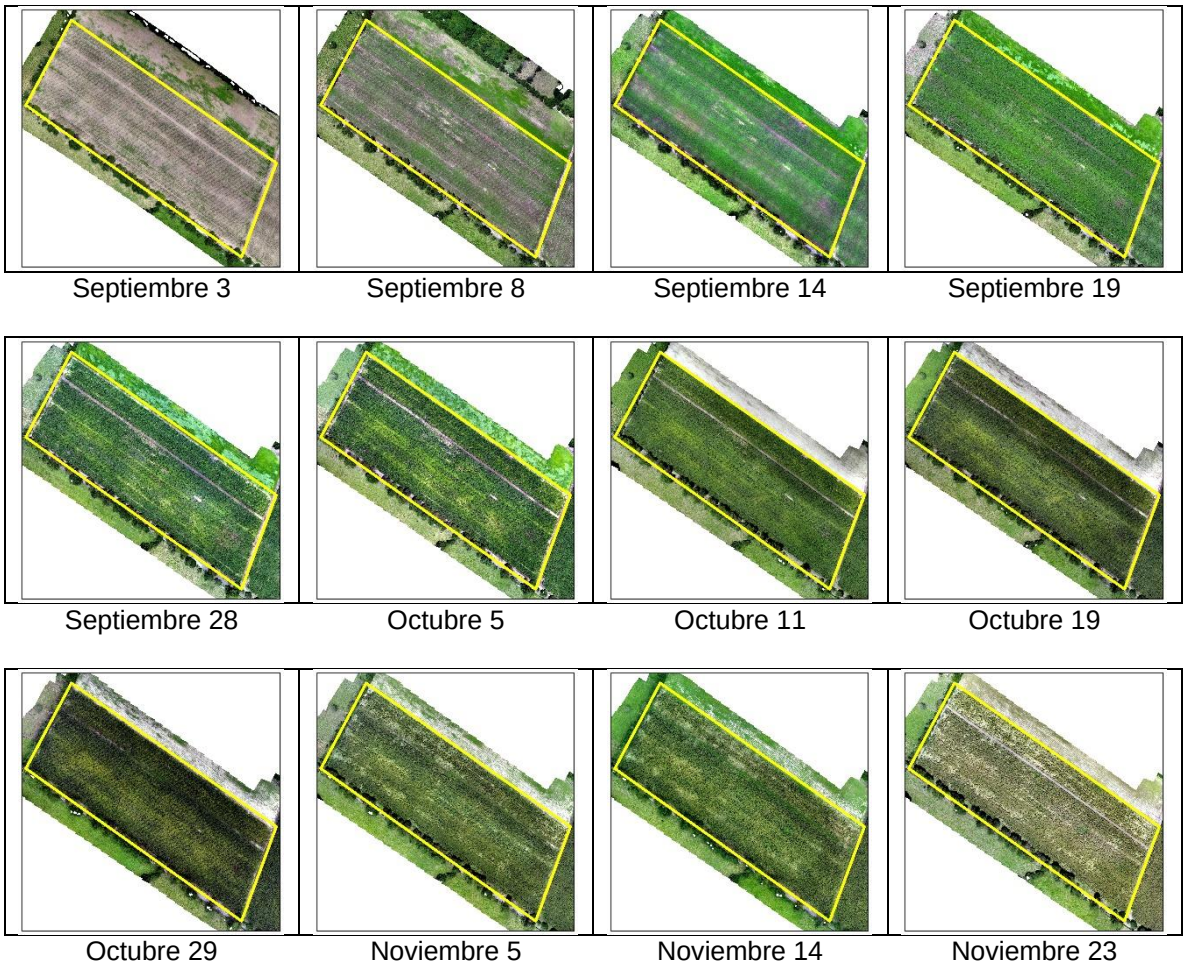

Figura 6. Ortoimágenes en color verdadero obtenidas para el cultivo de maíz de la granja Montelindo, segundo semestre - 2018.

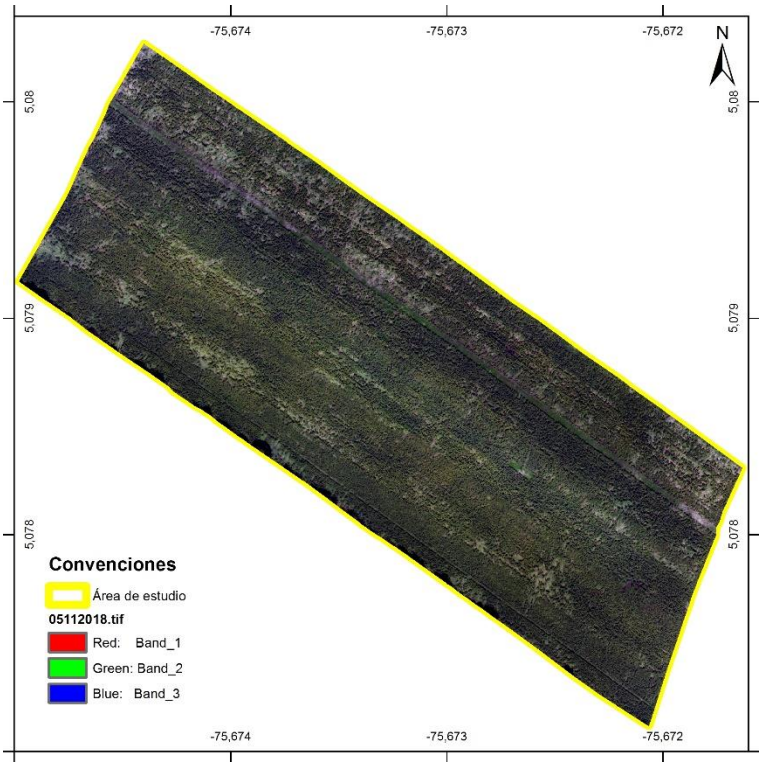

Figura 7. Ortoimagen en color verdadero del cultivo de maíz para el 5 de noviembre del 2018.

En la Tabla 5 se presentan los estadísticos básicos de la imagen RGB obtenida y sobre la cual se realizó el estudio.

Tabla 5. Estadísticos básicos de la imagen RGB para el 5 de noviembre.

BANDA	MÍNIMO	MÁXIMO	MEDIA	DESVIACIÓN ESTÁNDAR	COEFICIENTE DE VARIACIÓN
Red (rojo)	0	255	188,01	74,92	0,398
Green (verde)	6	255	196,13	66,01	0,337
Blue (azul)	5	255	180,54	82,78	0,459

De acuerdo con los valores obtenidos para el coeficiente de variación (Tabla 5), éste presenta valores más altos para la banda azul (45,9%) con respecto a las bandas rojo (39,8%) y verde (33,7%), indicando mayor variabilidad de niveles en la banda azul.

5.2 INTERPRETACIÓN VISUAL

Aplicando las técnicas de interpretación visual fue posible identificar cinco clases de cobertura, algunas no se habían contemplado desde el inicio, pero dada su manifestación en la imagen, y a que éstas producen respuestas diferenciadas, se hizo necesario realizar su separación, además sus patrones de rugosidad, color y tono las hacen fácilmente diferenciables de las demás categorías consideradas desde el inicio, estas fueron: Malas hierbas, Sombra, Suelo. A continuación, se describen sucintamente las categorías identificadas en el ortofotomosaico.

Caracterización de clases identificadas:

Maíz en pie: corresponde con maíz que al momento de la toma de la imagen se encuentra erecto, dada la perspectiva de vista en planta, se puede apreciar la arquitectura de la planta donde se distinguen las hojas y se puede evidenciar su disposición alterna en el tallo, además se puede observar el traslape entre hojas de diferentes plantas entre hileras (Figura 8 a).

Maíz volcado: dado que el volcamiento implica caída de las plantas al piso, en algunos casos se observan fácilmente los tallos en sentido horizontal, las hojas manifiestan alta reflectividad (Figura 8 b).

Malas hierbas o malezas: se considera malas hierbas a aquellas plantas que crecen en lugares no deseados en medio de los cultivos y que además su presencia puede causar perjuicios económicos. También se considera como maleza una planta poco familiar, indeseable o fuera de sitio. Corresponde a sitios en los cuales se observó presencia de plantas invasoras, las cuales son fácilmente diferenciables especialmente por sus patrones de textura, color y forma (Figura 8 c).

Suelo: se identifica como aquellas áreas que se encuentran desprovistas de vegetación, puede estar dentro del cultivo o en zona externa como camino de separación de lote (Figura 8 d).

Sombra: se caracteriza por bajos valores de reflectividad en las tres bandas, donde los pixeles se observan en tonos casi negros, pueden corresponder a sombra proyectada de los árboles (localizados al margen de la imagen) o a zonas dentro del cultivo con sombra de las hojas proyectada sobre el suelo por lo que no permite percibir directamente el suelo o elementos de éste (Figura 8 e).

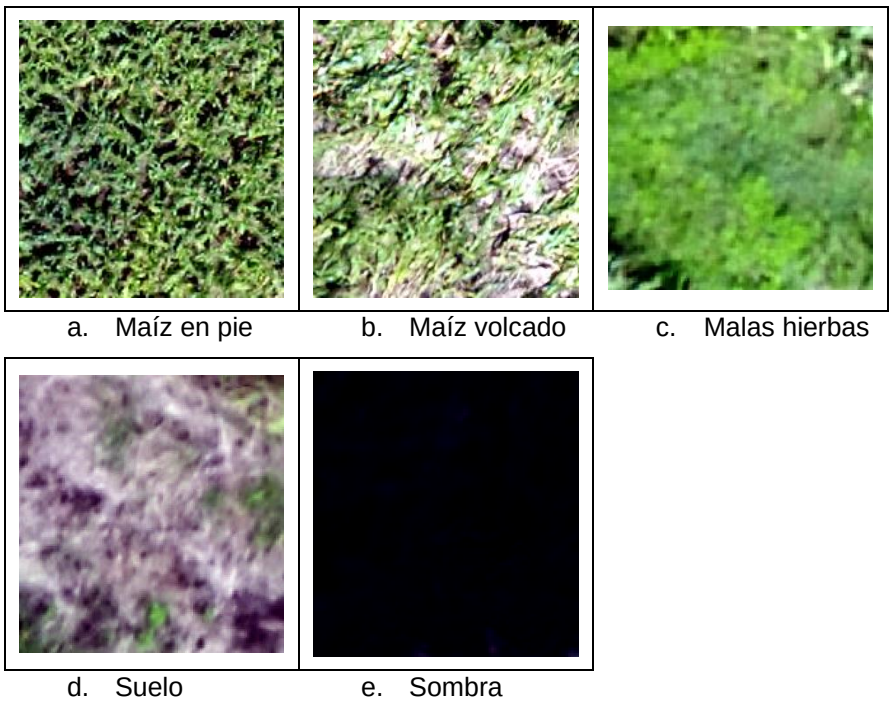

Figura 8. Visualización en color verdadero (RGB) de cada categoría de cobertura.

La Tabla 6 muestra datos preliminares de áreas obtenidos luego de aplicar las técnicas de interpretación visual. Dado el interés de la interpretación preliminar, los datos que se relacionan se consideran indicativos, se presentan con el fin de mostrar el cubrimiento aproximado de cada categoría, especialmente las categorías de Maíz volcado y Maíz en pie; el área en sombra está subestimado dado que son áreas muy pequeñas, la gran mayoría al interior del cultivo por la sombra proyectada de las hojas de maíz en el suelo, se identifican claramente las áreas de sombra que se localizan en el borde de la imagen y que corresponden a sombras de árboles externos al cultivo. De acuerdo con (Richards, 2013) la fotointerpretación se realiza por parte de un analista humano, y generalmente funciona a una escala mucho mayor que el pixel individual de una imagen por lo tanto el enfoque se realiza a nivel general y se pueden tomar decisiones acerca del contexto, el tamaño, la forma, la proximidad, elementos que pueden no ser tan sencillos de considerar en un análisis automatizado.

Tabla 6. Área preliminar de cada clase de cobertura identificada en el cultivo de maíz para la fecha de interés.

CLASE	ÁREA (m^2)	PORCENTAJE (%)
Maíz en pie	33.839,3	79,56
Maíz volcado	6.922,5	16,28
Malas hierbas	809,9	1,90
Suelo	456,3	1,07
Sombra	504,4	1,19

Como se mencionó previamente, la imagen analizada corresponde con el primer ortofotomosaico en el cual se identificó plenamente el fenómeno de volcamiento, para ese momento se presentó una afectación en aproximadamente 6.922 m^2 correspondientes al 16,28% del cultivo. En la Figura 9a se puede observar la distribución de cada una de las categorías identificadas y en la Figura 9b se observa la distribución de la categoría Maíz volcado con la imagen RGB de referencia. Se puede observar la gran afectación en el sector noreste del cultivo; tomando en consideración que para la fecha anterior de la cual se contó con mosaico corresponde al 29 de octubre del 2018, es decir siete días, se pone en evidencia la magnitud de las afectaciones que puede generar el fenómeno, cuando en tan solo siete días se pudo ver afectada casi la quinta parte del cultivo y por consiguiente los rendimientos y la productividad debidos a esta condición, al momento de la cosecha final se cuantificaron pérdidas considerables para la Granja Montelindo.

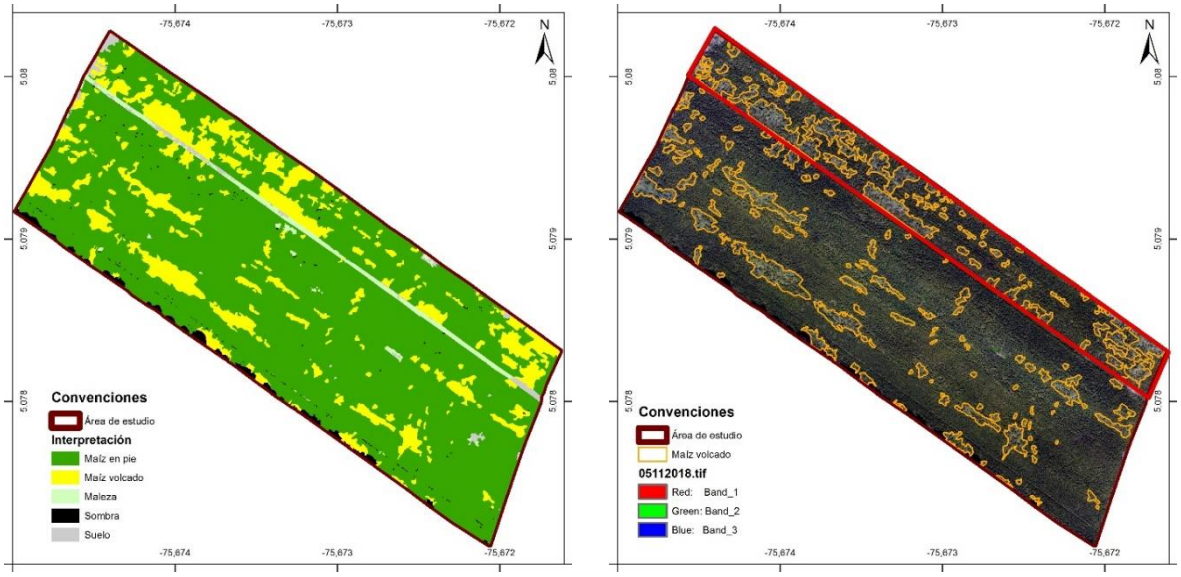

a. Categorías identificadas en la imagen b. Maíz volcado en la interpretación

Figura 9. Identificación de categoría de cobertura en la imagen RGB obtenidas por interpretación visual.

5.3 MUESTRAS DE ENTRENAMIENTO Y VERIFICACIÓN

La clasificación de imágenes se define como el proceso en el cual los pixeles de una imagen datos provenientes de sensores remotos se categorizan, para obtener un conjunto dado de temas de cobertura terrestre (Al-doski et al., 2013). El algoritmo de Máxima Verosimilitud es un clasificador rígido que se basa en parámetros estadísticos, en el cual el componente supervisado está referido a las clases que se definen en las muestras de entrenamiento por parte del interesado. De acuerdo con (Al-doski et al., 2013) y (Parra, 2014) cada muestra definida debe ser lo más homogénea posible pero a su vez debe recoger todo el rango de variabilidad de cada clase. A partir de la interpretación visual realizada se seleccionaron las muestras de entrenamiento y las muestras que posteriormente se emplearon para verificación, todas fueron ubicadas al azar y de forma tal que se cubriera la totalidad de sectores de la imagen (Figura 10).

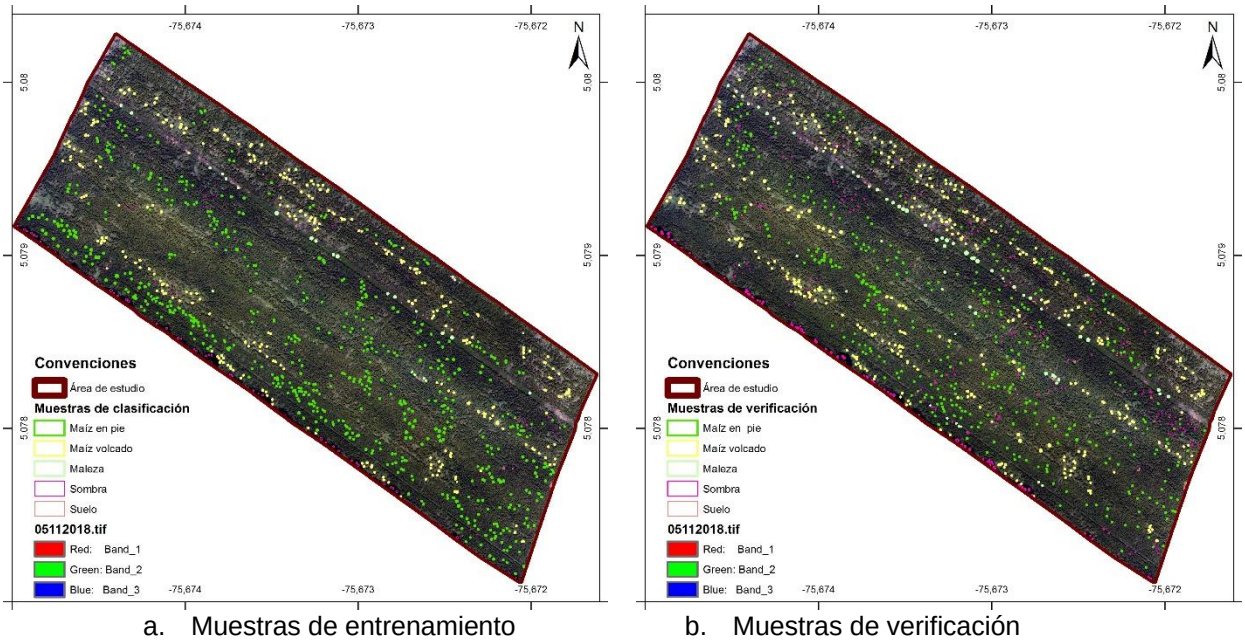

a. Muestras de entrenamiento b. Muestras de verificación

Figura 10. Distribución de muestras de entrenamiento y de verificación.

Las muestras identificadas varían en tamaño y dado que la unidad de clasificación es el pixel, se obtuvo la cantidad total de pixeles para cada categoría de cobertura a clasificar (Tabla 7).

Tabla 7. Cantidad de pixeles para las muestras de entrenamiento y verificación.

COBERTURA	MUESTRAS DE ENTRENAMIENTO	MUESTRAS DE VERIFICACIÓN
Maíz en pie	547.321	225.962
Maíz volcado	186.607	296.675
Mala hierba	48.806	132.076
Sombra	133.739	156.125
Suelo	49.909	63.887

Con el fin de identificar el comportamiento en el espectro visible de cada cobertura, se extrajeron los estadísticos básicos de cada categoría tomando el conjunto total de pixeles de entrenamiento, de forma tal que se obtuvieron los diferentes estadísticos (Anexo 1). El comportamiento espectral de las coberturas vegetales de maíz en pie, maíz volcado y malas hierbas es coherente con la curva espectral de la vegetación, donde para la banda verde se tienen valores más alto que para las bandas rojo y azul (Figura 11). Con respecto al maíz volcado se tienen, en todas las bandas, valores más altos de ND que para el maíz en pie (maíz no volcado), la principal razón para que esto ocurra es que el volcamiento genera cambios en la estructura y forma del cultivo, ocasionando cambios en la reflectancia espectral del dosel, hay tallos expuestos y estos tienen una reflectancia mayor que la de la hoja (Sun et al., 2019).

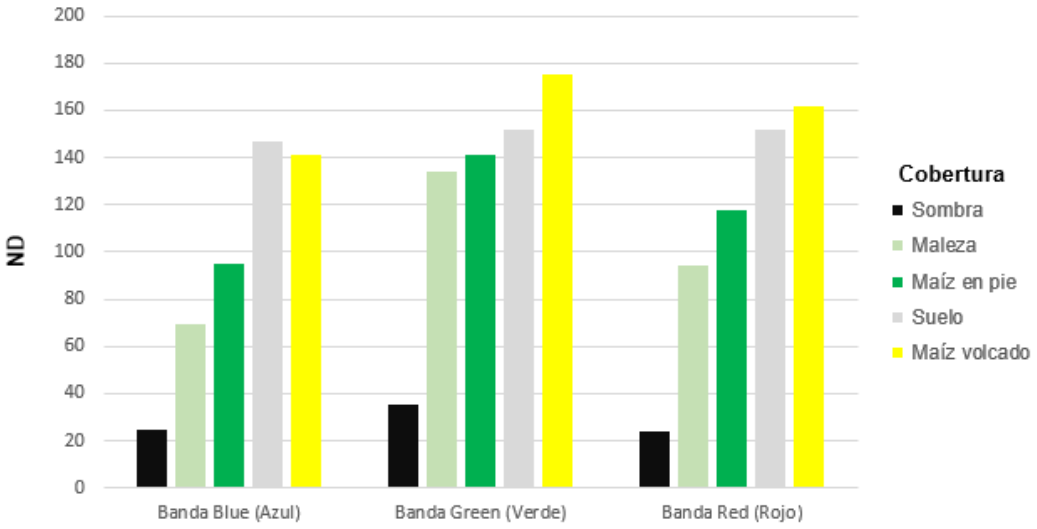

Figura 11. Características espectrales de las muestras de entrenamiento para cada categoría de cobertura.

Para las coberturas de maíz en pie y malas hierbas, se observan valores más bajos en la banda azul, esto está en concordancia con (Metternicht, 2003), quien expresa

que en estudios previos se reporta que los pigmentos foliares como las clorofilas y los carotenoides presentan picos de absorción alrededor de los 450 nm por lo tanto, el dosel altamente pigmentado presentaría una fuerte absorción en la banda azul, traducida como números digitales más bajos en dicha banda.

5.3 GENERACIÓN DE ÍNDICES ESPECTRALES

Los índices de vegetación son una combinación lineal o no lineal de dos o más bandas, que refleja la abundancia relativa y la actividad de la vegetación verde. El propósito principal de establecer índices de vegetación es sintetizar de manera efectiva las señales espectrales relevantes, mejorar la información de la vegetación y reducir la información no relacionada con la vegetación (Sun et al., 2019). (Bannari et al., 1995) expresan que cada índice, en sí mismo, es un indicador de vegetación verde, y estos no tienen un valor estándar universal, entre los factores que pueden afectar los índices se encuentran la atmósfera, la calibración del sensor, las condiciones de visualización del sensor, la geometría de la iluminación solar, la humedad del suelo, el color y el brillo.

Se generaron cuatro índices de vegetación empleando el espectro visible. En la Tabla 8 se presentan los estadísticos para cada índice calculado.

Tabla 8. Estadísticos de los índices calculados.

BANDA/ÍNDICE ESPECTRAL	MÍNIMO	MÁXIMO	MEDIA	DESVIACIÓN ESTÁNDAR	COEFICIENTE DE VARIACIÓN
GRVI	-1	1	0,0992	0,0916	0,923
PPR	-1	1	0,21135	0,137157	0,649
GLI	-1	1	0,1508	0,10242	0,679
VARI	-1	1	0,1498	0,1340	0,895

De acuerdo con los valores de coeficiente de variación obtenidos para cada índice en la imagen completa (Tabla 8), se tiene que los cuatro índices presentan en general valores altos a muy altos (64,9% - 92-3%), presentándose valores muy altos en los índices GRVI y VARI con valores de 92,3% y 89,5% respectivamente, indicando una relativa alta variabilidad de éstos dentro de la imagen.

A partir de las muestras de entrenamiento, se calcularon los estadísticos básicos de los índices para cada cobertura (Anexo 2), en la Figura 12 se presenta el comportamiento de cada cobertura en las muestras de entrenamiento dentro de cada índice.

De acuerdo con (Metternicht, 2003), el Índice de Vegetación Verde-Rojo o Relación de vigor fotosintético GRVI, muestra valores altos en las zonas fotosintéticamente activas, en este caso corresponden con las zonas de malas hierbas y maíz en pie, donde hay fuerte absorción en la banda roja y reflejo en la banda verde, los valores bajos indican vegetación poco activa por deficiencias en nutrientes, estrés o estados iniciales de senescencia, correspondiendo con las zonas de maíz volcado. (Barbosa et al., 2019) encontraron que este índice (denominado MPRI en su estudio) fue el índice más adecuado para evaluar la variabilidad de la vegetación y la cobertura del suelo, ya que proporcionó la mejor distinción visual entre estas variables.

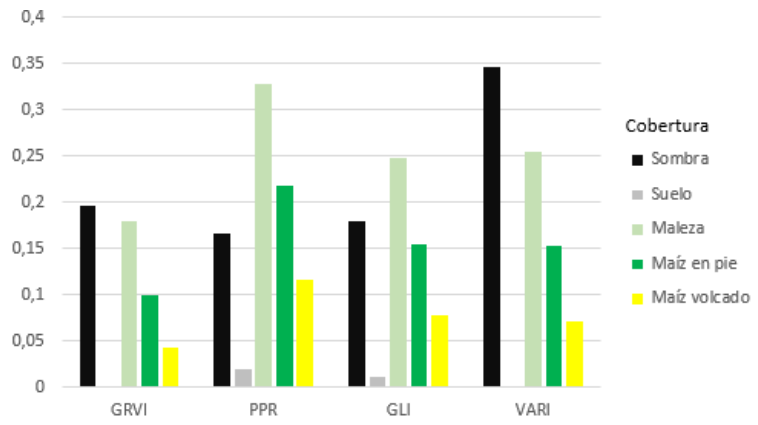

Figura 12. Comportamiento de las coberturas (muestras de entrenamiento) en cada índice.

El índice de proporción de pigmentos o índice de vegetación vede-azul PPR produce una imagen en la cual el follaje fuertemente pigmentado presenta un valor alto (Metternicht, 2003), lo cual concuerda con las áreas de malas hierbas y maíz en pie, mientras que el follaje débilmente pigmentado tiene un PPR bajo, correspondiendo en este caso con el maíz volcado.

Con respecto al índice de hoja verde GLI (Louhaichi et al., 2001), identificaron que éste varía entre -1 y +1, donde los valores negativos tienden a ser suelo o elementos inertes, los valores positivos se relacionan con hojas y tallos verdes, los autores pudieron establecer, en la mayoría de los casos, un umbral con valor cercano a 0 para obtener dos clases y separar suelo/elementos inertes de elementos de hojas verdes. En el estudio conducido por (Barbosa et al., 2019) este índice les proporcionó efectividad en identificación de suelos expuestos y no fue eficiente para el realce de la vegetación.

El Índice visible de resistencia a la atmósfera VARI (Gitelson et al., 2002) está diseñado para resaltar la vegetación en la parte visible del espectro, dado que es mínimamente sensible a los efectos atmosféricos favorece la estimación de la fracción de vegetación, en este caso los cultivos pueden ser analizados en todas las etapas de desarrollo. De acuerdo con (Costa et al., 2020) este índice es uno de los índices más utilizados para recopilar datos de la vegetación utilizando solo una cámara RGB.

Los índices no están desarrollados, en general, para identificar las sombras en la imagen, sino los elementos de suelo y vegetación, las sombras, finalmente son suelo que por la configuración del cultivo las hojas proyectan su propia sombra sobre éste, por lo que las categorías de suelo y sombra podrían agruparse en una misma categoría. En la Figura 13 se presenta la representación de cada índice.

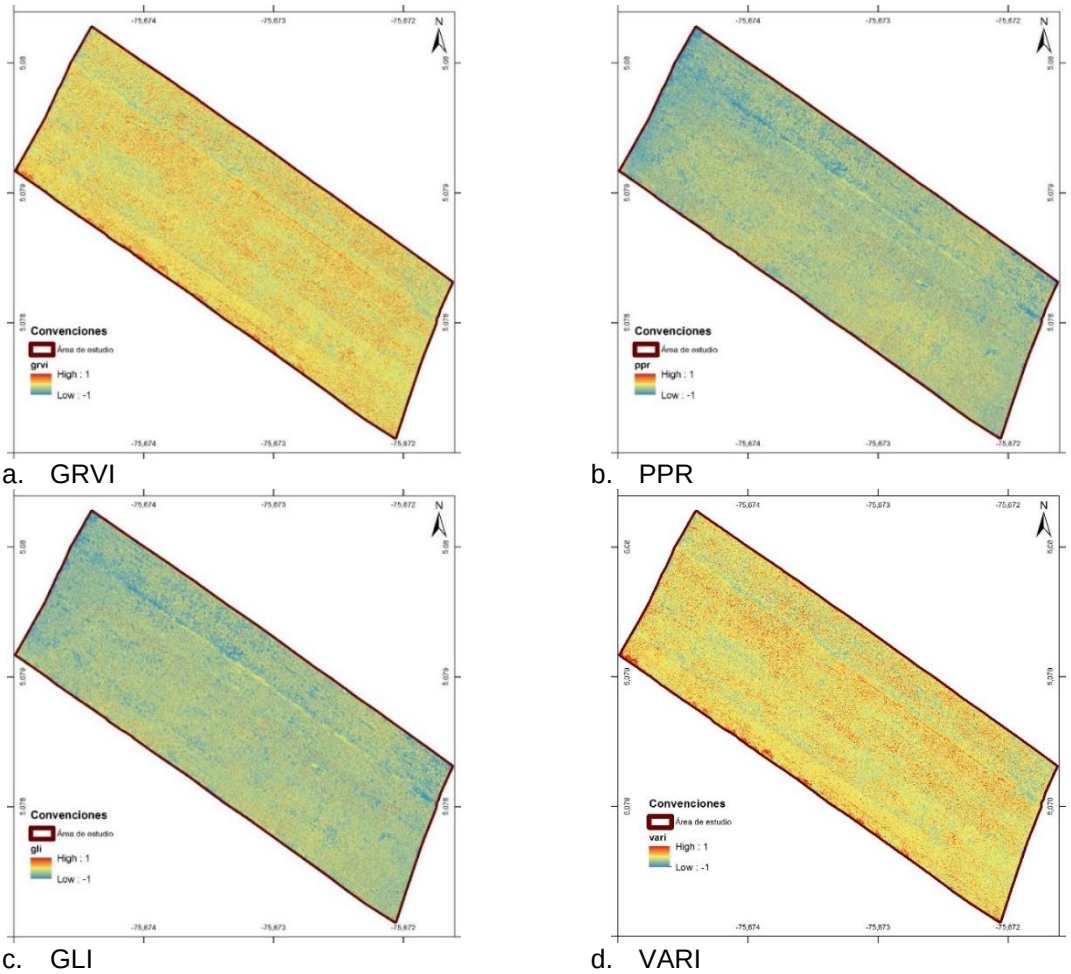

Figura 13. Índices espectrales obtenidos a partir de la imagen RGB.

5.4 ANÁLISIS DE COMPONENTES PRINCIPALES

Dada la cantidad de información que se obtuvo se generó el análisis de componentes principales, que tiene como finalidad reducir la dimensionalidad de las variables (Ferrero et al., 2002), al comprimir los datos por eliminación de la redundancia, y de esa forma se obtienen además componentes no autocorrelacionados. El análisis de componentes principales se generó en tres vías, 1. Para las bandas espectrales RGB, 2. Para los cuatro índices espectrales calculados, y 3. Para las bandas RGB y los índices espectrales calculados.

5.4.1 ACP de bandas espectrales RGB

Empleando las tres bandas de la imagen RGB, se generó el análisis de componentes principales (ACP), se obtuvieron entonces tres CP con sus respectivos vectores y valores propios (Tabla 9).

Tabla 9. Vectores y valores propios para los componentes principales de las bandas RGB.

CAPA	C1	C2	C3
R	0,57947	0,12429	-0,80546
G	0,51397	0,71126	0,47952
B	0,63249	-0,69185	0,34827
Valor propio	17.841,71468	120,25927	22,79265
Porcentaje	99,2046	0,6687	0,1267
Porcentaje acumulado	99,2046	99,8733	100,00

De la Tabla 9 se observa que el componente 1 (CP1) explica el 99,20% de la variabilidad de los datos incorporados en el ACP. El segundo componente (CP2) almacena un 0,66% de variación y que no se encuentra descrita por el CP1, representando un valor marginal. Para cada componente se resaltó la banda con la que más se encuentra relacionado cada CP, lo cual se identifica a partir del valor absoluto de los vectores propios (Ferrero et al., 2002). Para el CP1 es la banda Azul, para el CP2 la banda Verde, y para el CP3 la banda Roja. Dados los resultados obtenidos, se emplearon los componentes 1 y 2 para el proceso de clasificación que se desarrolla más adelante.

5.4.2 ACP de índices espectrales

Empleando los cuatro índices espectrales calculados, se generó el análisis de componentes principales (ACP), se obtuvieron entonces cuatro componentes con sus respectivos vectores y valores propios (Tabla 10).

Tabla 10. Vectores y valores propios para los componentes principales de los índices espectrales.

ÍNDICE	C1	C2	C3	C4
GRVI	0,40544	-0,22674	-0,74256	-0,48251
PPR	0,56388	0,67534	0,32630	0,34568
GLI	0,47095	0,17234	-0,31824	0,80450
VARI	0,54394	-0,68030	0,49078	0,02146
Valor propio	0,01850	0,00374	0,00029	0,00001
Porcentaje	82,0684	16,5925	1,3036	0,0355
Porcentaje acumulado	82,0684	98,6608	99,9645	100,0000

De la Tabla 10 se observa que el componente 1 (CP1) explica el 82,07% de la variabilidad de los datos incorporados en el ACP. El segundo componente (CP2) almacena un 16,59% de variación y que no se encuentra descrita por el CP1, el tercer componente (CP3) explica un 1,30% de variabilidad que no ha sido explicada aún, y este valor se considera ya marginal. Para cada componente se resaltó la banda con la que más se encuentra relacionado cada CP, lo cual se identifica a partir del valor absoluto de los vectores propios (Ferrero et al., 2002). Para el CP1 es el índice PPR, para el CP2 el VARI, para el CP3 el GRVI y finalmente para el CP4 se tiene el GLI. Dados los resultados obtenidos, se emplearon los componentes 1, 2 y en el proceso de clasificación que se desarrolla más adelante.

5.4.3 ACP de bandas espectrales e índices espectrales

Empleando las tres bandas en el espectro visible RGB y los cuatro índices espectrales calculados, se generó el análisis de componentes principales (ACP), se obtuvieron entonces cuatro CP con sus respectivos vectores y valores propios (Tabla 11). Debido a la alta variabilidad en los datos y escalas de clasificación de cada índice calculado, se siguió un proceso de estandarización previo a la incorporación en el análisis de componentes principales de los índices.

Tabla 11. Vectores y valores propios para los componentes principales de las bandas del espectro visible y los índices espectrales.

BANDA/ÍNDICE	C1	C2	C3	C4	C5	C6	C7
R	0,53522	0,21863	0,24883	0,17854	-0,75578	-0,02690	0,00462
G	0,52207	0,42341	0,00969	-0,65724	0,34049	-0,01157	-0,00659
B	0,50279	0,08265	-0,32165	0,67041	0,43099	0,04120	0,00392
GRVI	-0,18739	0,36192	-0,73474	-0,05609	-0,26686	-0,46634	-0,04714
PPR	-0,31035	0,63396	0,51001	0,28474	0,21084	-0,34060	-0,01122
GLI	-0,23820	0,48286	-0,18468	0,04906	-0,10691	0,81283	0,03840
VARI	-0,00418	0,00710	-0,02169	-0,00913	-0,00207	-0,05724	0,99805
Valor propio	0,04339	0,00740	0,00166	0,00041	0,00012	0,00001	0,00000
Porcentaje	81,9018	13,9585	3,1266	0,7757	0,2226	0,0144	0,0005
Porcentaje acumulado	81,9018	95,8603	98,9869	99,7625	99,9851	99,9995	100,0000

De la Tabla 11 se observa que el componente 1 (CP1) explica el 81,90% de la variabilidad de los datos incorporados en el ACP. El segundo componente (CP2) almacena un 13,96% de variación y que no se encuentra descrita por el CP1, el tercer componente (CP3) explica un 3,13% de variabilidad que no ha sido explicada aún, a partir del cuarto CP se presentan aportes marginales. Para cada componente se resaltó la banda con la que más se encuentra relacionado cada CP, lo cual se identifica a partir del valor absoluto de los vectores propios (Ferrero et al., 2002). Para el CP1 es la banda roja, para el CP2 el índice PPR, para el CP3 el índice GRVI. Dados los resultados obtenidos, se emplearon los componentes 1, 2 y 3 en el proceso de clasificación que se desarrolla más adelante.

5.5 CLASIFICACIÓN Y VERIFICACIÓN DE RESULTADOS

Con base en las características espectrales de la imagen RGB, los índices de vegetación en el espectro visible y los componentes principales, se generó la clasificación para cada uno de estos por el método de máxima verosimilitud, con el fin de obtener el maíz volcado y no volcado (maíz en pie), malas hierbas, suelo y sombras. Se emplearon las muestras de entrenamiento previamente generadas (Parra, 2014). La resolución de la imagen de estudio es de 1,7 cm y los resultados conservan este nivel de resolución, dado que no se generaron procesos de remuestreo. Obtenidos los resultados del proceso de clasificación, se aplicó un filtro de mayoría con el fin de que los pixeles aislados fueran asignados a la categoría adyacente basado en la mayoría de pixeles en la ventana de análisis o vecindario (Parra, 2014), este proceso no afecta la resolución espacial ni la escala de análisis.

En la Figura 14a se presenta la imagen RGB con combinación en color verdadero y la identificación de las zonas identificadas en maíz volcado a partir de la interpretación visual, se resalta la zona del cultivo en la cual se localizan las áreas más extensas y concentradas de volcamiento. Las zonas donde se encuentra el maíz con volcamiento son fácilmente identificables en esta imagen y claramente diferenciables del maíz en pie. Así mismo se pueden identificar las malas hierbas, el suelo y las sombras. En la imagen analizada se evidencia una clara presencia del fenómeno del volcamiento, el cual se localiza a lo largo y ancho de todo el cultivo abarcando áreas desde 2 m^2 aproximadamente como área mínima hasta casi 900 m^2 y abarca aproximadamente el 17% del área del cultivo analizado.

En las figuras Figura 14b - Figura 14e se muestran los resultados obtenidos para los cuatro procesos de clasificación realizados. Se puede observar que para las clasificaciones de la imagen RGB, sus componentes principales, los índices espectrales y los componentes principales de la imagen RGB con los índices de vegetación aplicados existen errores en la asignación de categoría, donde se clasifica maíz volcado en zonas donde claramente se tiene maíz en pie, y también se da el caso de pixeles clasificados como suelo donde se presenta maíz volcado, esto está relacionado con el planteamiento de (López Carvajal, 2016) se debe tener en cuenta la alta heterogeneidad espectral al interior de los objetos, y simultáneamente la similaridad espectral entre diferentes objetos.

En la clasificación realizada con base en el análisis de componentes principales de los índices espectrales, se observa una clara sobreestimación del maíz volcado en toda la imagen (Tabla 12). En esta clasificación, también se observa la subestimación que se realiza de las sombras, esto es esperable dado el planteamiento previamente realizado con relación a que los índices no están diseñados para identificar esta característica como tal, sino para determinación de fracción de vegetación

Aunque el maíz volcado presenta sobreestimaciones en las dos primeras clasificaciones con respecto al valor estimado por la interpretación visual, la localización de las áreas globales son más consistentes en estas dos clasificaciones que en las otras dos (ACP de índices y ACP RGB-Índices), dado que los pixeles clasificados como maíz volcado y que realmente pertenecen a otras categorías se encuentran disperso por toda la imagen y no agrupados en zonas indicativas como tal de maíz volcado, es probable que en nuevos post-procesos de generalización de información, por ejemplo en un sistema de información geográfica, muchos de estos pixeles, sean incorporados en una categoría adyacente de mayor área.

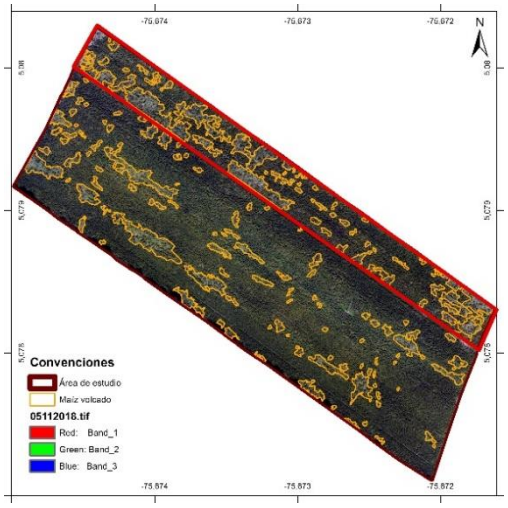

a. Imagen RGB con maíz volcado

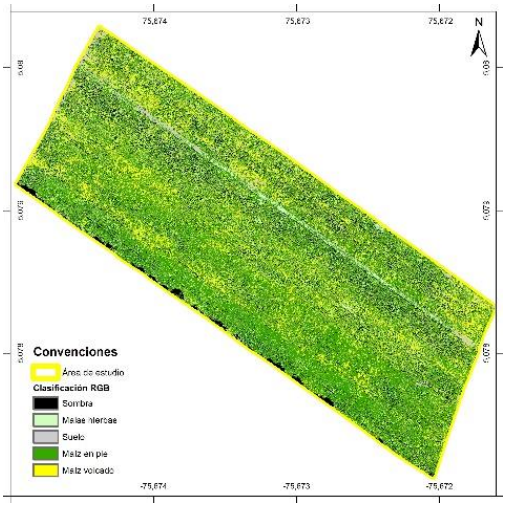

b. Clasificación de imagen espectral

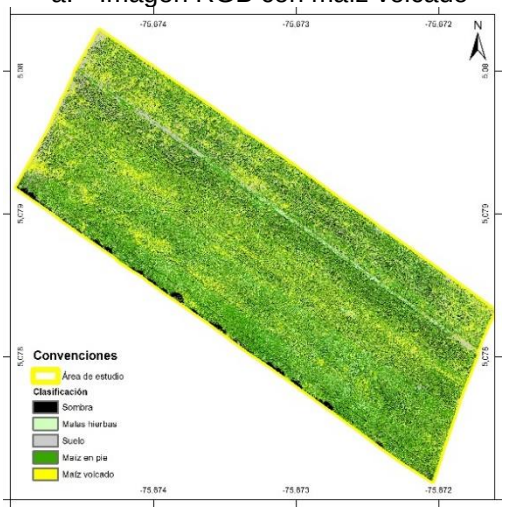

c. Clasificación basada en ACP de la imagen espectral RGB

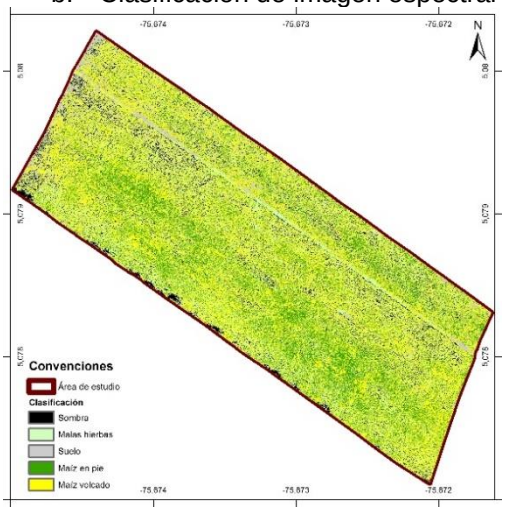

d. Clasificación basada en ACP de índices espectrales

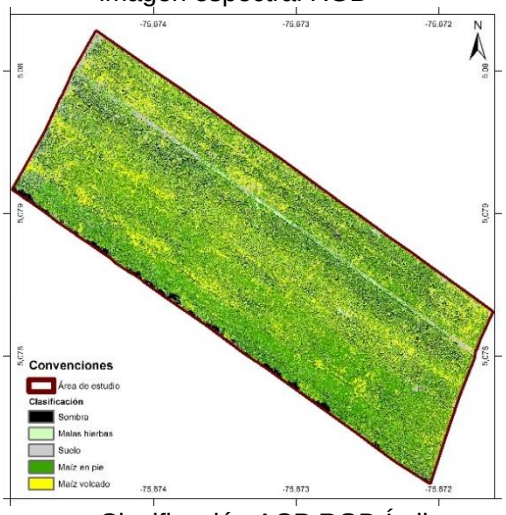

e. Clasificación ACP RGB-Índices

Figura 14. Resultados de clasificación supervisada.

Tabla 12. Área de las diferentes categorías de coberturas en las diferentes clasificaciones efectuadas.

COBERTURA	IMAGEN ESPECTRAL	ACP DE IMAGEN ESPECTRAL	ACP ÍNDICES ESPECTRALES	ACP BANDAS E ÍNDICES
Maíz en pie	21.653,41	19.712,34	7.735,96	18.633,63
Maíz volcado	8.204,50	7.966,51	18.709,89	10.380,87
Maleza	3.232,68	4.905,21	8.806,36	3.448,29
Sombra	4.503,05	5.117,77	2.727,03	5.104,79
Suelo	3.441,54	3.333,36	3.055,95	3.467,61
Total	41.035,19	41.035,19	41.035,19	41.035,19

Las clasificaciones realizadas se evaluaron empleando la matriz de confusión (Khorram et al., 2012), (Parra, 2014), esta indica en las columnas las categorías de referencia y en las filas las clases derivadas por el proceso de clasificación. Se calculan los porcentajes de exactitud del usuario y el productor, así como los respectivos errores de comisión y de omisión. Se obtuvieron además los indicadores de exactitud global y coeficiente Kappa (Tabla 13 - Tabla 16).

Clasificación de imagen RGB

Tabla 13. Matriz de confusión para la clasificación de la imagen RGB.

Clasificación	Referencia validación					Total general	Exactitud Usuario (%)	Error comisión (%)
	Maíz en pie	Maíz volcado	Malas hierbas	Sombra	Suelo			
Maíz en pie	193.551	32.772	10.337	382	1.555	238.597	81,12	18,88
Maíz volcado	15.364	237.145	469	65	6.262	259.305	91,45	8,55
Malas hierbas	15.506	1.933	120.668	382	75	138.564	87,08	12,92
Sombra	750	504	154	153.776	278	155.463	98,92	1,08
Suelo	791	24.320	448	1.520	55.716	82.796	67,29	32,71
Total general	225.962	296.675	132.076	156.125	63.887	874.724		
Exactitud Productor (%)	85,66	79,93	91,36	98,50	87,21	**Exactitud total (%)**		86,98
Error de omisión (%)	14,34	20,07	8,64	1,50	12,79	**Coeficiente Kappa**		0,83

En la clasificación de la imagen espectral se observa altos valores de exactitud de usuario y productor (Tabla 13) para las categorías de sombra y maleza, siendo

sombra la categoría que menores errores de omisión y comisión reporta. Las características espectrales de las sombras son bastante contrastante con respecto a las de maíz (volcado y en pie) y las malas hierbas. Con respecto al maíz volcado, desde la perspectiva del usuario, se tuvo una exactitud del 91,45%, la cual es más alta que la que se obtuvo para maíz en pie, el error de comisión fue tan solo de 8,55% indicando que del total clasificado como maíz volcado, el porcentaje señalado pertenece realmente a otras categorías (preponderantemente maíz en pie y luego suelo). Desde la perspectiva del productor, para el maíz volcado se tuvo una exactitud del 79,93% indicando que del total del total de maíz volcado identificado en las muestras de verificación, el 20% de los pixeles fueron clasificados como maíz en pie y suelo principalmente. Esto se da por dos razones, el maíz ha caído al suelo en fecha reciente, en algunas zonas las hojas no han perdido el vigor al momento de la toma de la imagen, y allí el algoritmo las clasifica como maíz en pie, por otro lado, cuando se observa un volcamiento muy agresivo los tallos quedan expuestos por la caída y es allí donde la reflectancia aumenta y puede confundirse con suelo expuesto.

La exactitud global de la clasificación fue del 86,98% indicando que la clasificación es fiable para identificar el volcamiento de maíz en imágenes espectrales de alta resolución.

(Sun et al., 2019) identificaron diferentes grados de volcamiento de maíz (sin volcamiento, ligero, moderado, severo) con una imagen multiespectral (con banda NIr) adquirida con un sensor Parrot Sequia, los autores obtuvieron errores de omisión entre 13,43% - 25,88%, y errores de comisión entre 13,52% - 28,28% para la imagen multiespectral.

Clasificación de componentes principales imagen RGB

Tabla 14. Matriz de confusión para la clasificación de componentes principales de la imagen RGB.

Clasificación	Referencia validación					Total general	Exactitud Usuario (%)	Error comisión (%)
	Maíz en pie	Maíz volcado	Malas hierbas	Sombra	Suelo			
Maíz en pie	194.614	33.159	10.830	319	1.517	240.439	80,94	19,06
Maíz volcado	15.197	236.445	472	36	6.175	258.327	91,53	8,47
Malas hierbas	14.835	1.762	120.176	300	48	137.120	87,64	12,36
Sombra	682	442	150	154.045	281	155.601	99,00	1,00
Suelo	635	24.866	447	1.424	55.865	83.237	67,12	32,88
Total general	225.962	296.675	132.076	156.125	63.887	874.724		
Exactitud Productor (%)	86,13	79,70	90,99	98,67	87,44	**Exactitud total (%)**		87,02
Error de omisión (%)	13,87	20,30	9,01	1,33	12,56	**Coeficiente Kappa**		0,831

En la clasificación de los dos primeros componentes principales de la imagen espectral se observa un comportamiento similar al análisis de la imagen espectral, con altos valores de exactitud de usuario y productor (Tabla 14) para las categorías de sombra y maleza, siendo nuevamente la categoría de sombra la que menores errores de omisión y comisión reporta. Con respecto al maíz volcado, desde la perspectiva del usuario, se tuvo una exactitud del 91,53%, ligeramente superior al análisis espectral y nuevamente se obtiene una exactitud más alta que la obtenida para maíz en pie. El error de comisión fue tan solo de 8,47% indicando que del total clasificado como maíz volcado, el porcentaje señalado pertenece realmente a otras categorías (principalmente maíz en pie y luego suelo). Desde la perspectiva del productor, para el maíz volcado se tuvo una exactitud del 79,70% indicando que del total del total de maíz volcado identificado en las muestras de verificación, el 20,30% de los pixeles fueron clasificados también como maíz en pie y suelo principalmente. El análisis de componentes principales ACP permite resumir entonces la variabilidad de los datos y así emplear menos bandas evitando la redundancia de datos. Se obtuvo una exactitud global de la clasificación del 87,02% indicando que la clasificación a partir de los componentes principales de la imagen espectral de alta resolución es fiable para identificar el volcamiento de maíz en imágenes de alta resolución

(Sun et al., 2019) generaron un análisis de componentes principales sobre la imagen multiespectral capturada con la cámara Sequioa Parrot con el fin de identificar diferentes grados de volcamiento de maíz en, los autores obtuvieron errores de omisión entre 12,5% - 24,57%, y errores de comisión entre 10,71% – 28,34%.

Clasificación de índices en el espectro visible

Tabla 15. Matriz de confusión para la clasificación de componentes principales de los cuatro índices espectrales calculados.

Clasificación	Referencia validación					Total general	Exactitud Usuario (%)	Error comisión (%)
	Maíz en pie	Maíz volcado	Malas hierbas	Sombra	Suelo			
Maíz en pie	90.063	15.592	3.960	1.982	608	112.205	80,27	19,73
Maíz volcado	111.892	207.472	9.683	14.138	10.548	353.733	58,65	41,35
Malas hierbas	21.971	3.163	116.573	21.748	247	163.702	71,21	28,79
Sombra	962	1.412	1.264	101.803	281	105.721	96,29	3,71
Suelo	1.074	69.035	597	16.455	52.204	139.364	37,46	62,54
Total general	225.962	296.675	132.075	156.125	63.887	874.724		
Exactitud Productor (%)	39,86	69,93	88,26	65,21	81,71	**Exactitud total (%)**		64,95
Error de omisión (%)	60,14	30,07	11,74	34,79	18,29	**Coeficiente Kappa**		0,54

En la clasificación de los tres primeros componentes principales empleando los cuatro índices espectrales calculados (Tabla 15), sólo se obtuvo un valor muy favorable para exactitud del usuario, y este corresponde con la categoría de sombras. Para el maíz volcado se obtuvo una exactitud del 58,65% en este indicador, mostrando que el 41,35% que fue clasificado como maíz con volcamiento, realmente pertenece a otras clases (maíz en pie, sombra, y suelo), en este caso se presenta una baja proporción de malas hierbas. La categoría de suelo fue la que presentó mayores valores en el error de comisión, alcanzando el 62,54%, donde un gran porcentaje corresponde realmente a maíz volcado.

Con respecto a la exactitud del productor y su complementario valor de omisión, el maíz en pie fue la categoría que menor exactitud presentó en esta clasificación seguida por las sombras. Para el maíz en pie, en este caso se obtuvo un error de omisión del 30%.

La exactitud total alcanzó el 64,95%, lo cual es un valor bajo considerando el valor de exactitud total obtenido para las clasificaciones antes reseñadas. Además considerando la Figura 14d, donde se aprecia la distribución espacial de las categorías clasificadas, este resultado se podría considerar medianamente aceptable para los fines perseguidos.

Con el fin de obtener el trigo volcado en un cultivo, (Wang et al., 2018) emplearon clasificación no supervisada en un análisis realizado en ocho parcelas de muestreo, los autores realizaron análisis texturales y de índices de color con imágenes RGB, y obtuvieron 91,08% de exactitud del usuario para trigo volcado y para trigo en pie del 86,15%.

Clasificación de componentes principales RGB-Índices espectrales

Tabla 16. Matriz de confusión para la clasificación de componentes principales de las tres bandas RGB y los cuatro índices espectrales empleados.

Clasificación	Referencia validación					Total general	Exactitud Usuario (%)	Error comisión (%)
	Maíz en pie	Maíz volcado	Malas hierbas	Sombra	Suelo			
Maíz en pie	159.269	23.521	23.192	1.050	1.112	208.143	76,52	23,48
Maíz volcado	55.577	228.364	948	494	5.692	291.075	78,46	21,54
Malas hierbas	8.857	1.887	106.242	555	193	117.734	90,24	9,76
Sombra	1.164	2.201	805	152.940	737	157.846	96,89	3,11
Suelo	1.096	40.702	888	1.086	56.154	99.927	56,20	43,80
Total general	225.962	296.675	132.075	156.125	63.887	874.724		
Exactitud Productor (%)	70,48	76,97	80,44	97,96	87,90	**Exactitud total (%)**		80,36
Error de omisión (%)	29,52	23,03	19,56	2,04	12,10	**Coeficiente Kappa**		0,74

Con respecto a la clasificación de los componentes principales empleando las bandas RGB y los índices espectrales calculados, se observa una disminución del orden del 7% en la exactitud total de la clasificación (Tabla 16) con respecto a las clasificaciones de la imagen RGB y los componentes principales de la misma. La categoría de sombra, es nuevamente la categoría que menores errores de omisión y comisión reporta. Con respecto al maíz volcado, desde la perspectiva del usuario, se tuvo una exactitud del 78,46%, y nuevamente se obtiene una exactitud un poco más alta que la obtenida para maíz en pie. El error de comisión fue 21,54%

indicando que del total clasificado como maíz volcado, el porcentaje señalado pertenece realmente a otras categorías (principalmente maíz en pie), pudiendo ser en este caso un efecto de los índices aplicados. Desde la perspectiva del productor, para el maíz volcado se tuvo una exactitud del 76,97% indicando que del total del total de maíz volcado identificado en las muestras de verificación, el 23,030% de los pixeles fueron clasificados como suelo y maíz en pie principalmente. La exactitud global de la clasificación se ubica en el 80,36% indicando que la clasificación a partir de los componentes principales combinando las bandas RGB y los índices en el espectro visible calculados también puede ser fiable para identificar el volcamiento de maíz, aunque los indicadores de calidad son un poco menores que los dos análisis anteriores.

En este estudio se aplicó la técnica de clasificación supervisada por el método de máxima verosimilitud a una imagen RGB de alta resolución obtenida con una aeronave remotamente tripulada. La clasificación se aplicó a las bandas espectrales RGB, índices espectrales calculados en el espectro visible y análisis de componente principales, los resultados mostraron que el volcamiento del maíz es posible identificarlo de manera confiable a partir de la imagen RGB y los correspondientes componentes principales, se obtuvieron valores de exactitud de usuario de 91,45%, 91,53%, exactitud del productor de 79,93%, 79,70% para el maíz volcado, con exactitudes totales de la imagen del 86,98% y 87,02%, presentándose un incremento poco significativo. En contraste se tiene el estudio conducido por (Sun et al., 2019) para identificar diferentes grados de volcamiento en un cultivo de maíz a partir de una imagen multiespectral (con banda NIr), en razón de que emplearon un método similar, aunque contaron con datos en el infrarrojo cercano. Los autores obtuvieron exactitudes del productor entre 74,12% al 86,57%, y exactitudes del usuario del orden de 71,72% al 86,48%, empleando componentes principales de la imagen tuvieron mejoras inferiores al 2% para estos dos indicadores. Con respecto a la exactitud total tuvieron un incremento del 1%.

Por otro lado, (T. Liu et al., 2018) emplearon imágenes infrarrojas térmicas y de rango visible para identificar arroz volcado en dos cultivos, y obtuvieron una tasa de falsos positivos y una tasa de falsos negativos inferior al 10%, y una tasa de alojamiento estimada con un R^2 superior a 0,9, el método empleado por estos autores incluía técnicas de optimización y máquinas de soporte vectorial. Además encontraron

Con respecto al análisis de componentes principales para la imagen RGB con los índices de vegetación en el espectro visible, en este estudio se presentó una disminución en la exactitud del usuario con respecto a los dos análisis previos, donde ésta se ubicó en 78,46% (un 13% menos), con respecto a la exactitud del productor se obtuvo un nivel levemente inferior, 76,97% (3% aproximadamente), con relación a la exactitud global, esta fue de 80,36%, presentándose una disminución del 7%. Aun así se considera que es una exactitud aceptable para los fines perseguidos. (Sun et al., 2019) encontraron que los niveles más severos de volcamiento aumentan la reflectancia espectral y a partir de los resultados obtenidos determinaron que existe la ventaja de extraer de forma rápida y precisa los niveles o severidad de volcamiento de maíz en función de la combinación de características de la imagen multiespectral de alta resolución obtenida con un vehículo aéreo no tripulado.

Con el fin de obtener el trigo volcado en un cultivo, (Wang et al., 2018) emplearon clasificación no supervisada en un análisis realizado en ocho parcelas de muestreo, los autores realizaron análisis texturales y de índices de color con imágenes RGB, y obtuvieron 91,08% de exactitud del usuario para trigo volcado y para trigo en pie del 86,15%.

Para este estudio, a partir de los índices espectrales calculados no se obtuvieron resultados muy satisfactorios para identificar el maíz volcado, la exactitud del usuario fue de 58,65% y la del productor 69,93%, por lo que se requeriría explorar con otros índices en el espectro visible. En los estudios anteriores que se tuvieron de referencia, la selección de características ha sido materia de investigación para determinar cuáles son las que pueden ofrecer más exactitud, sin embargo, (Chauhan et al., 2019), (Li et al., 2021) manifiestan que no existe consenso sobre el método o la forma más apropiada para evaluar el volcamiento de cultivos, así como para producir y validar mapas del mismo.

Con el volcamiento, la estructura del dosel se altera, principalmente por la proporción de tallos y hojas que quedan expuestos en el suelo, esto produce una respuesta espectral diferente entre el maíz en pie y el maíz que se ha volcado al suelo (Sun et al., 2019), ya sea por mecanismos de raíz o del tallo (lo cual no era objeto de análisis en este estudio), en este caso, se produjo un error de comisión de tan solo 8,47% para identificar el maíz volcado, y error de omisión del 20,30% para los componentes principales de la imagen RGB; además para la imagen RGB se obtuvieron errores de comisión y omisión de 8,55% y 20,07% respectivamente,

aportando en este caso dos método válidos para identificar el maíz volcado en un cultivo.

Para este estudio se contó con imágenes de alta resolución, con pixel de 1,7 cm, por lo que la clasificación efectuada se realiza a nivel de pixel. Las muestras de clasificación contaron con comportamiento espectral contrastante para separar maíz en pie y maíz volcado, pero al tener una imagen con tan alta resolución es posible que el mismo maíz se divida en dos o más categorías por lo cual se generan errores en la clasificación.

CONCLUSIONES

- En este estudio se empleó una aeronave remotamente tripulada (ART) equipada con una cámara con sensibilidad en el espectro visible RGB, que puede ser asequible para agricultores o diferentes usuarios a costos razonables. A partir del uso de las imágenes de alta resolución obtenidas con este sensor, se pudieron identificar y delimitar las zonas donde se presenta el fenómeno de volcamiento, sin llegar a discriminar el mecanismo del volcamiento, es decir si este es de raíz o de tallo, se identificaron además el maíz en pie, las zonas de suelo, malas hierbas y las sombras en la margen de la imagen así como algunas sombras al interior del cultivo, el maíz en pie ocupa la mayor extensión dentro del cultivo. Las diferentes categorías fueron fácilmente identificables a partir de la aplicación de técnicas de interpretación visual empleando criterios como brillo, textura, forma, patrón, tamaño, contraste.

- El comportamiento espectral de las coberturas de maíz en pie, maíz volcado y malas hierbas es coherente con la curva espectral de la vegetación, donde para la banda verde se tienen valores más alto que para las bandas rojo y azul. Al comparar el maíz volcado con el maíz en pie solamente, se tienen, en las tres bandas del espectro visible, valores más altos de niveles digitales que para el maíz en pie, la principal razón para que esto se presente es que el volcamiento genera cambios en la estructura y forma del cultivo, ocasionando cambios en la reflectancia espectral del dosel.

- En este estudio se aplicó clasificación supervisada por el método de máxima verosimilitud en cuatro vías: 1. sobre una imagen RGB, 2. sobre el análisis de componentes principales de dicha imagen, 3. sobre índices espectrales aplicados a la imagen y 4. sobre un análisis de componentes principales combinando las bandas RGB y los índices espectrales, los resultados obtenidos para la clasificación de los dos primeros métodos se consideran satisfactorios, dados los indicadores de exactitud obtenidos a partir de las diferentes matrices de confusión.

- Los clasificación propuesta para imagen RGB y componentes principales de la misma tienen potencial para ser empleados en la identificación y

cuantificación de áreas afectadas por volcamiento en cultivos de maíz, estableciendo que una de las principales ventajas es la rápida adquisición de las imágenes, además la toma puede realizarse en el momento que lo requiera el manejador del cultivo de forma tal que pueda identificar prontamente el estado del cultivo en el momento requerido.

- Los indicadores de exactitud, empleando solamente los índices espectrales no se consideraron satisfactorios, dado que los niveles de error fueron altos para las categorías de mayor interés en la clasificación como son maíz en pie y maíz volcado, además se obtuvo una alta sobreestimación del maíz volcado, no correspondiente con lo que se observa directamente en la imagen, en este sentido se requiere analizar otros índices

- Dados los indicadores de exactitud obtenidos para los índices espectrales empleados en este estudio se requieren más estudios en los que se exploren otros índices en el espectro visible, donde se incorporen además otros métodos de clasificación de imágenes que pueden incluir aprendizaje de máquinas (*machine learning*) u otros.

RECOMENDACIONES

Dadas las diferencias percibidas para la clasificación automatizada del volcamiento en el cultivo de maíz de la Granja Montelindo, se desprenden varios estudios posteriores que podrán llevarse a cabo y con el fin de complementar e incluso mejorar algunos de los resultados obtenidos en este estudio:

- En este estudio la extracción de muestras de entrenamiento se hizo en fecha posterior a la obtención de las imágenes, siempre lo recomendable es que se realice la verificación en campo el mismo día, o por lo menos en fecha cercana, en este caso las muestras se extrajeron con base en la interpretación visual con técnicas de fotointerpretación, por lo que cabe la posibilidad de que tanto algunas muestras de entrenamiento como las de verificación contengan errores de asignación inherentes al proceso interpretativo. Así mismo, es recomendable contar con información fiable de los diferentes estadios fenológicos en el cultivo.

- Para el estudio se contó con imágenes de alta resolución con pixeles de 1,7 cm, es probable que algunos de los errores obtenidos en la clasificación sean debidos a la alta resolución, ya que el mismo maíz puede dividirse en dos o más categorías, por lo que se podría explorar con diferentes alturas de vuelo y por tanto diferentes tamaños de pixel y así obtener un tamaño de pixel que optimice el proceso e incluso mejores los indicadores de exactitud.

- Dada la falta de consenso en cuáles son los métodos o características más apropiadas para identificar el volcamiento en cultivos y que existen diversos índices en el espectro visible que no se emplearon en este estudio, en ese sentido, se requieren más estudios en los cuales los análisis incluyan algunos de estos índices así como otro tipo de análisis, por ejemplo de texturas en la imagen (que también han sido reportados en la literatura consultada).

- El volcamiento en maíz, y en general en los cereales, no tiene una causa única, éste puede presentarse por la confluencia de múltiples factores, puede ser de interés realizar un análisis multitemporal (en diferentes años de cultivo establecido), que permita inferir o correlacionar condiciones previas en el terreno que puedan influir en la aparición y grado del volcamiento en momentos futuros, como por ejemplo alguna deficiencia nutricional o incluso exceso, condición de humedad en el suelo o afectación por ciertos tipos de malas hierbas (malezas) o

elemento topográfico. En este caso sería también recomendable contar con información en regiones del infrarrojo.

- Dados los cambios generados por el volcamiento en la estructura de dosel, se pueden realizar estudios con nubes densas de puntos y aplicar estructuras basadas en movimiento (*Structure from motion*), estas pueden ser adquiridas con sensores RGB, que permitan identificar los sitios de volcamiento así como las alturas de las plantas y los ángulos de desplazamiento desde la vertical y así incluso categorizar la afectación en el cultivo por grados de severidad.

BIBLIOGRAFÍA

Abd-Elrahman, A., Quirk, B., Corbera, J., & Habib, A. (2019). Small unmanned aerial system development and applications in precision agriculture and natural resource management. *European Journal of Remote Sensing*, *52*(1), 504–505. https://doi.org/10.1080/22797254.2019.1655997

Abd El-Ghany, N. M., Abd El-Aziz, S. E., & Marei, S. S. (2020). A review: application of remote sensing as a promising strategy for insect pests and diseases management. *Environmental Science and Pollution Research International*. https://doi.org/10.1007/s11356-020-09517-2

Acorsi, M. G., Martello, M., & Angnes, G. (2019). Identification of maize lodging: a case study using remotely piloted aircraft system. *Engenharia Agrícola, Jaboticabal*, *39*, 66–73.

Agisoft LLC. (2018). Agisoft Photoscan User Manual - Standard Edition, version 1.4. In *Version 1.2.3*. https://www.agisoft.com/pdf/photoscan-pro_1_4_en.pdf

Al-doski, J., Mansor, S. B., Zulhaidi, H., & Shafri, M. (2013). Image Classification in Remote Sensing. *Journal of Environment and Earth Science*, *3*(10), 141–148.

Ballesteros, R., Ortega, J. F., Hernandez, D., del Campo, A., & Moreno, M. A. (2018). Combined use of agro-climatic and very high-resolution remote sensing information for crop monitoring. *International Journal of Applied Earth Observation and Geoinformation*, *72*(June), 66–75. https://doi.org/10.1016/j.jag.2018.05.019

Ballesteros, R., Ortega, J. F., Hernández, D., & Moreno, M. a. (2014). Applications of georeferenced high-resolution images obtained with unmanned aerial vehicles. Part I: Description of image acquisition and processing. *Precision Agriculture*, *15*(6), 579–592. https://doi.org/10.1007/s11119-014-9355-8

Bannari, A., Morin, D., Bonn, F., & Huete, A. R. (1995). A review of vegetation indices. *Remote Sensing Reviews*, *13*(1–2), 95–120. https://doi.org/10.1080/02757259509532298

Barbedo, J. G. A. (2019). Detection of nutrition deficiencies in plants using proximal images and machine learning: A review. *Computers and Electronics in Agriculture*, *162*(December 2018), 482–492. https://doi.org/10.1016/j.compag.2019.04.035

Barbosa, B. D. S., Ferraz, G. A. S., Gonçalves, L. M., Marin, D. B., Maciel, D. T., Ferraz, P. F. P., & Rossi, G. (2019). RGB vegetation indices applied to grass monitoring: A qualitative analysis. *Agronomy Research*, *17*(2), 349–357. https://doi.org/10.15159/AR.19.119

Bendig, J., Yu, K., Aasen, H., Bolten, A., Bennertz, S., Broscheit, J., Gnyp, M. L., & Bareth, G. (2015). Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. *International Journal of Applied Earth Observation and Geoinformation*, *39*, 79–87. https://doi.org/10.1016/j.jag.2015.02.012

Berry, P. M. (2013). Lodging resistance in cereals. In P. Christou, R. Savin, B. A. Costa-Pierce, I. Misztal, & C. B. A. Whitelaw (Eds.), *Sustainable Food Production* (pp. 1096–1110). Springer New York. https://doi.org/10.1007/978-1-4614-5797-8_228

Berry, P., Sterling, M., Spin, J., Baker, C., Sylvester-Bradley, R., Mooney, S., Tams, A., & Ennos, A. (2004). Understanding and reducing lodging in cereals. *Advances in Agronomy*, *84*, 215–269. https://doi.org/10.1016/S0065-2113(04)84005-7

Bock, C. H., Poole, G. H., Parker, P. E., & Gottwald, T. R. (2010). Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging. *Critical Reviews in Plant Sciences*, *29*(2), 59–107. https://doi.org/10.1080/07352681003617285

Brune, P. F., Baumgarten, A., McKay, S. J., Technow, F., & Podhiny, J. J. (2018). A biomechanical model for maize root lodging. *Plant and Soil*, *422*(1–2), 397–408. https://doi.org/10.1007/s11104-017-3457-9

Campbell, J. B., & Wynne, R. H. (2011). *Introduction to remote sensing* (5th ed). The Guilford Press.

Campuzano D., L. F., Caicedo G., S., Narro, L., & Alfonso, H. (2014). Corpoica H5: primer híbrido de maíz amarillo de alta calidad de proteína (QPM) para la altillanura plana colombiana. *Corpoica Ciencia y Tecnología Agropecuaria*, *15*(2), 173. https://doi.org/10.21930/rcta.vol15_num2_art:357

Canada Centre for Remote Sensing. (1998). *Fundamentals of Remote Sensing* (p. 258). Canada Centre for Remote Sensing. https://www.nrcan.gc.ca/sites/www.nrcan.gc.ca/files/earthsciences/pdf/resource/tutor/fundam/pdf/fundamentals_e.pdf

Cardona Alzate, C. A. (2009). Perspectivas de la producción de biocombustibles en Colombia : contextos latinoamericano y mundial. (Perspectives of biofuels production in Colombia : latinamerican and world Contexts, in spanish). *Revista de Ingeniería Uniandes*, *29*, 109–120. http://www.scielo.org.co/pdf/ring/n29/n29a14.pdf

Casal, G., Domínguez, J. A., Sánchez-Carnero, N., & Freire, J. (2011). Utilización del sensor de imagen Airborne Hyperspectral Scanner (AHS) para la cartografía de bosques de Sargassum muticum en la Ría de Vigo (Galicia). *Revista de Teledetección*, *35*(July 2016), 17–22.

Chauhan, S., Darvishzadeh, R., Boschetti, M., & Nelson, A. (2020). Discriminant analysis for lodging severity classification in wheat using RADARSAT-2 and Sentinel-1 data. *ISPRS Journal of Photogrammetry and Remote Sensing*, *164*(April), 138–151. https://doi.org/10.1016/j.isprsjprs.2020.04.012

Chauhan, S., Darvishzadeh, R., Boschetti, M., Pepe, M., & Nelson, A. (2019). Remote sensing-based crop lodging assessment: Current status and perspectives. *ISPRS Journal of Photogrammetry and Remote Sensing*, *151*(August 2018), 124–140. https://doi.org/10.1016/j.isprsjprs.2019.03.005

Chen Z. et al. (2008). Monitoring and Management of Agriculture with Remote Sensing. In S. Liang (Ed.), *Advances in Land Remote Sensing* (pp. 397–421). Springer. https://doi.org///doi.org/10.1007/978-1-4020-6450-0_15

Chu, T., Starek, M. J., Brewer, M. J., Murray, S. C., & Pruter, L. S. (2017). Assessing lodging severity over an experimental maize (Zea mays L.) field using UAS images. *Remote Sensing*, *9*(9), 1–24. https://doi.org/10.3390/rs9090923

Chuvieco, E. (1995). *Fundamentos de teledetección espacial* (2nd ed.). Ediciones Rialp, S.A.

Chuvieco, E. (2008). *Teledeteccion ambiental. La observación de la Tierra desde el Espacio* (3a ed. rev). Editorial Ariel S. A.

CIMMYT, & CIAT. (2019). *Maíz para Colombia: Visión 2030* (E. Figueroa (ed.)). https://www.fenalce.org/archivos/maiz2030.pdf

Colomina, I., & Molina, P. (2014). 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

Congalton, R. G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, *37*(1), 35–4. https://doi.org///doi.org/10.1016/0034-4257(91)90048-B.

Cortes, C., & Vapnik, V. (1995). Support-Vector Networks. *Machine Learning*, *20*(3), 273–297. https://doi.org/http://dx.doi.org/10.1007/BF00994018

Costa, L., Nunes, L., & Ampatzidis, Y. (2020). A new visible band index (vNDVI) for estimating NDVI values on RGB images utilizing genetic algorithms. *Computers and Electronics in Agriculture*, *172*(March), 105334. https://doi.org/10.1016/j.compag.2020.105334

De Backer, S., Kempeneers, P., Debruyn, W., & Scheunders, P. (2004). Classification of dune vegetation from remotely sensed hyperspectral images. *Image Analysis and Recognition*, 497–503.

De Ocampo, A. L. P., Bandala, A. A., & Dadios, E. P. (2019). Estimation of Triangular Greenness Index for Unknown PeakWavelength Sensitivity of CMOS-acquired Crop Images. *2019 IEEE 11th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management, HNICEM 2019*. https://doi.org/10.1109/HNICEM48295.2019.9072796

Dhingra, G., Kumar, V., & Joshi, H. D. (2018). Study of digital image processing techniques for leaf disease detection and classification. *Multimedia Tools and Applications*, *77*(15), 19951–20000. https://doi.org/10.1007/s11042-017-5445-8

DJI. (2017). *Phantom 4 Advanced/Advanced+*. DJI. https://dl.djicdn.com/downloads/Phantom_4_Advanced/20171010/Phantom_4_Advanced_User_Manual-EN.pdf

Escribano, P., Palacios, A., & Oyonarte, C. (2008). Cuantificación y distribución espacial de los tipos de cubierta en los ecosistemas semiáridos con imágenes hiperespactrales, caso práctico en el Parque Natural Cabo de Gata-Nijar (Almería). *Ecosistemas*, *17*(3), 79–88. https://doi.org/10.7818/79

FAO. (2003). *Maize. Post-harvest Operations* (FAO (ed.)). http://www.fao.org/fileadmin/user_upload/inpho/docs/Post_Harvest_Compendium_-_MAIZE.pdf

Fenalce. (2011). Aspectos técnicos de la producción de maíz en Colombia. In *Fenalce* (p. 222). Federación Nacional de Cultivadores de Cereales. https://repository.agrosavia.co/handle/20.500.12324/19418

Fenalce. (2019). *Indicadores Cerealistas* (p. 77). Fenalce, Departamento Económico y apoyo a la comercialización. https://www.fenalce.org/archivos/indicerealista2019.pdf

Fenalce. (2020). *Indicadores Cerealistas* (p. 77). Fenalce, Departamento Económico y apoyo a la comercialización. https://www.fenalce.org/archivos/indicerealista2020B.pdf

Ferrero, S., Palacio, M., & Campanella, O. (2002). Análisis de componentes principales en teledetección: consideraciones estadísticas para optimizar su interpretación. *Revista de Teledetección: Revista de La Asociación Española de Teledetección*, *17*, 43–54.

Fleiss, J. L., Levin, B., & Paik, M. C. (2013). *Statistical Methods for Rates and Proportions* (Third edit). John Wiley & Sons.

Foody, G. M. (2020). Explaining the unsuitability of the kappa coefficient in the assessment and comparison of the accuracy of thematic maps obtained by image classification. *Remote Sensing of Environment*, *239*(December 2019), 111630. https://doi.org/10.1016/j.rse.2019.111630

García, M., & Watson, C. E. (2003). Herencia de la resistencia al acame de raíces en maíz dulce (Zea mays L.). *Revista Cientifica UDO Agricola*, *3*(1), 24–33.

García, M., Watson, C., & Salcedo, F. (2001). Resistencia Al Acame De Raíces. *Bioagro*, *13*(1), 22–31.

Gitelson, A. A., Stark, R., Rundquist, D., Gitelson, A. A., Kaufman, Y. J., Stark, R., & Rundquist, D. (2002). Novel Algorithms for Remote Estimation of Vegetation Fraction. *Remote Sensing of Environmen*, *80*, 76–87.

Gomarasca, M. A. (2009). *Basics of Geomatics* (Vol. 1, Issue). https://doi.org/10.1017/CBO9781107415324.004

Gómez Mejía, J. (1986). *Características e importancia socioeconómica: maíz* (p. 47 p.). Servicio Nacional de Aprendizaje.

Gonçalves, J. a., & Henriques, R. (2015). UAV photogrammetry for topographic monitoring of coastal areas. *ISPRS Journal of Photogrammetry and Remote Sensing*, *104*, 101–111. https://doi.org/10.1016/j.isprsjprs.2015.02.009

Govender, M., Chetty, K., & Bulcock, H. (2007). A review of hyperspectral remote sensing and its application in vegetation and water resource studies. *Water SA*, *33*(2), 145–151. https://doi.org/10.4314/wsa.v33i2.49049

Grenzdörffer, G., Engel, A., & Teichert, B. (2008). The photogrammetric potential of low-cost UAVs in forestry and agriculture. *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences*, *1*, 1207–1213. http://www.isprs.org/proceedings/XXXVII/congress/1_pdf/206.pdf

Hemmati-Sarapardeh, A., Larestani, A., Nait Amar, M., & Hajirezaie, S. (2020). Intelligent models. *Applications of Artificial Intelligence Techniques in the Petroleum Industry*, 23–50. https://doi.org/10.1016/b978-0-12-818680-0.00002-3

Hunt, E. R., Daughtry, C. S. T., Eitel, J. U. H., & Long, D. S. (2011). Remote Sensing Leaf Chlorophyll Content Using a Visible Band Index. *Agronomy Journal*, *103*(4), 1090–1099. https://doi.org/https://doi.org/10.2134/agronj2010.0395

Jannoura, R., Brinkmann, K., Uteau, D., Bruns, C., & Joergensen, R. G. (2015). Monitoring of crop biomass using true colour aerial photographs taken from a remote controlled hexacopter. *Biosystems Engineering*, *129*, 341–351. https://doi.org/10.1016/j.biosystemseng.2014.11.007

Karthikeyan, L., Chawla, I., & Mishra, A. K. (2020). A review of remote sensing applications in agriculture for food security: Crop growth and yield, irrigation, and crop losses. *Journal of Hydrology*, *586*(March), 124905. https://doi.org/10.1016/j.jhydrol.2020.124905

Kataoka, T., Kaneko, T., Okamoto, H., & Hata, S. (2003). Crop growth estimation system using machine vision. *IEEE/ASME International Conference on Advanced Intelligent Mechatronics, AIM*, *2*(Aim), 1079–1083. https://doi.org/10.1109/AIM.2003.1225492

Khorram, S., Koch, F. H., van der Wiele, C. F., & Nelson, S. A. C. (2012). *Remote Sensing*. Springer. https://doi.org/10.1007/978-1-4614-3103-9

Landis, J. R., & Koch, G. G. (1977). The Measurement of Observer Agreement for Categorical Data. *Biometrics*, *33*(1), 159. https://doi.org/10.2307/2529310

Lee, M. K., Golzarian, M. R., & Kim, I. (2020). A new color index for vegetation segmentation and classification. *Precision Agriculture*, *0123456789*. https://doi.org/10.1007/s11119-020-09735-1

Li, X., Li, X., Liu, W., Wei, B., & Xu, X. (2021). A UAV-based framework for crop lodging assessment. *European Journal of Agronomy*, *123*(September 2020), 126201. https://doi.org/10.1016/j.eja.2020.126201

Liu, J. G., & Mason, P. J. (2016). *Image processing and GIS for remote sensing* (Second Edi). John Wiley & Sons, Ltd.

Liu, T., Li, R., Zhong, X., Jiang, M., Jin, X., Zhou, P., Liu, S., Sun, C., & Guo, W. (2018). Estimates of rice lodging using indices derived from UAV visible and thermal infrared images. *Agricultural and Forest Meteorology*, *252*(December 2017), 144–154. https://doi.org/10.1016/j.agrformet.2018.01.021

López Carvajal, J. (2016). *Metodología para el análisis automático de imágenes de sensores remotos de alta resolución basada en líneas* (p. 106). Universidad Nacional de Colombia - Medellin.

Louargant, M., Villette, S., Jones, G., Vigneau, N., Paoli, J. N., & Gée, C. (2017). Weed detection by UAV: simulation of the impact of spectral mixing in multispectral images. *Precision Agriculture*, *18*(6), 932–951. https://doi.org/10.1007/s11119-017-9528-3

Louhaichi, M., Borman, M. M., & Johnson, D. E. (2001). Spatially located platform and aerial photography for documentation of grazing impacts on wheat. *Geocarto International*, *16*(1), 65–70. https://doi.org/10.1080/10106040108542184

Marcial-Pablo, M. de J., Gonzalez-Sanchez, A., Jimenez-Jimenez, S. I., Ontiveros-Capurata, R. E., & Ojeda-Bustamante, W. (2019). Estimation of vegetation fraction using RGB and multispectral images from UAV. *International Journal of Remote Sensing*, *40*(2), 420–438. https://doi.org/10.1080/01431161.2018.1528017

McKinnon, T., & Hoff, P. (2017). Comparing RGB-Based Vegetation Indices With NDVI For Drone Based Agricultural Sensing. *Retina*, *17*(2), 105–108. https://doi.org/10.1097/00006982-199703000-00004

Mesas-Carrascosa, F. J., Notario-García, M. D., de Larriva, M. D. N. G., de la Orden, M. S., & Porras, A. G. F. (2014). Validation of measurements of land plot area using UAV imagery. *International Journal of Applied Earth Observation and Geoinformation*, *33*(1), 270–279. https://doi.org/10.1016/j.jag.2014.06.009

Metternicht, G. (2003). Vegetation indices derived from high-resolution airborne videography for precision crop management. *International Journal of Remote Sensing*, *24*(14), 2855–2877. https://doi.org/10.1080/01431160210163074

Monserud, R. A., & Leeman, R. (1992). Comparing global vegetation maps with the Kappa statistic. *Ecological Modelling*, *62*(4), 275–293. https://doi.org/https://doi.org/10.1016/0304-3800(92)90003-W.

Mukherjee, A., Misra, S., & Raghuwanshi, N. S. (2019). A survey of unmanned aerial sensing solutions in precision agriculture. *Journal of Network and Computer Applications*, *148*(October), 102461. https://doi.org/10.1016/j.jnca.2019.102461

Nielsen, B., & Colville, D. (1988). *Stalk Lodging in Corn: Guidelines for Preventive Management*. Purdue University. https://www.extension.purdue.edu/extmedia/ay/ay-262.html

Niklas, K. J. (1992). *Plant Biomechanics: An Engineering Approach to Plant Form and Function*. U Chicago Press.

Pádua, L., Vanko, J., Hruška, J., Adão, T., Sousa, J. J., Peres, E., & Morais, R. (2017). UAS, sensors, and data processing in agroforestry : a review towards practical applications. *International Journal of Remote Sensing*, *38*(8–10), 2349–2391. https://doi.org/10.1080/01431161.2017.1297548

Parra, A. (2014). *Análisis digital de imágenes e teledetección. Teoría y práctica* (p. 386). Universidad de los Andes.

Petropoulos, G. P., Kalaitzidis, C., & Prasad Vadrevu, K. (2012). Support vector machines and object-based classification for obtaining land-use/cover cartography from Hyperion hyperspectral imagery. *Computers and Geosciences*, *41*, 99–107. https://doi.org/10.1016/j.cageo.2011.08.019

Poehlman, J. M., & Sleper, D. A. (1995). *Breeding Field Crops* (Fourth edi). Iowa State University Press /Ames.

Portero, C., Mercadal, M., & Salas, P. (2015). *Incorporación de imágenes aéreas en el manejo del cultivo del maíz*. 807–815. http://congresoage.unizar.es/eBook/trabajos/084_Portero.pdf

Puri, V., Nayyar, A., & Raja, L. (2017). Agriculture drones: A modern breakthrough in precision agriculture. *Journal of Statistics and Management Systems*, *20*(4), 507–518. https://doi.org/10.1080/09720510.2017.1395171

Quintero, L. (1999). *La producción y comercialización de granos y algodón en Colombia*. Bolsa Nacional Agropecuaria. Le'Print Club Express.

Radoglou-Grammatikis, P., Sarigiannidis, P., Lagkas, T., & Moscholios, I. (2020). A compilation of UAV applications for precision agriculture. *Computer Networks*, *172*(February), 107148. https://doi.org/10.1016/j.comnet.2020.107148

Reinecke, M., & Prinsloo, T. (2017). The influence of drone monitoring on crop health and harvest size. *2017 1st International Conference on Next Generation Computing Applications, NextComp 2017*, 5–10. https://doi.org/10.1109/NEXTCOMP.2017.8016168

Richards, J. A. (2013). Remote sensing digital image analysis: An introduction. In *Remote Sensing Digital Image Analysis: An Introduction* (Vol. 9783642300). https://doi.org/10.1007/978-3-642-30062-2

Shu, M., Zhou, L., Gu, X., Ma, Y., Sun, Q., Yang, G., & Zhou, C. (2020). Monitoring of maize lodging using multi-temporal Sentinel-1 SAR data. *Advances in Space Research*, *65*(1), 470–480. https://doi.org/10.1016/j.asr.2019.09.034

Sishodia, R. P., Ray, R. L., & Singh, S. K. (2020). Applications of remote sensing in precision agriculture: A review. *Remote Sensing*, *12*(19), 1–31. https://doi.org/10.3390/rs12193136

Sotier, B. (2014). High resolution aerial images from UAV for forest applications State-of-the-Art. *Forest Resources & LiDar*, *2*. https://www.newfor.net/wp-content/uploads/2015/02/DL14-Newfor-SoA-UAV.pdf

Sugiura, R., Noguchi, N., & Ishii, K. (2005). Remote-sensing technology for vegetation monitoring using an unmanned helicopter. *Biosystems Engineering*, *90*(4), 369–379. https://doi.org/10.1016/j.biosystemseng.2004.12.011

Sun, Q., Sun, L., Shu, M., Gu, X., Yang, G., & Zhou, L. (2019). Monitoring Maize Lodging Grades via Unmanned Aerial Vehicle Multispectral Image. *Plant Phenomics*, *2019*, 1–16. https://doi.org/10.34133/2019/5704154

Tang, L., & Shao, G. (2015). Drone remote sensing for forestry research and practices. *Journal of Forestry Research*, *26*(4), 791–797. https://doi.org/10.1007/s11676-015-0088-y

Torres-Sánchez, J., Peña, J. M., de Castro, A. I., & 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. https://doi.org/10.1016/j.compag.2014.02.009

Torres-Sánchez, Jorge, López-Granados, F., Serrano, N., Arquero, O., & Peña, J. M. (2015). High-Throughput 3-D Monitoring of Agricultural-Tree Plantations with Unmanned Aerial Vehicle (UAV) Technology. *PloS One*, *10*(6), 1–20. https://doi.org/10.1371/journal.pone.0130479

Toth, C., & Jóźków, G. (2016). Remote sensing platforms and sensors: A survey. *ISPRS Journal of Photogrammetry and Remote Sensing*, *115*, 22–36. https://doi.org/10.1016/j.isprsjprs.2015.10.004

Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, *8*(2), 127–150. https://doi.org/https://doi.org/10.1016/0034-4257(79)90013-0

Wang, J. J., Ge, H., Dai, Q., Ahmad, I., Dai, Q., Zhou, G., Qin, M., & Gu, C. (2018). Unsupervised discrimination between lodged and non-lodged winter wheat: a case study using a low-cost unmanned aerial vehicle. *International Journal of Remote Sensing*, *39*(8), 2079–2088. https://doi.org/10.1080/01431161.2017.1422875

Xiang, H., & Tian, L. (2011). Development of a low-cost agricultural remote sensing system based on an autonomous unmanned aerial vehicle (UAV). *Biosystems Engineering*, *108*(2), 174–190. https://doi.org/10.1016/j.biosystemseng.2010.11.010

Xue, J., & Su, B. (2017). Significant remote sensing vegetation indices: A review of developments and applications. *Journal of Sensors*, *2017*. https://doi.org/10.1155/2017/1353691

Yang, Z., Willis, P., & Mueller, R. (2008). Impact of Band-Ratio Enhanced Awifs Image To Crop Classification Accuracy. *Pecora 17 – The Future of Land Imaging…Going Operational*, 11.

Zarco-Tejada, P. J., González-Dugo, V., & Berni, J. A. J. (2012). Fluorescence, temperature and narrow-band indices acquired from a UAV platform for water stress detection using a micro-hyperspectral imager and a thermal camera. *Remote Sensing of Environment*, *117*, 322–337. https://doi.org/10.1016/j.rse.2011.10.007

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

Zhuang, S., Wang, P., Jiang, B., Li, M., & Gong, Z. (2017). Early detection of water stress in maize based on digital images. *Computers and Electronics in Agriculture*, *140*, 461–468. https://doi.org/10.1016/j.compag.2017.06.022

ANEXOS

Anexo 1. Valores promedio y desviaciones estándar de las bandas RGB para cada cobertura de las muestras de entrenamiento en el ortofotomosaico obtenido.

COBERTURA	Red (Rojo)		Green (Verde)		Blue (Azul)	
	MEDIA	DESV.	MEDIA	DESV.	MEDIA	DESV.
Sombra	23,64	10,71	35,09	14,62	24,80	10,24
Maleza	94,11	14,52	134,26	15,21	69,21	17,15
Suelo	151,97	37,11	151,41	36,38	146,98	38,73
Maíz en pie	117,48	29,75	141,39	29,44	94,71	30,47
Maíz volcado	161,46	30,55	174,94	26,51	141,03	33,57

Anexo 2. Valores promedio y desviaciones estándar de los índices en espectro visible calculados, para cada cobertura en las muestras de entrenamiento.

COBERTURA	GRVI		PPR		GLI		VARI	
	MEDIA	DESV.	MEDIA	DESV.	MEDIA	DESV.	MEDIA	DESV.
Sombra	0,195743	0,099784	0,166141	0,105617	0,178887	0,091178	0,346577	0,194099
Maleza	0,178716	0,039954	0,328023	0,100419	0,24804	0,062983	0,254254	0,043884
Suelo	0,001318	0,03816	0,020117	0,040724	0,010385	0,035536	0,00152	0,071435
Maíz en pie	0,09995	0,052868	0,216888	0,103613	0,154379	0,068543	0,153379	0,070004
Maíz volcado	0,043125	0,04562	0,115628	0,075607	0,07767	0,055876	0,070408	0,074883