

Segmentación foliar en sistemas de cultivo de banano: aplicaciones del flujo de trabajo fotogramétrico y teledetección mediante imágenes multiespectrales de aeronaves no tripuladas (UAS)*

Jairo René Escobar Villanueva^a ■ Luis Miguel Torres Ustate^b ■ Miguel Ángel Gutiérrez Estrada^c ■ Martha Ligia Castellanos Martínez^d

Resumen: Este estudio presenta una metodología para lograr la segmentación foliar en sistemas de producción de cultivos de banano, utilizando imágenes multiespectrales provenientes de una aeronave no tripulada (UAS, por sus siglas en inglés), procesamiento fotogramétrico y aplicación de teledetección con Sistemas de Información Geográfica (SIG). En esta se plantea la integración de procesos como: 1) diseño de vuelo y captura de imágenes multiespectrales con UAS (multirrotor) en áreas prioritarias dentro del sistema de producción; 2) procesamiento fotogramétrico de imágenes RGB y multiespectrales; 3) explotación con SIG de los productos fotogramétricos para apoyar la segmentación (ortoimágenes y modelos digitales de alturas forestales); 4) validación de la segmentación, y 5) aplicaciones para el seguimiento de zonas focalizadas, utilizando índices de vegetación enfocados solo en la estructura foliar segmentada. Los resultados demuestran una diferenciación aceptable de la estructura foliar tanto en áreas de cultivo fragmentadas como densamente explotadas. Además, permite la aplicación de índices de vegetación como apoyo para seguimientos rutinarios y como primer criterio para identificar sospechas de enfermedades foliares. En este sentido, este estudio

* Artículo de investigación.

- a Doctor en Investigación, Modelización y Análisis del Riesgo en Medio Ambiente, de la Universidad de La Guajira, Riohacha, Colombia.
Correo electrónico: jrescobar@uniguajira.edu.co; ORCID: <https://orcid.org/0000-0002-2558-3500>
- b Magíster en Gestión Integral frente al Cambio Climático, de la Universidad de La Guajira. Riohacha, Colombia.
Correo electrónico: lmigueltorres@uniguajira.edu.co; ORCID: <https://orcid.org/0000-0002-9614-3043>
- c Magíster en Gestión Integral frente al Cambio Climático, de la Universidad de La Guajira. Riohacha, Colombia.
Correo electrónico: mangelgutierrez@uniguajira.edu.co; ORCID: <https://orcid.org/0000-0003-2017-4262>
- d Doctora en Ciencias Agropecuarias, de la Universidad de La Guajira. Riohacha, Colombia.
Correo electrónico: mlcastellanosm@uniguajira.edu.co; ORCID: <https://orcid.org/0000-0001-8965-8885>

se presenta como una contribución de la aplicación práctica en condiciones reales de operación, brindando pautas para el avance hacia una tecnificación de sistemas de producción de banano, tomando como caso de estudio particular a una de las principales actividades económicas del Caribe colombiano.

Palabras clave: sistemas de producción de banano; clasificación; dron; índices de vegetación; SIG; monitoreo de enfermedades foliares; agricultura de precisión

Recibido: 28/05/2024 **Aceptado:** 04/11/2024 **Disponible en línea:** 11/04/2025

Cómo citar: Escobar Villanueva, J. R., Torres Ustate, L. M., Gutiérrez Estrada, M. A., & Castellanos Martínez, M. L. (2025). Segmentación foliar en sistemas de cultivo de banano: Aplicaciones del flujo de trabajo fotogramétrico y teledetección mediante imágenes multiespectrales de aeronaves no tripuladas (UAS). *Ciencia E Ingeniería Neogranadina*, 35(1), 25–45. <https://doi.org/10.18359/rcin.7365>

Leaf Segmentation in Banana Cultivation Systems: Applications of Photogrammetric Workflow and Remote Sensing Using Multispectral Images from Unmanned Aerial Vehicles

Abstract: This study presents a methodology for leaf segmentation in banana cultivation systems using multispectral images acquired from an unmanned aerial system (UAS), photogrammetric processing, and remote sensing applications within Geographic Information Systems (GIS). The proposed approach integrates the following processes: (1) flight planning and multispectral image acquisition with a multirotor UAS in priority areas of the production system; (2) photogrammetric processing of RGB and multispectral images; (3) GIS-based analysis of photogrammetric products, such as orthophotos and digital surface models, to support segmentation; (4) segmentation validation; and (5) application of vegetation indices focused exclusively on the segmented leaf structure for targeted monitoring. The results demonstrate effective differentiation of leaf structures in both fragmented and densely cultivated areas. Additionally, the methodology facilitates the application of vegetation indices to support routine monitoring and serves as a primary criterion for identifying potential foliar diseases. In this context, the study offers a practical contribution under real operational conditions, providing guidelines for advancing the technological enhancement of banana production systems. It focuses on a case study of one of the most significant economic activities in the Colombian Caribbean.

Keywords: Banana Cultivation Systems; Classification; Drone; Vegetation Indices; GIS; Leaf Disease Monitoring; Precision Agriculture

Segmentação foliar em sistemas de cultivo de banana: aplicações do fluxo de trabalho fotogramétrico e sensoriamento remoto com imagens multiespectrais de aeronaves não tripuladas (UAS)

Resumo: Este estudo apresenta uma metodologia para segmentação foliar em sistemas de produção de banana, utilizando imagens multiespectrais capturadas por aeronaves não tripuladas (UAS, na sigla em inglês), processamento fotogramétrico e aplicação de sensoriamento remoto com Sistemas de Informação Geográfica (SIG). A abordagem integra os seguintes processos: 1) planejamento de voo e captura de imagens multiespectrais com UAS (multirrotor) em áreas prioritárias dentro do sistema de produção; 2) processamento fotogramétrico de imagens RGB e multiespectrais; 3) análise dos produtos fotogramétricos no SIG para apoiar a segmentação (ortoimagens e modelos digitais de altura da vegetação); 4) validação da segmentação; e 5) aplicação para monitoramento de

áreas específicas, utilizando índices de vegetação focados exclusivamente na estrutura foliar segmentada. Os resultados demonstram uma diferenciação eficiente da estrutura foliar em áreas de cultivo fragmentadas e intensamente exploradas. Além disso, a metodologia possibilita o uso de índices de vegetação para monitoramento regular e como critério inicial para a identificação de possíveis doenças foliares. Assim, este estudo representa uma contribuição prática para a aplicação da tecnologia em condições reais de operação, fornecendo diretrizes para a modernização dos sistemas de produção de banana. O caso de estudo foi conduzido em uma das principais regiões produtoras do Caribe colombiano.

Palavras-chave: sistemas de produção de banana; classificação; drone; índices de vegetação; SIG; monitoramento de doenças foliares; agricultura de precisão

Introducción

La producción agrícola a gran escala enfrenta desafíos asociados al monitoreo y el mantenimiento de la salud de los cultivos [1, 2]. El banano se destaca como uno de los productos agrícolas ampliamente cultivados en los trópicos y subtrópicos, por lo que se convierte en un componente fundamental de la economía agrícola en muchas regiones [3]. Sin embargo, la integridad y calidad foliar son aspectos críticos para garantizar el rendimiento sostenible de los sistemas de cultivo de banano [4]. El monitoreo manual de la salud foliar en sistemas de cultivo a gran escala puede ser costoso, laborioso y poco eficiente, lo que plantea la necesidad de desarrollar métodos indirectos, robustos y sistemáticamente replicables para evaluar la salud de los cultivos [5]. La producción de banano desempeña un papel crucial en la economía regional y nacional de Colombia, especialmente en la zona del Caribe. No obstante, en las regiones productivas de La Guajira y Magdalena enfrenta desafíos relacionados con el monitoreo de la salud de los cultivos en un entorno tropical, propenso a enfermedades y plagas [6]. Además, eventos climáticos extremos también afectan la productividad de las plantaciones [7]. En respuesta a estos desafíos, la teledetección y el uso de vehículos aéreos no tripulados (UAS, por sus siglas en inglés) emergen como herramientas potenciales para analizar en detalle la salud foliar.

Es así que el desarrollo de técnicas avanzadas de teledetección y análisis de imágenes multiespectrales se presentan como una alternativa para mejorar el monitoreo de la salud foliar en las plantaciones de banano de regiones como el Caribe colombiano [7, 8]. Estas tecnologías permiten la captura de datos a gran escala y de alta resolución, que junto con la integración de sistemas de información geográfica (SIG), proporcionan herramientas para el análisis espacial y la toma de decisiones en la gestión de sistemas de producción [10]. Una etapa clave, al evaluar la calidad foliar en plantaciones de banano, es separar todas aquellas coberturas o clases que no son precisamente parte de la estructura de la planta, como son el suelo, la hojarasca o las sombras. Mediante la segmentación foliar se

pretende identificar y cuantificar de manera efectiva indicios de anomalías en la estructura foliar que puedan estar relacionados con enfermedades, estrés hídrico u otros problemas de salud de la planta, basándose en los valores típicos de los índices de vegetación, como el NDVI. La segmentación inicia con la clasificación, un proceso que parte de la respuesta espectral de la hoja, asignando a cada píxel de la imagen espectral una clase específica: hoja, suelo, sombra u otros elementos [11]. Posteriormente, se da la segmentación de la hoja, lo que implica la identificación y delineación precisa o vectorización de los contornos de las hojas individuales dentro de una imagen [12]. Estos avances han sido posibles gracias al uso de algoritmos de imágenes de teledetección satelital que pueden procesar con eficiencia la información multiespectral de la alta resolución capturada por sensores de imágenes aéreas de plataformas UAS [13].

Los avances teóricos y antecedentes investigativos en el campo de la teledetección y la fotogrametría han sentado las bases para el desarrollo de esta metodología en plataformas UAS. Investigaciones previas han demostrado la pertinencia de las imágenes multiespectrales y la teledetección para el monitoreo de la salud vegetal en determinados casos de cultivos agrícolas, incluido sistemas de producción de banano. Por ejemplo [13, 14], destacan la importancia de la teledetección en el monitoreo de la salud de los cultivos, mientras que [15, 16] resaltan la utilidad de la segmentación foliar para la detección temprana de enfermedades y estrés en las plantas. Sin embargo, experiencias de implementación en sistemas productivos de banano, en especial aquellos sujetos a condiciones extremas de clima y a riesgos fitosanitarios, aún no están suficientemente documentada en regiones como el Caribe colombiano. Por ello, resulta pertinente la investigación aplicada que permita comprobar la efectividad de estas tecnologías geoespaciales bajo condiciones reales de operación.

El presente estudio se centra en específico en desarrollar y aplicar una metodología para la segmentación foliar documentada en sistemas de cultivo de banano del Caribe colombiano. Metodológicamente, la investigación propone un nuevo enfoque para la segmentación foliar en sistemas de

cultivo de banano, basado en la combinación de imágenes multispectrales obtenidas mediante UAS con algoritmos de procesamiento de imágenes satelitales. En teoría, el estudio genera nuevos conocimientos sobre la relación entre los datos espectrales de las hojas de banano y su estado de salud, lo cual contribuye a la comprensión de la aplicación de la teledetección en sistemas productivos de banano en regiones tropicales con alta incidencia de plagas y enfermedades. Los resultados de esta investigación pueden servir como base para el desarrollo de nuevas herramientas de monitoreo de cultivos y contribuir a una gestión agrícola más eficiente y sostenible. El caso de estudio del desarrollo metodológico propuesto, se centró en las zonas de producción bananera de los departamentos del Magdalena y La Guajira (Caribe colombiano), regiones biogeográficas representativas, altamente expuestas a amenazas constantes de tipo fitosanitario y a escenarios climáticos extremos. La selección del área de estudio se justifica por su ubicación dentro de una importante zona productora de banano en Colombia, que aporta a las 2.4 millones de toneladas de banano que se generan en el país, de las cuales un 87 % es destinada a la exportación [18]. El estudio en esta área aporta información valiosa para el desarrollo de estrategias de manejo fitosanitario en regiones productoras de banano con características similares.

Materiales y métodos

Área de estudio y equipo geomático (dron) empleado


La finca de banano objeto de estudio (aproximadamente de 20 ha) se ubica en inmediaciones del poblado de Orihueca, Zona Bananera, Magdalena (figura 1, Lat: 10.816107 °; Long: -74.168448 °). Esta región biogeográfica se beneficia de condiciones climáticas y edáficas propicias para el cultivo de banano. El clima tropical húmedo, con temperaturas promedio anuales de 27 °C y altas precipitaciones, favorece los sistemas de producción a gran escala. Los suelos aluviales, ricos en materia orgánica, permiten una retención adecuada

de humedad y nutrición. Sin embargo, la región enfrenta desafíos, como fuertes lluvias en época de La Niña y períodos de sequía prolongados en época de El Niño, que afectan el recurso hídrico esencial para el riego. Además, a estos retos se suma la amenaza constante de enfermedades con el potencial de afectar significativamente la producción, particularmente las de origen Fusariosis, también conocida como marchitez por *Fusarium*, causada por el hongo *Fusarium oxysporum*. Estas enfermedades, junto con los eventos climáticos extremos particulares, ponen a prueba la gestión agrícola de los cultivos, haciendo oportuno el papel de la finca para el desarrollo de prácticas agrícolas de monitoreo geoespacial en escenarios no favorables de cambio climático y amenazas fitosanitarias.

Respecto a los equipos utilizados, estos comprenden instrumentación geomática basada en UAS (drones), que funcionan como plataformas portadoras de sensores de imágenes de tipo multispectral. Las imágenes fueron capturadas mediante el multirrotor especializado cuadricóptero Phantom 4, DJI, China. El DJI Phantom 4 Multispectral (P4M) está equipado con seis semiconductores complementarios de óxido metálico (CMOS) de 1/2,9 pulgadas: incluye un sensor RGB para capturar imágenes visibles y cinco sensores monocromáticos diseñados para recolectar imágenes multispectrales en distintas bandas espectrales, azul, verde, rojo, borde rojo e infrarrojo cercano. Los detalles principales de estos sensores se presentan en la tabla 1. Cada banda es capaz de generar una imagen de 1600 × 1300 píxeles, lo que resulta en un total de seis imágenes por captura (incluida la RGB). Además, el P4M se conectó a un sistema GNSS Real-Time Kinematic (RTK) en el terreno (el D-RTK 2 de la casa DJI), permitiendo correcciones en tiempo real para alcanzar una precisión de posicionamiento de navegación y georreferenciación de imagen a nivel centimétrico.

La tabla 2 detalla el diseño de vuelo ejecutado el 13 de diciembre de 2022 en dos áreas, utilizando la aplicación DJI™ GS Pro. Cabe destacar que se estudiaron áreas distintas para realizar pruebas de validación, configurando los parámetros de altura para obtener un nivel de detalle de 1,6 y 0,6 cm/píxel.

Figura 1. Ubicación del área de estudio, contexto general, Zona Bananera (Caribe colombiano). Detalle: finca en proximidades del municipio Orihueca (Zona Bananera, Magdalena, Colombia). En tonalidad diferente se demarca el área efectiva producto del vuelo



Fuente: elaboración propia.

Tabla 1. Especificaciones técnicas de DJI Phantom IV Multispectral

Parámetros	Especificaciones
Cámara	6 sensores 1/2,9" CMOS incluyendo uno (1) RGB y 5 monocromáticos. Píxeles efectivos 2,08 MP (1600x1300) Distancia focal 6,82407 mm
Longitud de onda del sensor	Azul (B): 450 nm $\pm$ 16 nm; verde (g): 560 nm $\pm$ 16 nm; rojo (r): 650 nm $\pm$ 16 nm; borde rojo (RE): 730 nm $\pm$ 16 nm; Infrarrojo cercano (NIR): 840 nm $\pm$ 26 nm
Estabilizador (Gimbal)	3 ejes (pitch, roll, yaw)
Tiempo de vuelo	Max. 27 minutes
Peso	1487 g
Velocidad máxima	14 m/s (P-mod); 16 m/s (A-mod)
Velocidad de resistencia al viento	Max. 10 m/s
Temperatura de operación	0 ° to 40 °C
Módulo de posicionamiento exterior	GPS, Glonass, Galileo, Beidou
Rango de precisión de desplazamiento	RTK habilitado: $\pm$ 0,1 m V, $\pm$ 0,1 m H; RTK deshabilitado: $\pm$ 0,1 m V, $\pm$ 0,3 m H (visión); $\pm$ 0,5 m V, $\pm$ 1,5 m H (GPS)
Precisión de posicionamiento RTK	1 cm + 1 ppm (RMS) horizontal; 1,5 cm + 1 ppm (RMS) vertical

Nota: 1 ppm indica error con un aumento de 1 mm en 1 km de desplazamiento; RMS: raíz cuadrada media.

Fuente: elaboración propia.

Tabla 2. Parámetros y configuración para el diseño de vuelo con la app DJI™ GS Pro

Parámetros	Configuración/opción
Basic	
Camera Model	P4 Mulespectral Camera
Shooting Angle	Course Aligned
Capture Mode	Capture at Equal Dist. Interval
Fligh Course Mode	Inside Mode
Speed	2,1 m/s
Shutter Intv.	2,0 sec
Heigth	20 M / 30 M
Resolution	0,6 cm (centímetros)/PX (pixel) / 1,6 cm/PX
Advanced	
Front Overlap Ratio	80 %
Side Overlap Ratio	70 %
Course Angle	77 °
Margin	-2,8 M

Parámetros resultantes	
Waypoints Qty	22 Pts (puntos)
Course Count	11
Flight Length	1275 M
Cover Area	1,02 Ha (hectáreas)
Flight Time est.	12 min. 9 sec.
Batteries	1 sets approx
Photos Est.	280
Capture Interval	F: 4,2 M / S: 7,5 M

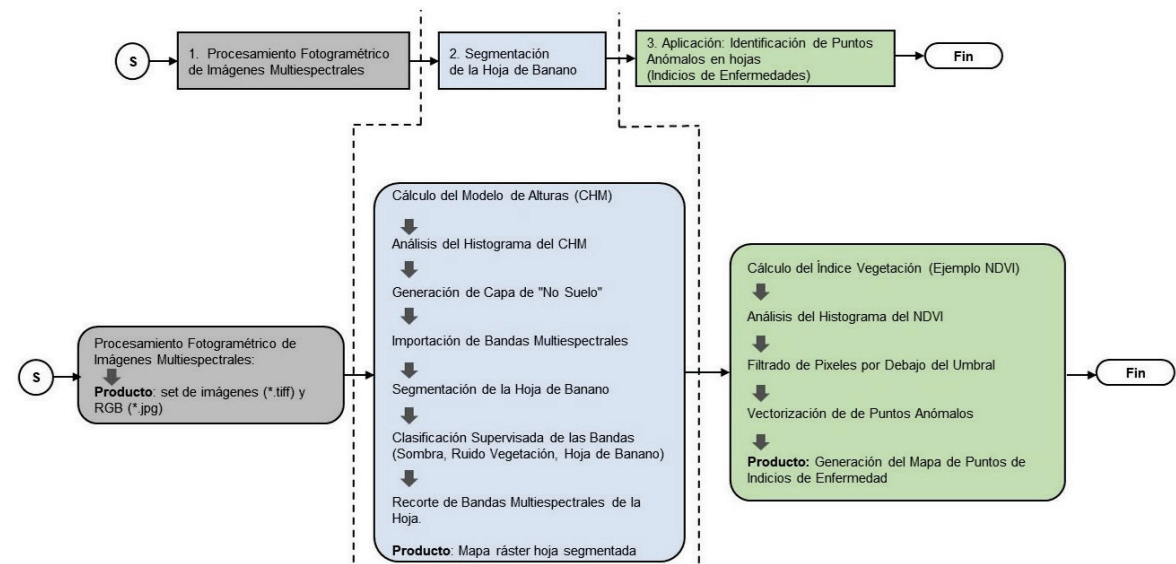
Fuente: elaboración propia.

Propuesta metodológica de segmentación foliar

La metodología propuesta (figura 2) se centra en la segmentación multispectral de las hojas de banano en imágenes fotogramétricas capturadas por plataformas no tripuladas (dron). Este proceso es esencial

para aplicar un filtro basado en índices de vegetación, que detecta valores atípicos en el espectro (histograma) de datos. Estos valores supuestamente anómalos en la vegetación podrían dar indicios de enfermedades, como la sigatoka negra (causada por *Pseudocercospora fijiensis*), que afecta en particular a los cultivos de banano en la zona de estudio.

Figura 2. Descripción general de la metodología propuesta del estudio



Fuente: elaboración propia.

La metodología sigue una secuencia de tres etapas para segmentar la hoja y posteriormente aplicar la detección de potenciales anomalías foliares basadas en índices de vegetación. En la que, 1) se aplica el flujo de trabajo fotogramétrico que

empieza con la captura de imágenes multispectrales de alta resolución y su procesamiento; 2) se realiza la segmentación detallada de las hojas de banano para aislarlas del resto de la imagen utilizando técnicas de teledetección en SIG, y 3) se

procede con la aplicación de filtros basados en índices de vegetación (una etapa propuesta para el análisis del estado foliar), para finalmente desplegar la identificación y distribución espacial de posibles anomalías que podrían ser indicativas de la presencia de enfermedades foliares. A continuación, se describe en detalle el procedimiento de la metodología propuesta para la segmentación foliar y su aplicación en tres fases:

Fase 1: procesamiento de datos de UAS

1) Procesamiento fotogramétrico de imágenes multiespectrales y RGB: se inicia con la captura de imágenes multiespectrales (.tiff) y RGB (.jpg), utilizando un dron equipado con un sensor multiespectral. Posteriormente, se procede al procesamiento de estas imágenes mediante el *software* Pix4Dmapper Pro o AGISOFT Metashape [19], [20]. Este proceso tiene como objetivo obtener ortoimágenes RGB para cada banda multiespectral, considerando la resolución radiométrica del sensor. Además, utilizando el flujo de trabajo fotogramétrico que integra la estructura a partir del movimiento y la multivista estéreo (SfM-MVS, por sus siglas en inglés) de *software* especializado, como Pix4D o Metashape, se logra la generación final de productos altimétricos basados en datos tipo ráster del sensor RGB [21]. Entre estos productos se incluyen los modelos digitales de superficie (MDS) y los modelos digitales de terreno (MDT), de los cuales a estos últimos se le han eliminado elementos como vegetación e infraestructuras mediante filtros basados en algoritmos de clasificación de tipo adaptativo [22].

Fase 2: segmentación de la hoja de banano

1) Cálculo del CHM: obtención del modelo de alturas (CHM) o modelo de alturas normalizado [23]. Se calcula como la diferencia entre el Modelo Digital de Superficie (MDS) y el Modelo Digital de Terreno (MDT). Este producto proporciona una representación de la configuración y distribución espacial de las alturas del

cultivo en la escena de vuelo. Posteriormente, se lleva a cabo un análisis de la distribución de alturas en el CHM, mediante histograma, junto al cálculo de estadísticos descriptivos, con el fin de seleccionar un rango adecuado que permita discriminar (filtrar) el suelo de la vegetación.

- 2) Generación de capa de “no suelo”:** se selecciona el rango de alturas correspondiente al dosel de las plantas para diferenciar suelo y no suelo. Luego se crea una capa binaria que representa vegetación del cultivo (1) y suelo (0).
- 3) Importación de bandas multiespectrales a SIG:** se importan las bandas multiespectrales (RGB y NIR) y se editan mediante la eliminación del suelo, utilizando una capa vectorial de “no suelo”.
- 4) Segmentación de la hoja de banano:** utilizar el módulo Semi-Automatic Classification Plugin (SCP) en SIG para segmentar la hoja de banano y otras áreas como sombras y ruido. Para este fin se utilizó el programa hospedado en el QGIS versión 3.30.3 [24].
- 5) Clasificación supervisada de las bandas:** se ejecuta el algoritmo de clasificación en SCP a partir de áreas de muestreo, categorizando sombras, ruido y hoja de banano, y utilizando las bandas B, G, R y NIR.
- 6) Ejecución del algoritmo:** aplicar el algoritmo de clasificación “Minimum Distance” en SCP para clasificar las áreas definidas.
- 7) Recorte de bandas multiespectrales de la hoja:** se recortan las bandas multiespectrales para quedarse solo con la hoja de banano clasificada, eliminando ruido y sombras.

Fase 3: indicios de enfermedad

- 1) Cálculo del índice NDVI:** calcular el Índice de Vegetación de Diferencia Normalizada (NDVI) utilizando las bandas del rojo e infrarrojo cercano (NIR).
- 2) Filtrado de píxeles por debajo del umbral:** filtrar los píxeles con valores de NDVI por debajo de un umbral definido.

- 3) **Vectorización de la nube de puntos anómalos:** se convierten los píxeles filtrados en puntos vectorizados para representar indicios de enfermedades.
- 4) **Generación del mapa de puntos de indicios de enfermedad:** se genera un mapa de puntos (vectorial) que muestra la distribución espacial de las áreas con indicios de enfermedades en hojas de banano.

Descripción y objeto de diferentes pruebas de estudio

En este estudio, se diseñaron tres pruebas (figura 1b) con el objetivo de evaluar el proceso convencional de clasificación y segmentación (prueba 1), así como las pruebas 2 y 3 para analizar y discutir el alcance de la metodología propuesta. A continuación, se describen cada una de estas pruebas:

- **Prueba 1:** el propósito de esta evaluación es analizar los productos multispectrales mediante el uso de un *software* de clasificación de coberturas en SIG. Para esta prueba se utilizó el sistema UAS P4M, operado a una altura de 30 metros, con el objetivo de obtener ortomosaicos de las cinco bandas del espectro electromagnético, cada una con un tamaño de píxel de 1,4 cm, utilizando el *software* Pix4D. Posteriormente, estos ortomosaicos fueron analizados con el *software* SIG libre (QGIS versión 3.30.3) y el complemento de clasificación semiautomática (SCP) [24]. Este enfoque posibilita la clasificación supervisada de las coberturas en el sistema de producción, mediante la creación interactiva de polígonos que permiten entrenar algoritmos con firmas espectrales de la escena. Se evaluaron tres algoritmos de clasificación basados en la firma espectral. Esta prueba se enfoca básicamente en la primera fase de la metodología propuesta.
- **Prueba 2:** en esta se implementaron las tres fases de la metodología propuesta en una parcela de cultivo de banano caracterizada por un espaciamiento disperso entre los individuos, utilizando los datos obtenidos en el vuelo correspondiente a la prueba 1. Se analizaron críticamente los

resultados obtenidos del mapeo y la segmentación foliar, evaluando su precisión en la detección de signos preliminares de enfermedades en el cultivo.

En ambas pruebas (1 y 2) se puso especial énfasis en la metodología de segmentación foliar propuesta, desde la recolección de datos hasta el análisis final, para asegurar la replicabilidad de los resultados y la validez de las anomalías identificadas.

- **Prueba 3:** en esta se buscó examinar el impacto de la densidad del cultivo y la resolución de la imagen en la efectividad de la metodología propuesta para identificar potenciales afecciones en las plantas. Similar al diseño de la prueba 2, se diferenció en el entorno de ejecución. Se llevó a cabo sobre una zona de cultivo con una densidad vegetal más alta y se realizó un vuelo a menor altitud (20 metros) (figura 1b), lo cual permitió obtener ortomosaicos de mayor resolución (0,6 cm/píxel) para cada banda espectral.

Resultados

Prueba 1


Las bandas del espectro electromagnético seleccionadas para la clasificación supervisada, resultado del procesamiento fotogramétrico de las imágenes multispectrales, fueron cuatro: azul (b), verde (g), rojo (R) e infrarrojo cercano (NIR). Para entender los perfiles de reflectancia espectral de los elementos de interés, se toma como ejemplo la composición de colores falsos del NIR, mostrada en la figura 3a, en la que la vegetación sana se presenta en un rojo brillante. Esto se debe a que refleja más luz en el espectro del NIR que en el verde.

En el procesamiento, se implementaron tres algoritmos de clasificación basados en la firma espectral, disponibles en el *software* SCP [24], a saber: la distancia mínima (Minimum Distance), la máxima verosimilitud (Maximum Likelihood) y el mapeo del ángulo espectral (Spectral Angle Mapping). Así mismo, la figura 3a ilustra polígonos azules que delimitan las regiones de interés (ROI) desde las que se extrajeron las

firmas espectrales requeridas para la clasificación multispectral mediante el *plugin* scp. El conjunto de datos de entrenamiento comprende un

componente vectorial (*.shp) y otro correspondiente a las firmas espectrales, las cuales operan de manera independiente entre sí.

Figura 3. Resultados de la clasificación: a) ubicación de las áreas de entrenamiento supervisado (azul) y falso color NIR para la clasificación de siete categorías. Mapas temáticos de clasificación del área por los algoritmos. b) "Minimal Distance". c) Máximo Likelihood y d) "Espectral Angle"



Fuente: elaboración propia.

Para esta prueba (1) se procedió a la identificación y clasificación manual de siete elementos distintos, presentes en la escena mediante un proceso de fotointerpretación y digitalización de polígonos. Estas tareas fueron realizadas por un operario SIG especializado. Las categorías definidas para la clasificación fueron las siguientes: 1) suelo despejado, 2) cuerpos de agua, 3) hojarasca, 4) sombras, 5) hojas de banano, 6) áreas construidas, y 7)


vegetación alta. Los resultados obtenidos de la clasificación, mediante la aplicación de los tres algoritmos seleccionados, se presentan en los mapas temáticos correspondientes a las figuras 3b, 3c y 3d, permitiendo una visualización de las diferencias y similitudes en la identificación y clasificación de estas categorías.

Al analizar visualmente los mapas clasificados se observan discrepancias notables entre los

resultados obtenidos por cada algoritmo, con una similitud particular entre los enfoques “Maximum_Likelihood” y “Spectral_Angle”. Estas discrepancias se observan en la figura 4, que proporcionan una interpretación cuantitativa de las

diferencias observadas en los mapas de clasificación. En particular, las mayores discrepancias se observan al clasificar la cobertura de “suelo despejado”, “vegetación alta” y “sombras”.

Figura 4. Áreas (%) de cobertura para cada clase determinada para los tres algoritmos de clasificación utilizados



Fuente: elaboración propia.

Los resultados muestran diferencias notables, según el método de clasificación empleado, las cuales pueden atribuirse a varias razones, incluyendo un posible entrenamiento deficiente del algoritmo por parte del fotointérprete o del operador SIG. Otro factor que podría influir es el solapamiento o similitud entre las firmas espectrales de cada clase analizada, por lo que es importante considerar estas posibles fuentes de variación al interpretar y comparar los resultados obtenidos de los distintos algoritmos de clasificación utilizados en la prueba. Para lo anterior, SCP dispone de un módulo de posproceso que estima la precisión de la clasificación de la escena (tabla 3). De la precisión se puede observar que el algoritmo “Minimum Distance” alcanza la mayor precisión, aunque en general es baja si se tiene como límite, ninguna sobrepasa el 50 %. La pobre clasificación general alcanzada puede atribuirse, en parte, a la similitud observada entre las firmas espectrales de las diferentes clases estudiadas, como se evidencia en la figura 5.

Tabla 3. Estadísticos de precisión de las clasificaciones para cada algoritmo

Estadístico	Minimum_Distance	Maximum_Likelihood	Spectral_Angle
Exactitud general [%]	40,2589	28,959	20,8574
Clasificación Kappa hat [0 - 1]	0,0508	0,0142	-0,0009

Nota: interpretación índice: clasificación perfecta = 1; clasificación pobre o nula = 0 (o tendiente a cero).

Fuente: elaboración propia.


Además, otra razón por la que la exactitud es baja es por los algoritmos escogidos, aunque la elección de los algoritmos “Minimum Distance”, “Maximum Likelihood” y “Spectral Angle Mapping” se debió a su disponibilidad dentro del *plugin* Semi-Automatic Classification Plugin (SCP) de QGIS. Si bien estos algoritmos arrojaron una precisión general por debajo del 50 %, su uso se justifica en el contexto de este estudio exploratorio, cuyo

objetivo principal es evaluar la viabilidad del enfoque metodológico. Reconocemos que la incorporación de algoritmos más avanzados, como Random Forest o Support Vector Machine, podría mejorar la precisión de la clasificación. Sin embargo, la exploración de estas alternativas queda fuera del alcance del presente estudio y plantea desafíos para futuras investigaciones.

En la figura 5 se representan las firmas espectrales para cada clase en las cuatro bandas utilizadas (rojo, verde, azul, NIR), con el propósito de

evaluar su similitud. Se observa que algunas clases, como los diferentes tipos de vegetación densa y baja, muestran firmas espectrales muy parecidas, en especial en la banda NIR (3), incluyendo las clases “suelo despejado”, “hoja de banano” y “vegetación alta”. Asimismo, se observan similitudes notables entre las clases “hojarasca” y “construcción”. Estas similitudes pueden conducir a errores de clasificación si las regiones de interés (ROI) y las firmas espectrales no se adquieren adecuadamente.

Figura 5. a) Firmas espectrales para cada clase determinada. b) Firma espectral con rango de valores



Fuente: elaboración propia.

Por un lado, para mejorar los resultados se pueden intentar recopilar más ROI en estas áreas y entrenar el algoritmo para áreas muy similares. También se puede utilizar un umbral de firma para estas firmas, con el fin de reducir su variabilidad (solo se clasificarán píxeles muy similares a las firmas de entrada). Por otro lado, aparte de la información espectral en las cuatro bandas proporcionadas por


el flujo de trabajo con la plataforma P4M, se pueden utilizar, como entradas de datos para apoyo, la clasificación basada en objetos productos altimétricos derivados de las imágenes RGB (*.jpg), como Modelos Digitales de Superficie (MDS), de altura de la canopia (CHM) y espectrales, como el índice NDVI. Las pruebas 2 y 3 incluyen este tipo de información y se describen sus resultados a continuación.

Prueba 2

La figura 6 muestra los productos altimétricos derivados del procesamiento fotogramétrico de imágenes RGB. Se incluyen el Modelo Digital de Superficie (MDS) y el Modelo Digital de Terreno (MDT), junto con el modelo resultante de alturas de la vegetación (CHM). El MDS expone la topografía de la cubierta vegetal, mientras que el MDT muestra el relieve del suelo subyacente. La diferencia

entre estos modelos genera el CHM, que representa la altura de la vegetación normalizada al nivel del suelo. Este modelo desempeña un papel fundamental en la identificación y cuantificación de la estructura tridimensional de la vegetación, proporcionando una entrada de datos geométrica para la metodología de segmentación propuesta. El CHM es importado en el *software* QGIS versión 3.30.3 para los análisis espaciales posteriores.

Figura 6. Productos altimétricos provenientes del procesamiento fotogramétrico de las imágenes RGB (*.jpg)




Fuente: elaboración propia.

El análisis de la distribución de las alturas (figura 7a) determina un rango de alturas entre uno y seis metros para diferenciar entre el dosel de las plantas y el suelo. Luego, utilizando la fórmula (“chm@1” $\geq$ 1) AND (“chm@1” $\leq$ 6) en la calculadora ráster, se genera una clasificación binaria en la que el valor 1 representa la vegetación, y el valor 0, el suelo. La capa ráster resultante se convirtió en un vector utilizando la herramienta “Polygonize

(raster to vector)”, lo que facilitó la creación de un mapa binario que distingue claramente entre suelo y no suelo (figura 7b). Estos polígonos que representan la vegetación (valor 1 “no suelo”) se utilizaron para recortar las bandas multiespectrales originales (“Clip raster by Mask Layer”), eliminando así el suelo y preparando los datos para la clasificación supervisada con SCP en QGIS versión 3.30.3.

Figura 7. a) Histograma del Modelo Digital de Alturas (CHM) para la escena del sistema de cultivo de banano. b) Capa de suelo (color azul) que representan el rango de alturas entre 1 y 6 metros



Fuente: elaboración propia.


Se realiza la clasificación supervisada de las cuatro bandas, utilizando la información previamente extraída de suelo/no-suelo mediante el *plugin* SCP en QGIS versión 3.30.3. Las categorías incluyen sombras, hoja de banano y ruido vegetal. En esta etapa se crean áreas de muestreo para las categorías definidas, con el objetivo de registrar los valores de los píxeles que describen sus firmas espectrales para cada banda empleada.

Posteriormente, en el *plugin* SCP se accede a “Band Processing” y se selecciona “Classification”. Se opta por el algoritmo “Minimum Distance”, debido a su efectividad comprobada en clasificaciones, demostrada en la prueba 1, y se activa la opción “Create Vector”. Una vez segmentada la hoja de banano en forma de polígono *shapefile* (*.shp), se procede a recortar las bandas multiespectrales de manera similar a la sección anterior, dejando el ráster libre de ruido y sombras. Esto resulta en un producto final: un ráster limpio de la hoja de banano para cada banda.

Se procede al cálculo del Índice de Vegetación de Diferencia Normalizada (NDVI), utilizando las bandas de rojo (red) e infrarrojo cercano (NIR). Después se realiza un análisis detallado del NDVI, lo que incluye el cálculo de su histograma. En este análisis se utiliza la calculadora de ráster para filtrar todos los píxeles con valores NDVI inferiores o iguales a 0,3 ($\leq 0,3$). Luego, se procede a la vectorización (poligonización) del ráster resultante, utilizando la herramienta “Polygonize (raster to vector)”, y se calcula el centroide de estos polígonos con la herramienta “Centroids”. El producto obtenido es una nube de puntos que indica la presencia de posibles anomalías en las hojas o áreas sospechosas de enfermedad. Como resultado final, se genera una nube de puntos en formato *.shp que representa los indicios de enfermedad foliar basados en el análisis del NDVI, tal como se muestra en la figura 8. De este modo, el proceso de segmentación se basó en un análisis empírico del histograma de valores de NDVI. Mediante el proceso iterativo de filtrado con la calculadora ráster, se seleccionaron los rangos de NDVI que permitieron una óptima delimitación visual de las áreas de interés. Este proceso, si bien se apoyó en el juicio experto, se fundamentó en el análisis del comportamiento de

los histogramas, buscando rangos que maximizaran el contraste entre las áreas con y sin anomalías.

Figura 8. Nube de puntos en donde hay indicios de enfermedad foliar



Fuente: elaboración propia.

Prueba 3


Este vuelo se llevó a cabo sobre una zona caracterizada por una mayor densidad de cultivo, como se muestra en la figura 1a, y a una altitud reducida. No obstante, se mantuvieron constantes los parámetros especificados en la tabla 2. Este enfoque resultó en una mejora significativa del nivel de detalle de 0,6 cm por píxel, aunque sobre una extensión más limitada, aproximadamente 0,5 hectáreas. Para este nivel de detalle se utilizó Agisoft Metashape

para la generación de las bandas multiespectrales, debido a que Pix4D no pudo reconstruir de forma apropiada la geometría del vuelo.

El método de segmentación propuesto se implementó en tres categorías específicas: hojas de banano, suelo y sombras, utilizando las bandas, azul, verde, rojo y NIR, consistentes con los enfoques empleados en las pruebas 1 y 2. La metodología incluyó el cálculo del NDVI para toda la escena, como se muestra en la figura 9 (izquierda), facilitando la identificación de píxeles con valores

de NDVI inferiores a 0,3. Estos valores bajos por lo general sugieren una disminución en los contenidos de clorofila, lo que podría ser indicativo de lesiones o enfermedades foliares. Para la visualización de la detección de enfermedades se empleó un mapeo basado en el NDVI que señala posibles indicios de afecciones en las hojas, representados por medio de una capa de puntos. Cabe destacar la presencia tanto de falsos positivos como de potenciales evidencias de enfermedad foliar, detallados en la figura 9 (derecha).

Figura 9. Detección de indicios de enfermedad (puntos) foliar basado en el NDVI (izquierda) en el Test 3. Acercamiento a un sector (derecha)



Fuente: elaboración propia.

Discusión de resultados

A la luz de la evidencia de los resultados, la propuesta metodológica demuestra una capacidad aceptable para la segmentación foliar en sistemas de cultivo de banano, mediante imágenes multiespectrales de UAS. Los resultados obtenidos resaltan la capacidad de diferenciar la estructura foliar en áreas de cultivo tanto fragmentadas como densamente explotadas. Esta diferenciación es fundamental en aplicaciones de monitoreo de rutina y en la identificación temprana de enfermedades

foliares, lo cual es consistente con los hallazgos de estudios previos que enfatizan en la importancia de la teledetección en la agricultura de precisión [23, 24].

La detección de enfermedades en cultivos de banano mediante teledetección ha sido ampliamente explorada en la literatura. Congedo (2021) [25] demostró la eficacia de las imágenes hiperespectrales y un modelo PLS-PLR para la detección temprana de sigatoka negra, logrando una precisión del 98 %. De forma similar, [26] propusieron una Red neuronal convolucional híbrida para

clasificar enfermedades en banano, alcanzando un 99 % de precisión. Calou *et al.* 2020 [27] emplearon imágenes RGB de alta resolución obtenidas mediante UAV para monitorear la sigatoka amarilla, identificando que el algoritmo SVM ofreció el mejor desempeño (99,28 % de precisión general). Por su parte, Linero-Ramos *et al.* 2024 [28] evaluaron diferentes arquitecturas CNN usando imágenes multispectrales de drones para la detección de sigatoka negra, alcanzando un 86,5 % de precisión con MobileNetV2. Aunque estos estudios demuestran el gran potencial de la teledetección para el monitoreo de enfermedades en el banano, la complejidad logística relacionada con la adquisición y procesamiento de datos –en particular en el uso de imágenes hiperespectrales y algoritmos de aprendizaje profundo– puede limitar su implementación a gran escala. Nuestro estudio, al emplear un enfoque más accesible con imágenes multispectrales y análisis de índices de vegetación, busca facilitar su aplicabilidad en contextos de producción reales, promoviendo su uso práctico y rentable en el monitoreo fitosanitario de cultivos de banano.

La integración de procesos como diseño de vuelo, captura de imágenes, procesamiento fotogramétrico y explotación en SIG ha permitido la creación de ortoimágenes de alta precisión y modelos digitales de alturas forestales. Estos productos son fundamentales para la segmentación y clasificación precisa de la vegetación, lo que a su vez facilita la aplicación de índices de vegetación enfocados en la estructura foliar segmentada. La efectividad de esta metodología se ve reflejada en la capacidad de identificar anomalías en la estructura foliar que pueden indicar la presencia de enfermedades, corroborando la relevancia de la segmentación foliar en la detección temprana de patologías en cultivos [31].

La validación de la segmentación foliar ha revelado una diferenciación entre la vegetación y el suelo, lo que es esencial para cualquier análisis posterior relacionado con la salud de las plantas. Este resultado es un avance significativo en comparación con otras fuentes de imágenes de menor resolución (satelitales). Además, la capacidad de filtrar y vectorizar puntos anómalos en las hojas proporciona un insumo para la generación de mapas

de distribución espacial de enfermedades, contribuyendo a la tecnificación de los sistemas de producción de banano por parte de sus operarios [32].

El incremento en la frecuencia e intensidad de eventos climáticos extremos, acentuado por el cambio climático, resalta la urgencia de desarrollar sistemas de monitoreo avanzados y resilientes para prevenir y mitigar riesgos fitosanitarios vinculados con estas alteraciones ambientales [33]. La propuesta diseñada se vislumbra como una contribución para fortalecer la gestión sostenible de los sistemas de producción ante estas amenazas [7]; específicamente, la alternancia de periodos de intensas lluvias y sequías prolongadas, potenciada por el cambio climático, plantean desafíos significativos para los sistemas de producción de banano. Estas condiciones climáticas variables facilitan la proliferación de patógenos y vectores de enfermedades, alterando la incidencia y distribución espacial de enfermedades [34]. La propuesta metodológica de este estudio busca contribuir a la capacidad de realizar seguimientos sistemáticos de la estructura foliar, permitiendo la detección temprana de anomalías, en especial en cultivos afectados por cambios en los patrones climáticos, como los que se prevén en la región Caribe [7].

La adaptabilidad de esta metodología a distintas densidades de vegetación y resoluciones de imagen resalta su capacidad para monitorear los cambios en la salud de los cultivos bajo diferentes condiciones del cultivo. Lo anterior es esencial para adaptar las prácticas de gestión de los sistemas de producción dinámicos [1]. La capacidad demostrada de ajustar la metodología propuesta a las condiciones específicas de cada zona de cultivo será crítica para su aplicabilidad.

Sin embargo, es importante reconocer que la implementación de la propuesta metodológica en condiciones reales de operación presenta desafíos. La precisión de la segmentación puede verse afectada por factores como la calidad del entrenamiento de algoritmos y la similitud entre las firmas espectrales de diferentes clases de vegetación. Estos desafíos resaltan la necesidad de un entrenamiento adecuado y la selección cuidadosa de regiones de interés para la clasificación multispectral. Otras limitaciones incluyen la necesidad

de conocer las condiciones operativas específicas para la captura de imágenes (hora de muestreo, condiciones climáticas, etc.), altos requisitos de capacidad computacional y entrenamiento SIG especializado. Además, es importante destacar que la implementación de esta metodología aún carece de una amplia documentación en áreas críticas, como el Caribe colombiano, lo que resalta la necesidad de una mayor investigación para validar la efectividad de estas tecnologías geoespaciales en condiciones de operación reales.

Respecto a las condiciones ambientales de captura de imágenes, este estudio se realizó durante la etapa productiva de la plantación, y los vuelos se ejecutaron en horas del mediodía para minimizar la influencia de la variabilidad lumínica. No obstante, se reconoce que las condiciones ambientales, como la humedad y la nubosidad, pueden influir en la reflectancia espectral de las plantas [35]. Para mitigar estos efectos se utilizó un sensor de irradiancia solar integrado al dron, el cual registra las condiciones de luminosidad y permite la corrección de la incidencia de las condiciones lumínicas cambiantes en el posproceso y obtención de las ortoimágenes para cada banda multiespectral. Como estudios futuros, se propone evaluar el impacto de la variabilidad temporal en la identificación de anomalías, así como la realización de vuelos en diferentes momentos del día para analizar la influencia de las condiciones ambientales en la precisión de la clasificación.

Conclusiones

El presente estudio introduce una propuesta metodológica para la segmentación foliar en cultivos de banano mediante el uso de imágenes multiespectrales obtenidas por Sistemas Aéreos no Tripulados (UAS) y su posterior procesamiento fotogramétrico, junto con la explotación de sus productos en Sistemas de Información Geográfica (SIG). Esta metodología se articula en tres fases: primero, se capturan y procesan datos multiespectrales mediante un UAS equipado con un sensor multiespectral. Segundo, se efectúa una segmentación preliminar en SIG para diferenciar la vegetación del suelo y clasificar las hojas de banano

utilizando la información multiespectral obtenida. Por último, se aplica el cálculo del Índice de Diferencia Normalizada de Vegetación (NDVI) para detectar anomalías que podrían indicar la presencia de enfermedades y la creación de un mapa de distribución de las zonas afectadas.

Los resultados de este estudio tienen implicaciones prácticas en el manejo fitosanitario del banano. Para integrar esta tecnología a los sistemas de producción existentes, se propone una estrategia de transferencia de conocimiento que involucre a universidades, instituciones de formación técnica y tecnológica, asociaciones de bananeros y entidades gubernamentales. Esta estrategia debe incluir programas de capacitación y financiación para facilitar la adopción de la tecnología por parte de los agricultores.

Los resultados demuestran una capacidad aceptable para diferenciar la estructura foliar en áreas de cultivo, lo que permite la aplicación de índices de vegetación para el monitoreo rutinario y abre caminos hacia estrategias alternativas de detección temprana de enfermedades foliares. La adopción de este enfoque de segmentación foliar avanzaría hacia la tecnificación de los sistemas de producción de banano, en especial en la región del Caribe colombiano, ofreciendo medios con el uso de tecnologías UAS y geoespaciales avanzadas. La metodología propuesta adquiere mayor relevancia en el contexto del cambio climático, ya que asiste a la anticipación ante anomalías foliares detectadas, contribuyendo a asegurar la viabilidad de los sistemas de producción de banano a mediano y largo plazo.

Se reconocen ciertas limitaciones en la metodología, tales como la necesidad de condiciones operativas específicas para la captura de imágenes (época del año, hora del día, condiciones de luminosidad), elevados requisitos de capacidad computacional y entrenamiento especializado. Además, se identifica el desafío de la similitud entre las firmas espectrales de diferentes coberturas del cultivo, lo cual podría conducir a errores de clasificación, incluidas las falsas detecciones.

Para abordar estas limitaciones, se sugiere realizar estudios de reproducibilidad y replicabilidad que permitan evaluar la variabilidad de las mediciones en diferentes condiciones. Asimismo,

se propone la utilización de *software* libre, como WebODM, en lugar de opciones licenciadas y costosas como Pix4Dmapper Pro o Agisoft Metashape, que podrían limitar la posibilidad de replicar la metodología. Futuras investigaciones podrían realizar pruebas adicionales con el fin de validar la metodología en distintas condiciones ambientales y densidades de cultivo. Asimismo, se recomienda el desarrollo de algoritmos que permitan una mayor automatización de los procesos de segmentación y clasificación, optimizando así la reproducibilidad y eficacia de la propuesta metodológica.

Agradecimientos

Este artículo se enmarca en el proyecto *Sistemas Inteligentes para la Gestión de Recursos y Detección de Enfermedades en Sistemas de Producción de Banano en La Guajira y Magdalena*, con código 75979 (BPIN 2020000100417) de la convocatoria 008-2019 Mecanismo1-CONV2a (nombre genérico); buscó fortalecer las capacidades de investigación en instituciones de educación superior públicas, en colaboración con la Universidad del Magdalena y la Universidad de La Guajira.

Referencias

- [1] C. Atzberger, "Advances in remote sensing of agriculture: Context description, existing operational monitoring systems and major information needs," *Remote Sens.*, vol. 5, no. 2, pp. 949-981, 2013, doi: 10.3390/rs5020949.
- [2] R. P. Sishodia, R. L. Ray, and S. K. Singh, "Applications of remote sensing in precision agriculture: A review," *Remote Sens.*, vol. 12, no. 19, pp. 1-31, 2020, doi: 10.3390/rs12193136.
- [3] FAO, *The State of Food and Agriculture 2021: Making Agrifood Systems More Resilient to Shocks and Stress*. 2021.
- [4] S. Zhang, X. Li, Y. Ba, X. Lyu, M. Zhang, and M. Li, "Banana Fusarium Wilt Disease Detection by Supervised and Unsupervised Methods from UAV-Based Multispectral Imagery," *Remote Sens.*, vol. 14, no. 5, 2022, doi: 10.3390/rs14051231.
- [5] J. Alarcón y Y. Jiménez, "Manual de manejo fitosanitario del cultivo del plátano," 2012.
- [6] G. Rodríguez-Izquierdo, B. O. Olivares, O. Silva-Escobar, A. González-Ulloa, M. Soto-Suarez, and M. Betancourt-Vásquez, "Mapping of the Susceptibility of Colombian Musaceae Lands to a Deadly Disease: Fusarium oxysporum f. sp. cubense Tropical Race 4," *Horticulturae*, vol. 9, no. 7, 2023, doi: 10.3390/horticulturae9070757.
- [7] S. Noleppa, C. Gornott, S. Lüttringhaus, I. Hackenberg, and S. Gleixner, "Climate change and its effects on banana production in Colombia, Costa Rica, the Dominican Republic, and Ecuador," 2021.
- [8] M. X. Reyes Ortiz, "Proyecto de investigación en el entorno educativo, del uso de drones para agricultura de precisión, en fotogrametría, riego y fumigación en Colombia," pp. 1-13, 2023, doi: 10.26507/paper.3411.
- [9] M. X. Alfonso Rodríguez, "El uso de los drones y su impacto en la responsabilidad social empresarial de la agricultura de precisión en Colombia," Universidad Militar Nueva Granada, 2017.
- [10] M. Weiss, F. Jacob, and G. Duveiller, "Remote sensing for agricultural applications: A meta-review," *Remote Sens. Environ.*, vol. 236, no. August 2019, p. 111402, 2020, doi: 10.1016/j.rse.2019.111402.
- [11] S. Deenan, S. Janakiraman, and S. Nagachandrabose, "Image Segmentation Algorithms for Banana Leaf Disease Diagnosis," *J. Inst. Eng. Ser. C*, vol. 101, no. 5, pp. 807-820, Oct. 2020, doi: 10.1007/S40032-020-00592-5/METRIC5.
- [12] G. Dhingra, V. Kumar, and H. D. Joshi, "Study of digital image processing techniques for leaf disease detection and classification," *Multimed. Tools Appl.*, vol. 77, no. 15, pp. 19951-20000, Aug. 2018, doi: 10.1007/S11042-017-5445-8/METRIC5.
- [13] J. A. Guzmán-Álvarez, M. González-Zúñiga, J. A. Sandoval Fernández y J. C. Calvo-Alvarado, "Uso de sensores remotos en la agricultura: aplicaciones en el cultivo del banano," *Agron. Mesoam.*, vol. 33, no. 3, p. 48279, 2022, doi: 10.15517/am.v33i3.48279.
- [14] E. Omia *et al.*, "Remote Sensing in Field Crop Monitoring: A Comprehensive Review of Sensor Systems, Data Analyses and Recent Advances," *Remote Sens.*, vol. 15, no. 2, 2023, doi: 10.3390/rs15020354.
- [15] A. Bégué *et al.*, "Remote sensing and cropping practices: A review," *Remote Sens.*, vol. 10, no. 1, pp. 1-32, 2018, doi: 10.3390/rs10010099.

- [16] M. Gomez Selvaraj *et al.*, “Detection of banana plants and their major diseases through aerial images and machine learning methods: A case study in DR Congo and Republic of Benin,” *ISPRS J. Photogramm. Remote Sens.*, vol. 169, no. April, pp. 110-124, Nov. 2020, doi: 10.1016/j.isprsjprs.2020.08.025.
- [17] D. Mathew, C. Sathish Kumar, and K. Anita Cherian, “Foliar fungal disease classification in banana plants using elliptical local binary pattern on multiresolution dual tree complex wavelet transform domain,” *Inf. Process. Agric.*, vol. 8, no. 4, pp. 581-592, 2021, doi: 10.1016/j.inpa.2020.11.002.
- [18] FAOSTAT, “Food and Agriculture Organization of the United Nations. FAOSTAT database.” [Online]. Available: https://www.fao.org/faostat/es/#rankings/countries_by_commodity
- [19] Agisoft LLC, “Agisoft PhotoScan User Manual - Professional Edition, Version 1.2,” Agisoft LLC, St. Petersburg, Russia, 2016.
- [20] C. Draeyer, B., & Strecha, “Pix4D White paper-How accurate are UAV surveying methods,” Pix4D White Paper, Lausanne, Switzerland, 2014.
- [21] F. Nex and F. Remondino, “UAV for 3D mapping applications: A review,” *Appl. Geomatics*, vol. 6, no. 1, pp. 1-15, 2014, doi: 10.1007/s12518-013-0120-x.
- [22] P. Axelsson, “DEM Generation from Laser Scanner Data Using adaptive TIN Models,” *Int. Arch. Photogramm. Remote Sens.*, vol. 23, no. B4, pp. 110-117, 2000, doi: 10.1016/j.isprsjprs.2005.10.005.
- [23] D. Panagiotidis, A. Abdollahnejad, P. Surový, and V. Chiteculo, “Determining tree height and crown diameter from high-resolution UAV imagery,” *Int. J. Remote Sens.*, vol. 38, no. 8-10, pp. 2392-2410, 2017, doi: 10.1080/01431161.2016.1264028.
- [24] L. Congedo, “Semi-Automatic Classification Plugin: A Python tool for the download and processing of remote sensing images in QGIS,” *J. Open Source Softw.*, vol. 6, no. 64, p. 3172, Aug. 2021, doi: 10.21105/joss.03172.
- [25] J. Ugarte Fajardo *et al.*, “Early detection of black Sigatoka in banana leaves using hyperspectral images,” *Appl. Plant Sci.*, vol. 8, no. 8, pp. 1-11, 2020, doi: 10.1002/aps3.11383.
- [26] K. L. Narayanan *et al.*, “Banana Plant Disease Classification Using Hybrid Convolutional Neural Network,” vol. 2022, 2022.
- [27] V. B. Calou, dos S. Teixeira, L. C. Moreira, C. Lima, J. B. de Oliveira, and M. R. de Oliveira, “The use of UAVs in monitoring yellow sigatoka in banana,” *Biosyst. Eng.*, vol. 193, pp. 115-125, 2020, doi: 10.1016/j.biosystemseng.2020.02.016.
- [28] R. Linero-Ramos, C. Parra-Rodríguez, A. Espinosa-Valdez, J. Gómez-Rojas, and M. Gongora, “Assessment of Dataset Scalability for Classification of Black Sigatoka in Banana Crops Using UAV-Based Multispectral Images and Deep Learning Techniques,” *Drones*, vol. 8, no. 9, 2024, doi: 10.3390/drones8090503.
- [29] S. Liaghat and S. K. Balasundram, “A review: The role of remote sensing in precision agriculture,” *Am. J. Agric. Biol. Sci.*, vol. 5, no. 1, pp. 50-55, 2010, doi: 10.3844/ajabssp.2010.50.55.
- [30] Y. Huang, Z. Xin Chen, T. Yu, X. Zhi Huang, and X. Fa Gu, “Agricultural remote sensing big data: Management and applications,” *J. Integr. Agric.*, vol. 17, no. 9, pp. 1915-1931, 2018, doi: 10.1016/S2095-3119(17)61859-8.
- [31] R. Vidican *et al.*, “Using Remote Sensing Vegetation Indices for the Discrimination and Monitoring of Agricultural Crops: A Critical Review,” *Agronomy*, vol. 13, no. 12, pp. 1-27, 2023, doi: 10.3390/agronomy13123040.
- [32] T. R. Alabi, J. Adewopo, O. P. Duke, and P. L. Kumar, “Banana Mapping in Heterogenous Smallholder Farming Systems Using High-Resolution Remote Sensing Imagery and Machine Learning Models with Implications for Banana Bunchy Top Disease Surveillance,” *Remote Sens.*, vol. 14, no. 20, 2022, doi: 10.3390/rs14205206.
- [33] D. P. Bebber, M. A. T. Ramotowski, and S. J. Gurr, “Crop pests and pathogens move polewards in a warming world,” *Nat. Clim. Chang.* 2013 311, vol. 3, no. 11, pp. 985-988, Sep. 2013, doi: 10.1038/nclimate1990.
- [34] IPCC, *Climate Change 2014 Part A: Global and Sectoral Aspects*. 2014.
- [35] Z. Zhang and L. Zhu, “A Review on Unmanned Aerial Vehicle Remote Sensing: Platforms, Sensors, Data Processing Methods, and Applications,” *Drones*, vol. 7, no. 6, pp. 1-42, 2023, doi: 10.3390/drones7060398.

