

Despliegue del laboratorio al campo: Diseño de un Sistema de Imágenes Hiperespectrales aéreo para la detección Temprana de Sigatoka Negra.

Jorge Ugarte-Fajardo ^{1*}   Ximena Álvarez Macias²  Angel Torres Quijije ¹ 

¹ Universidad Técnica Estatal de Quevedo. Maestría en Ciencia de Datos. Quevedo. Ecuador

² Universidad de Guadalajara. Departamento de Postgrado de la Universidad de Guadalajara. Guadalajara. México

 Correspondencia: jugartef@uteq.edu.ec  + 593 996158120

DOI/URL: <https://doi.org/10.53313/gwj71111>

Resumen: En la actualidad, la agricultura se enfrenta al desafío del tratamiento de enfermedades de cultivos con fungicidas químicos, cuyos impactos negativos en la calidad de la fruta y el fomento de la resistencia del patógeno aumentan los costos y los daños ambientales. En este contexto, la detección temprana no destructiva de la Sigatoka Negra emerge como una estrategia clave para optimizar la aplicación de fungicidas y minimizar sus impactos adversos. Los Vehículos Aéreos No Tripulados (UAV) equipados con sensores y cámaras de alta resolución se han convertido en herramientas esenciales en actividades agrícolas, permitiendo la captura de imágenes de ultra alta resolución espacial y un rápido inicio de vuelo. Este estudio propone un diseño de sistema hiperespectral aerotransportado para la detección temprana de la Sigatoka Negra en plantaciones de banano. La metodología combina la teledetección aérea con técnicas de inteligencia artificial para una detección eficiente y precisa. Se establecen las especificaciones técnicas del sistema, que incluyen un espectrómetro ImSpector V10E y una cámara CMOS Kiralux montados en un dron, respaldados por una tarjeta inteligente Jetson Orin Nano 8 GB para procesamiento en tiempo real. Se recomienda la normalización y reducción de la dimensionalidad de los datos hiperespectrales para un análisis óptimo y la aplicación de técnicas de machine learning para la detección de la enfermedad. Los resultados experimentales en laboratorio muestran una alta precisión en la detección de la enfermedad, lo que destaca el potencial de esta metodología para una gestión agrícola más eficaz y sostenible.

Palabras claves: dron, imágenes hiperespectrales, espectrómetro, machine learning, Sigatoka negra, cultivo de banano.

Deployment from Laboratory to Field: Design of an Airborne Hyperspectral Imaging System for Early Detection of Black Sigatoka.

Abstract: Currently, agriculture faces the challenge of treating crop diseases with chemical fungicides, whose negative impacts on fruit quality and promotion of pathogen resistance increase costs and environmental damage. In this context, Green World Journal /Vol 07/ Issue 01/111/ January – April 2024 /www.greenworldjournal.com



Cita: Ugarte-Fajardo, J., Macias, X. Á., & Quijije, A. T. (2024). Despliegue del laboratorio al campo: Diseño de un Sistema de Imágenes Hiperespectrales aéreo para la detección Temprana de Sigatoka Negra. *Green World Journal*, 7(1), 111. <https://doi.org/10.53313/gwj71111>

Received: 23/January /2024

Accepted: 20/March /2024

Published: 27/March /2024

Prof. Carlos Mestanza-Ramón, PhD.
Editor-in-Chief / CaMeRa Editorial
editor@greenworldjournal.com

Editor's note: CaMeRa remains neutral with respect to legal claims resulting from published content. The responsibility for published information rests entirely with the authors.



© 2024 CaMeRa license, Green World Journal. This article is an open access document distributed under the terms and conditions of the license.

Creative Commons Attribution (CC BY).

<http://creativecommons.org/licenses/by/4.0>

non-destructive early detection of Black Sigatoka emerges as a key strategy to optimize fungicide application and minimize adverse impacts. Unmanned Aerial Vehicles (UAVs) equipped with high-resolution sensors and cameras have become essential in agricultural activities, allowing for the capture of ultra-high spatial resolution images and rapid flight initiation. This study proposes the design of a hyperspectral system airborne on a drone for early detection of Black Sigatoka in banana plantations. The methodology combines aerial remote sensing with artificial intelligence techniques for efficient and accurate detection. Technical specifications of the system are established, including an ImSpector V10E spectrometer and a Kiralux CMOS camera mounted on a drone, backed by an 8 GB Jetson Orin Nano smart card for real-time processing. Normalization and dimensionality reduction of hyperspectral data are recommended for optimal analysis and machine learning techniques for disease detection. Laboratory experimental results show high accuracy in disease detection, highlighting the potential of this methodology for more effective and sustainable agricultural management.

Keywords: drone, hyperspectral images, spectrometer, machine learning, Black Sigatoka, banana cultivation.

1. Introducción

La producción mundial de banano representa una actividad agrícola de magnitud global, constituyendo un pilar fundamental para la seguridad alimentaria, la generación de ingresos y el crecimiento industrial en diversas naciones. Asia, encabezada por India, China, Filipinas, lidera en el cultivo de bananos con una producción significativa, seguida de cerca por América Latina y África, donde países como Ecuador, Brasil, y Ghana se destacan como principales productores [1-2].

No obstante, las plantaciones de banano enfrentan una serie de desafíos fitosanitarios, siendo la Sigatoka Negra (BLSN, por sus siglas en inglés Black Sigatoka Disease) una de las mayores preocupaciones. Esta enfermedad foliar se ha consolidado como una amenaza grave para la producción bananera debido a su impacto devastador, llegando a ocasionar pérdidas de hasta un 80 % de los cultivos.

En la actualidad, los cultivos afectados se enfrentan al tratamiento con fungicidas químicos, los cuales, impactan negativamente en la calidad de la fruta y promueven la resistencia del patógeno, aumentando los costos asociados al control de la enfermedad y los daños ambientales [3]. En este escenario, la implementación de un pronóstico temprano no destructivo de la BLSN emerge como una estrategia clave. Este enfoque permite optimizar la aplicación de fungicidas, asegurando un control efectivo de las enfermedades de las plantas mientras se minimizan los impactos adversos en el medio ambiente, el desarrollo de resistencias y la presencia de residuos de pesticidas [4].

La detección de la Sigatoka negra ha sido un tema de gran interés para los investigadores durante años, con el propósito de controlar la propagación de la enfermedad. Actualmente, la identificación de la BLSN se lleva a cabo mediante métodos invasivos como pruebas de ADN o inmunológicas, además de la evaluación visual de los síntomas [5]. Sin embargo, los métodos moleculares y serológicos presentan limitaciones significativas, siendo tardíos y requiriendo operadores entrenados. A pesar de su sensibilidad, precisión y eficacia, estas técnicas son poco confiables en las etapas asintomáticas de los patógenos vegetales, y no son adecuadas para monitorear patógenos ocultos que han ingresado a las plantas antes de manifestar síntomas visibles [6]. Además, el muestreo desde el campo hasta el laboratorio es laborioso y debe realizarse correctamente, con reducida detección de enfermedades en pocas plantas [7].

Los métodos indirectos, conocidos como "Nueva Generación", aprovechan principalmente técnicas basadas en biomarcadores, como el perfilado de metabolitos de las interacciones planta-patógeno, como la imagenología y la espectroscopia utilizando drones (Figura 1). Con estos métodos indirectos, en particular el uso de drones, se puede estimar la enfermedad con mayor precisión en comparación con los métodos de diagnóstico moleculares, serológicos y microbiológicos [6].



Figura 1. Escaneo de cultivo de banano mediante un dron.

En el ámbito de la Agricultura de Precisión, se resalta el uso de tecnologías avanzadas, como los sistemas de imágenes hiperespectrales (HSI) y multiespectrales. El análisis de imágenes hiperespectrales ha facilitado la detección de enfermedades en diversas plantas al revelar cambios estructurales y químicos durante la patogénesis [10]. Investigaciones anteriores, abarcando una amplia gama de cultivos como remolacha [11], trigo [12], tomate [13], lechuga [14], arroz [15], cebada [16], tabaco [17], soya [18], entre otros [19], han contribuido al entendimiento de la relación entre las infecciones y las variaciones de las firmas espectrales de las hojas.

La utilización de sistemas hiperespectrales estacionarios con fines de detección de enfermedades en plantas de banano ha sido objeto de múltiples investigaciones llevadas a cabo en ambientes de laboratorio. Liao et al. exploraron las características espectrales-espaciales de las hojas de banano mediante el análisis de imágenes hiperespectrales de series temporales y el uso de operadores morfológicos avanzados [20]. Estas características, combinadas con una reconstrucción parcial, se ingresan en un clasificador que puede predecir la enfermedad en hojas de banano previamente infectadas. Bendini et al. calcularon índices de vegetación a partir de la reflectancia hiperespectral para caracterizar la Sigatoka Negra y la Amarilla [21]. Por otro lado, Krishnan et al. emplearon un procedimiento híbrido de fuzzy C-means para llevar a cabo la segmentación y clasificación de imágenes hiperespectrales [22]. Además, para la identificación de enfermedades en plantas de banano, se extraen características relacionadas con el color, la forma y la textura. Ugarte Fajardo et al. proponen la detección temprana de la BLSA en los estados presintomático, estadio 1 y estadio 2, resaltando la importancia crítica de la detección en estas etapas para la implementación oportuna de estrategias de control. La técnica de clasificación utilizada en este estudio fue PLS-PLR y HS-Biplot, logrando una precisión del 98% [23].

Para avanzar hacia la aplicación práctica de esta metodología y facilitar la transición del entorno de laboratorio al campo, el uso de la teledetección aérea (Remote Sensing) mediante drones (Vehículos Aéreos No Tripulados (UAV)), combinado con técnicas de inteligencia artificial, puede ser una manera eficiente y económica de detectar enfermedades en cultivos y plantas en una variedad de campos agrícolas, desde invernaderos hasta grandes explotaciones [24,25].

La detección automática de enfermedades en plantas a través de UAS (Unmanned Aerial Systems) es un campo que ha surgido en las últimas décadas con un gran potencial de investigación futura, dado que las enfermedades individuales pueden tener síntomas drásticamente diferentes en

muchas especies hospedantes diferentes [28]. Kurihara et al. presentaron un sistema de imágenes hiperespectrales equipado con un espectrómetro secuencial bidimensional montado en un UAV [29]. La tecnología de filtro sintonizable de cristal líquido se aplica al espectrómetro hiperespectral para el escaneo de longitudes de onda en 460–780 nm. Zarco-Tejada et al. llevaron a cabo la estimación del contenido de carotenoides foliares mediante el cálculo de índices de vegetación R_{515} / R_{570} utilizando imágenes hiperespectrales de alta resolución adquiridas desde un vehículo aéreo no tripulado (UAV), logrando estimar mapas que muestran la variabilidad espacial del contenido de carotenoides en las hojas [30]. Kang et al. evaluaron el uso del generador de imágenes hiperespectrales 'Headwall Nano-Hyperspec' a bordo de un sistema de aeronave pilotada remotamente (RPAS) DJI Matrice 600 Pro UAV para inspeccionar la salud de las plantas y la calidad del agua en Ontario [31]. En el estudio de Abdulridha et al., se utilizaron imágenes hiperespectrales (380–1020 nm) y un modelo de función de base radial (RBF) para desarrollar la detección de diferentes etapas de desarrollo de enfermedades (asintomática, temprana, intermedia y tardía) del mildiú polvoriento (PM) en calabaza. Los datos se recopilaban tanto en el laboratorio como en el campo utilizando un vehículo aéreo no tripulado (UAV) [13].

La capacidad de movilidad y flexibilidad proporcionada por la plataforma aérea puede superar las limitaciones geográficas y permitir la obtención de datos hiperespectrales en tiempo real. La transición de los sistemas hiperespectrales estacionarios a soluciones áreas utilizando drones representa una herramienta invaluable para los agricultores al proporcionar información precisa y oportuna que les permite tomar decisiones informadas y mejorar la eficiencia y productividad de sus operaciones agrícolas. El objetivo de esta investigación es presentar una propuesta de diseño para un sistema hiperespectral que utilice un dron como plataforma para la detección de la Sigatoka Negra en los cultivos de forma eficiente y precisa.

2. Materiales y métodos

La metodología se basó en tres etapas: el diseño del sistema hiperespectral aéreo, calibración del sistema, análisis de imágenes hiperespectrales.

2.1 Sistema Hiperespectral aéreo.

El sistema hiperespectral aerotransportado incluye cuatro componentes: sensor hiperespectral, cámara, computador y el dron.

2.1.1 Sensor Hiperespectral

El sensor hiperespectral o espectrómetro es un dispositivo diseñado para capturar el valor de reflectancia en una amplia gama de longitudes de onda dentro del espectro electromagnético.

Los sistemas hiperespectrales constan de cuatro componentes principales: la fuente de luz, las lentes, el espectrógrafo y el detector de área (Figura 6). En entornos de laboratorio para la obtención de imágenes hiperespectrales (HSI), generalmente se emplean lámparas halógenas y LED como fuentes de luz, mientras que los sistemas HSI aerotransportados utilizan la radiación solar. Las lentes de objetivo definen el enfoque de la luz entrante en el detector, creando cada píxel en la imagen resultante. El espectrómetro, una parte esencial del sistema HSI, utiliza una rejilla de difracción para descomponer la luz entrante en diferentes longitudes de onda. El detector de área convierte los fotones en energía eléctrica, la cual se digitaliza posteriormente. El dispositivo de carga acoplada (CCD) es el detector más comúnmente utilizado para este propósito, conformado por fotodiodos dispuestos en una matriz 1D o 2D. Como alternativa, el sensor CMOS ofrece una mayor velocidad y un menor costo [42].




Figura 6. Diagrama esquemático de un espectrómetro [9].

Existen cuatro técnicas disponibles para la adquisición de imágenes hiperespectrales: exploración por punto (whisk-broom), barrido por línea (push-broom), barrido por área (spectral scanning) y captura instantánea (shot non-scanning) (Figura 7).

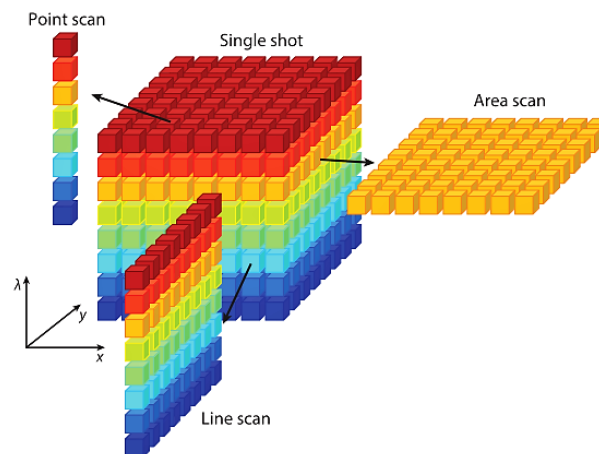


Figura 7. Métodos de adquisición de imágenes hiperespectrales [43].

El ImSpector V10E (SPECIM) es un escáner de línea (push-broom) que ha sido evaluado en varios trabajos de investigación con resultados sobresalientes [23, 47, 48]. El ImSpector V10E presenta diversas ventajas, como una excelente resolución espectral, una alta velocidad de adquisición de datos y está equipado con un sensor CMOS de alta sensibilidad. Esto asegura una calidad de imagen excelente incluso en condiciones de iluminación desafiantes en tiempo real. Además, gracias a su diseño compacto y ligero, es fácil de integrar en diversas plataformas, lo que lo convierte en una opción ideal para aplicaciones móviles y de campo [49,50].

2.1.2 Cámara

El sistema HSI propuesto se compone de un espectrómetro ImSpector V10E (Spectral Imaging Ltd.) conectado a una cámara CMOS Kiralux de 2.3 MP (Thorlabs) montados en un dron con las características indicadas en el apartado anterior. El espectrómetro puede ser acoplado e integrado con la cámara monocromática utilizando un montaje estándar C-mount para construir una cámara hiperespectral de imagen lineal.

La cámara CMOS Kiralux de 2.3 MP (Thorlabs) está diseñada para aplicaciones científicas y técnicas que requieren imágenes precisas y detalladas. Su alta resolución permite obtener imágenes nítidas y claras para una amplia variedad de aplicaciones. Incorpora un sensor CMOS avanzado que proporciona una excelente sensibilidad a la luz y un rendimiento óptimo en condiciones de iluminación variable. Además, la cámara Kiralux está equipada con una interfaz estándar que facilita su integración con el sensor hiperespectral. Gracias a su diseño compacto y robusto, es ideal para su uso en sistemas aerotransportados.

2.1.3 Computador

El sistema computacional en un sistema aerotransportado demanda una alta capacidad de procesamiento y almacenamiento de imágenes en tiempo real, manteniendo un perfil físico reducido para no comprometer las condiciones de vuelo del dron. Unidades de almacenamiento de gran capacidad, como discos duros SSD de tamaño considerable, ofrecen el espacio necesario para almacenar grandes volúmenes de datos de imágenes hiperespectrales. Además, una potente unidad de procesamiento, como el miniordenador Jetson Orin Nano, posibilita el análisis y procesamiento eficiente de imágenes mientras el dron se encuentra en vuelo. Esta capacidad de procesamiento en tiempo real es esencial para aplicaciones que requieren respuestas rápidas y toma de decisiones instantáneas, como la detección de enfermedades en cultivos.

2.1.4 Dron

Los drones se han categorizado en dos tipos principales según el movimiento de las alas, es decir, de ala fija y de ala rotatoria. Los primeros son drones de despegue y aterrizaje en pista, mientras que los segundos son de despegue y aterrizaje vertical (Vertical Take-Off and Landing) [51] [52]. Los más utilizados en la actividad agrícola son los multirrotores cuadricópteros que tienen un tiempo de vuelo de 30 minutos y pueden cubrir hasta 65 hectáreas por vuelo [53].

Los drones multirrotor rotativos pueden volar a altitudes más bajas, y sus cámaras ofrecen una resolución superior de la distancia de muestreo en tierra (GSD). Dependiendo del número de rotores, pueden ser de tres (tricópteros), cuatro (cuadricópteros), seis (hexacópteros) y ocho (octocópteros). Algunas ventajas de este tipo de drones incluyen el despegue y aterrizaje vertical, la capacidad de capturar medidas de plantas muy detalladas, la capacidad de recuperación automática, la capacidad de flotar y volar a baja altura, aunque tienen baja velocidad y poca resistencia [6].

2.2 Calibración del sistema

La calibración del sistema para asegurar un adecuado escaneo de las imágenes se requiere la aplicación de métodos estándar de calibración espectral, radiométrica y espacial.

De acuerdo con la investigación realizada por Ochoa et al., la calibración espectral se realiza utilizando lámparas de descarga que contienen gases como mercurio (Hg), argón (Ar) y helio, las cuales emiten líneas espectrales específicas. Estas líneas se utilizan para estimar la longitud de onda correspondiente a cada píxel del dispositivo de acoplamiento de carga (CCD). Los espectros generados permiten calibrar las posiciones de las bandas espectrales en la imagen [54].

El resultado de la calibración del sistema hiperespectral estacionario se puede expresar mediante la relación definida por la siguiente ecuación:

$$\lambda(\text{row}_i) = 0,000022 * \text{row}_i^2 + 0,586019 * \text{row}_i + 386,829(\text{nm}) \quad (1)$$

Donde,

row_i es la posición de la banda espectral

$\lambda(\text{row}_i)$ es la longitud de onda en la posición row_i

La calibración radiométrica se utiliza para disminuir la influencia de las variaciones en la intensidad de la luz y el ruido del sensor CCD. Con este fin, se capturaron imágenes de referencias blancas y negras. La normalización de la imagen espectral en bruto se realiza utilizando la siguiente ecuación:

$$R_{\lambda} = \frac{I_{\lambda} - D_{\lambda}}{W_{\lambda} - D_{\lambda}} \quad (2)$$

(2)

Donde,

R_{λ} es la reflectancia en la longitud de onda λ .

I_{λ} es la intensidad de luz medida en la longitud de onda λ .

W_{λ} es la intensidad de referencia (blanco) medida en la longitud de onda λ .

D_{λ} es la intensidad obtenida por el sensor cuando no recibe luz (negro).

La calibración espacial implica ajustar el movimiento del dispositivo de transporte para evitar el submuestreo o sobremuestreo de los frames capturados (líneas de barrido). Cuando el espectrómetro se desplaza demasiado rápido, se obtiene información incompleta del objeto o submuestreo. Por el contrario, si el espectrómetro se mueve muy lentamente, se registra información redundante, lo que provoca la superposición de regiones o sobremuestreo. Para abordar este problema, se ajusta la velocidad y la altura de vuelo del dron.

2.3 Análisis de imágenes hiperespectrales

Tomando en cuenta los prometedores resultados obtenidos en la investigación realizada por [23] que utilizaron un sistema hiperespectral estacionario basado en el espectrómetro Inspector V10E, se estableció el procedimiento que se detalla a continuación para analizar los cubos hiperespectrales.

2.3.1 Preprocesamiento de imágenes

Con el fin de excluir las áreas de las imágenes que no sean relevantes para el análisis de la vegetación y, por consiguiente, identificar las regiones de interés, se sugiere aplicar una técnica de segmentación basada en la imagen a una longitud de onda de 700 nm. De esta manera, se puede utilizar la intensidad de los píxeles para diferenciar entre las plantas y el fondo en las imágenes.

Para corregir las disparidades de escala en las mediciones de reflectancia, ocasionadas por efectos como la longitud de trayectoria, variaciones en la fuente o el detector, y otros factores asociados a la sensibilidad instrumental, así como para mitigar las variaciones de reflectancia derivadas de la orientación relativa entre la superficie de la hoja y el sensor, se procedió a normalizar cada cubo hiperespectral mediante la técnica de varianza normal estándar (SNV) (Ec. 3).

$$x_{inorm} = \frac{x_i - \bar{x}_i}{\sigma_i} \quad (3)$$

Donde,

x_{inorm} es la reflectancia normalizada para una posición i .

x_i es la reflectancia sin normalizar en una posición i .

\bar{x}_i es la media de la reflectancia en todas las longitudes de onda para una posición i .

σ_i es la desviación estándar de la reflectancia en una posición i .

Para concluir, se llevó a cabo una reducción de la dimensionalidad del cubo hiperespectral, mediante el cálculo del promedio de los valores de reflectancia registrados en cada longitud de onda. Esto generó un vector espectral para cada imagen, el cual representa la firma espectral. En la Figura 7, se presentan las firmas espectrales correspondientes a hojas de banana, tanto sanas como infectadas, en diferentes niveles de gravedad de la enfermedad.

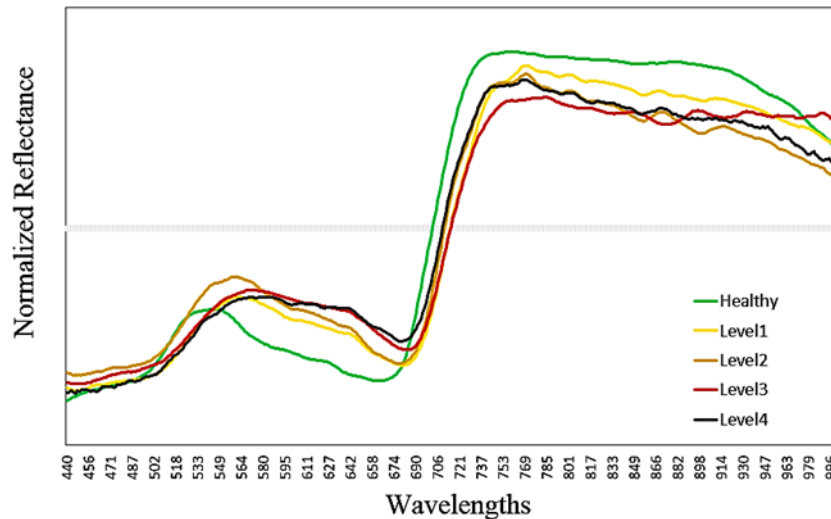


Figura 7. Firmas espectrales de regiones sanas y enfermas.

2.3.2 Entrenamiento y validación de modelos machine learning.

Dada la disposición tabular de los datos, es viable utilizar técnicas de aprendizaje automático para la clasificación de imágenes. Entre estas técnicas que han demostrado una clasificación efectiva con niveles de precisión elevados se incluyen: máquinas de vectores soporte (SVM), mínimos cuadrados parciales análisis discriminante (PLS-DA), redes neuronales artificiales perceptrón multicapa (ANN-MLP), mínimos cuadrados parciales regresión logística penalizada PLS-PLR entre otras. El algoritmo PLS-PLR, propuesto por Ugarte Fajardo et al., (2020), integra la reducción de dimensionalidad de PLS con la regresión logística, siendo particularmente efectiva para la clasificación binaria de datos con alta dimensionalidad y multicolinealidad. Asimismo, en otro estudio realizado por Ugarte Fajardo et al., (2022), se llevó a cabo una comparación entre los resultados obtenidos con el modelo PLS-PLR y aquellos generados con SVM, ANN-MLP y NPLS-DA. Para el entrenamiento de los modelos se empleó validación cruzada, seguida de una evaluación del desempeño mediante una prueba de validación externa. En cada fase de evaluación se consideraron métricas de predicción tales como exactitud, precisión, sensibilidad e índice F1. Además, en la prueba de validación externa se incorporó la índice área bajo la curva ROC (AUC) para cada modelo.

3 Resultados

3.1 Descripción del UAV

Plataforma de cuadricóptero con despegue y aterrizaje vertical equipado con cuatro motores alimentados por una batería que puede volar mediante control remoto o de forma autónoma con la ayuda de su receptor de Sistema de Posicionamiento Global (GPS) y su sistema de navegación por puntos de referencia.

Las especificaciones técnicas y condiciones operativas del UAV se muestran en la Tabla 1.

Tabla 1. Especificaciones técnicas y condiciones operativas del UAV

Descripción	valor
Velocidad de ascenso mínimo:	5 m/s
Velocidad de funcionamiento mínimo:	10 m/s
Empuje mínimo:	100 N
Carga mínima:	5 kg
Tiempo de vuelo mínimo:	50 minutos
Batería:	LiPo recargable ¹
Motores:	motores de núcleo plano ²
Hélice:	optimizada CFD ³
Carcasa:	de carbono (cerrada)
Protección:	IP43 ⁴
Temperatura:	hasta 50 °C
Humedad:	máx. 90% h.r.
Susceptibilidad al viento mínima:	imágenes sin vibraciones de hasta 6 m/s
Alcance de vuelo:	mín. 500 m con mando a distancia.
Techo de servicio:	mínimo 500 m ASL (Above Sea Level)
Altitud de despegue:	min 1000 m above sea level.

¹Baterías recargables de ion de litio (LiPo): Estas baterías recargables están fabricadas con polímero de ion de litio y son ampliamente utilizadas en dispositivos electrónicos. Se destacan por su alta densidad energética y su larga vida útil.

²Motores de núcleo plano: Los motores planos son motores eléctricos que tienen un diseño plano en forma de disco. Son empleados en drones debido a su tamaño compacto, peso ligero y eficacia.

³Hélice optimizada CFD: dinámica de fluidos computacional (CFD, por sus siglas en inglés) es una técnica de simulación utilizada para optimizar su rendimiento aerodinámico. Al aplicar CFD al diseño de las hélices de un dron, se pueden simular diferentes geometrías y configuraciones de hélices para determinar cuál proporciona el mejor rendimiento en términos de eficiencia, empuje, resistencia y otros factores.

⁴Protección IP43: La clasificación de protección IP43 indica el nivel de protección contra la entrada de sólidos y líquidos según la norma IP (Ingress Protection). IP43 significa que el dron está protegido contra objetos sólidos de tamaño moderado (I4) y contra salpicaduras de agua (P3), aunque no es completamente resistente al polvo ni al agua.

3.2 Descripción del sensor hiperespectral

La serie Enhanced ImSpector V10E (Figura 8) ofrece un rendimiento mejorado y está diseñada para aplicaciones que requieren alta resolución espacial o espectral. Cuenta con controles avanzados de distorsión espectral y se adapta a detectores de mayor tamaño con más píxeles y más pequeños.

Tabla 2. Especificaciones técnicas del ImSpector V10E

Descripción	valor
Resolución espectral	2.8 nm
Tamaño de la imagen	spectral 6.15mm, spatial 14.2mm
Longitud de onda	400 - 1000 nm

Dispersión	97.5 nm / mm
Apertura numérica	F/2.4 ¹
Ancho de la rendija	30 μ m
Longitud de la rendija	14.2 mm
Montura de lente y cámara	Standard C-mount adapter
Profundidad de bits	8 bit
Dimensiones	(W) 60 x (H) 60 x 175 mm
Peso	1100 g

¹La notación "F/2.4" define la cantidad de luz que puede ser recogida y enfocada por el sistema óptico del espectrómetro. El término "F" hace referencia a la distancia focal del sistema óptico del espectrómetro, mientras que "2.4" representa la relación entre dicha distancia focal y el diámetro de la apertura de la lente de entrada.




Figura 8. Vista del espectrómetro ImSpector V10E.

3.2 Descripción de la cámara

En la Tabla 3 se muestran las especificaciones de la cámara.

Tabla 3. Especificaciones técnicas de la cámara CMOS Kiralux de 2.3 MP (Thorlabs).

Descripción	Valor
Modelo	CS235MU
Resolución	2.3 Megapixels (1920 x 1200)
Sensor	Monochrome
Modo de Exposición	Global Shutter
Interfaz y Cable Incluido	USB 3.0
Disparador de Entrada/Salida	Yes
Área de Imagen (Horizontal x Vertical)	11.251 mm x 7.032 mm
Tamaño de Píxel	5.86 μ m, Square
Formato Óptico	1/1.2"
Velocidad Máxima de Fotogramas	39.7 fps
Resolución del Convertidor	12 Bits
Analógico-Digital (ADC)	
Tipo de Obturador del Sensor	Global Shutter
Eficiencia Cuántica Máxima	78%
Ruido de Lectura	<7 e ⁻ RMS
Velocidad del Reloj del Píxel	99 MHz
Agrupamiento de Píxeles Vertical y Horizontal	1 x 1 to 16 x 16

Región de Interés (ROI)	92 x 4 Pixels to 1920 x 1200 Pixels, Rectangular
Montura de Lente	C-Mount
Características de Montaje	Two 1/4"-20 Taps for Post Mounting, 30 mm
Interfaz	Cage Compatible USB 3.0
Consumo de Energía	3.25 W @ 39.7 fps (Full Sensor ROI)
Temperatura Ambiente de Operación	50 to 104 °F (10 °C to 40 °C) (NonCondensing)
Temperatura de Almacenamiento	32 to 131 °F (0 to 55 °C)



Figura 9. Vista de la cámara CMOS Kiralux CS235MU.

3.3 Unidad de procesamiento y almacenamiento

Se recomienda utilizar una tarjeta inteligente Jetson Orin Nano 8 GB (NVIDIA) con un disco duro SSD de 1TB para manejar las tareas de almacenamiento de imágenes hiperespectrales antes de su posterior procesamiento. La unidad Jetson Orin Nano está habilitada para llevar a cabo el procesamiento en tiempo real.

El Jetson Orin Nano 8GB (Figura 9) es una potente computadora de placa única diseñada para vehículos autónomos y aplicaciones robóticas. Tiene 8 GB de memoria y una arquitectura GPU Turing, lo que lo hace adecuado para una amplia gama de aplicaciones, incluidas visión por computadora, inteligencia artificial y aprendizaje automático. Se trata de un dispositivo pequeño y ligero que mide sólo 70 x 45 mm y pesa menos de 500g, lo que facilita su uso y transporte. Además, cuenta con opciones avanzadas de conectividad, bajo consumo de energía y capacidad para operar en diversos entornos de temperatura, lo que lo convierte en una excelente opción para aplicaciones agrícolas.

Su consumo de energía está clasificado en un máximo de 15 W. Este dispositivo no tiene conectividad de pantalla, ya que no está diseñado para tener monitores conectados a él. Más bien, está destinado para su uso en computadoras portátiles y utilizará la salida del dispositivo móvil anfitrión. El Jetson Orin Nano de 8 GB está conectado al resto del sistema utilizando una interfaz PCI-Express 4.0 x4. La tarjeta mide 70 mm de longitud, 45 mm de ancho y cuenta con una solución de enfriamiento integrada. Su precio en el lanzamiento fue de 299 dólares estadounidenses.

Tabla 4. Especificaciones técnicas de la tarjeta Jetson Orin Nano 8GB

Descripción	valor
AI Performance	40 TOPS (Tera Operations per Second)
GPU	1024-core NVIDIA Ampere architecture GPU with 32 Tensor Cores
GPU Max Frequency	625MHz

CPU	6-core Arm® Cortex®-A78AE v8.2 64-bit CPU 1.5MB L2 + 4MB L3
CPU Max Frequency	1.5 GHz
Memory	8GB 128-bit LPDDR5 68 GB/s
Storage	(Supports external NVMe)
Video Encode	1080p30 supported by 1-2 CPU cores
Video Decode	1x 4K60 (H.265) 2x 4K30 (H.265) 5x 1080p60 (H.265) 11x 1080p30 (H.265)
CSI Camera	Up to 4 cameras (8 via virtual channels) 8 lanes MIPI CSI-2 D-PHY 2.1 (up to 20Gbps)
PCIe	1 x4 + 3 x1 (PCIe Gen3, Root Port, & Endpoint)
USB	3x USB 3.2 Gen2 (10 Gbps) 3x USB 2.0
Networking*	1x GbE
Display	1x 4K30 multi-mode DP 1.2 (+MST)/eDP 1.4/HDMI 1.4
Other I/O	3x UART, 2x SPI, 2x I2S, 4x I2C, 1x CAN, DMIC & DSPK, PWM, GPIOs
Power	7W – 15W
Mechanical	69.6mm x 45mm 260-pin SO-DIMM connector



Figura 9. Vista de la Unidad Jetson Orin Nano.

3.4 Análisis de los datos recopilados durante las pruebas experimentales

Utilizando el sistema hiperespectral de laboratorio se recopiló un conjunto de imágenes hiperespectrales compuesto por un total de 104 imágenes (16 no infectadas, 16 pre-sintomáticas, 54 de gravedad 1 y 18 de gravedad 2)[23]. Estas imágenes fueron sometidas a procesos de calibración y preprocesamiento, generando una matriz de dimensiones 104 filas por 520 columnas. Cada fila representa la firma espectral de una hoja, mientras que las columnas corresponden a las 520 longitudes de onda en las que se realizó la evaluación de la reflectancia. Para el entrenamiento del modelo PLS-PLR, se utilizó un coeficiente de regularización Ridge de $\lambda=0.1$. Este modelo exhibió un ajuste a los datos sobresaliente con los resultados de las métricas de bondad de ajuste diferencia de devianza, R^2 de CoxSnell, R^2 de Nagekerke, R^2 de MacFadden que se presentan en la Tabla 5.

Tabla 5. Medidas de bondad de ajuste del modelo PLS-PLR.

Diff-Deviance	R ² CoxSnell	R ² Nagelkerke	R ² MacFadden
88.488	0.573	0.994	0.991

El modelo fue sometido a una evaluación de su desempeño mediante una prueba de validación utilizando el método de validación cruzada leave-one-out (LOOCV). Como resultado de este proceso, se logró clasificar correctamente 102 hojas como no infectadas o infectadas, obteniendo así una destacada precisión general de clasificación del 98%. Es importante destacar que todas las hojas infectadas en diferentes etapas de la enfermedad fueron clasificadas con exactitud, mientras que solo 2 hojas no infectadas fueron erróneamente clasificadas. El valor predictivo positivo alcanzó un 98%, y la sensibilidad, o recall, se situó en un 100%, lo que subraya la eficacia y fiabilidad del modelo en la detección precisa de la enfermedad en las hojas. La figura 10 muestra los valores de probabilidad de infección de cada hoja.

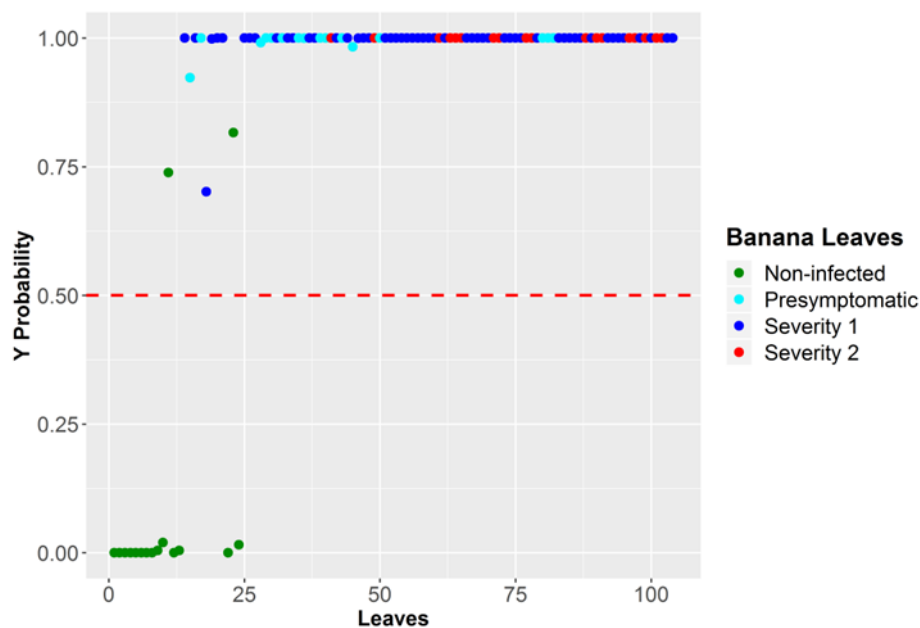


Figura 10. Probabilidad estimada por PLS-PLR con validación cruzada.

La comparación de los resultados del rendimiento de los modelos PLS-PLR, NPLS-DA, SVM y MLP reveló su elevada capacidad predictiva. Los resultados de las métricas de rendimiento evaluadas durante el entrenamiento de los modelos se presentan en la Tabla 6 [55].

Tabla 6. Métricas de predicción en fase de entrenamiento.

ENTRENAMIENTO				
Modelos	Exactitud	Precisión	Sensibilidad	F1
PLS-PLR	0.98	0.98	1	0.99
NPLS-DA	0.9	1	0.88	0.94
SVM lineal	1	1	1	1
SVM polinómico	1	1	1	1

MLP 1 capa oculta	1	1	1	1
MLP 2 capas ocultas	1	1	1	1

Los modelos PLS-PLR, SVM y MLP clasificaron correctamente todos los datos de entrenamiento, mientras que el modelo NPLS-DA no logró la separación de las clases.

En las pruebas de validación, todos los modelos arrojaron resultados similares, aunque el modelo PLS-PLR mostró una mayor precisión. El modelo NPLS-DA obtuvo las calificaciones más bajas según se muestra en la Tabla 7.

Tabla 7. Métricas de predicción en fase de validación.

VALIDACIÓN				
Modelos	Exactitud	Precisión	Sensibilidad	F1
PLS-PLR	0.94	0.94	0.94	0.94
NPLS-DA	0.91	0.88	0.94	0.91
SVM lineal	0.94	0.89	1	0.94
SVM polinómico	0.94	0.89	1	0.94
MLP 1 capa oculta	0.94	0.89	1	0.94
MLP 2 capas ocultas	0.94	0.89	1	0.94

El índice AUC fue de 0.94 para los modelos PLS-PLR, SVM y MLP, mientras que el modelo NPLS-DA obtuvo un valor de 0.91. Estos resultados indican una capacidad de discriminación muy buena en todos los modelos evaluados.

4 Discusión

La agricultura de precisión representa un factor clave en la revolución agrícola. Entre los beneficios que ofrece se encuentran la ayuda para definir las propiedades y características del suelo que permitan una productividad óptima, ayuda al uso eficiente de los recursos, reducir los costos y mitigar el impacto medioambiental. El uso de tecnologías avanzadas permite la aplicación focalizada de los productos fitosanitarios, controlar el funcionamiento de los equipos en tiempo real, hacer estimaciones de rendimientos y la identificación enfermedades de las plantas que se basan en métodos no destructivos en etapas iniciales permitiendo la gestión oportuna para evitar la propagación de la enfermedad y minimizar el efecto de los fungicidas en el medio ambiente.

El avance en la miniaturización de los sensores hiperespectrales permite su integración en vehículos aéreos no tripulados (UAVs), lo que promete revolucionar la detección de problemas agrícolas, incluso para pequeños agricultores. Los drones, equipados con múltiples motores, pueden volar con agilidad, mantenerse estables en un punto y realizar maniobras rápidas, lo que los hace ideales para diversas tareas en el campo.

Los sensores hiperespectrales registran la energía reflejada por una fuente de luz y generan firmas espectrales únicas de las hojas de banano, que pueden utilizarse para detectar la Sigatoka negra y otras enfermedades. La calidad de estas señales espectrales está influenciada por diversos factores, como el sistema del sensor (lentes, espectrógrafo y detector de área), la escala de medición (hoja, planta o campo) y el análisis e interpretación de los datos. Dado que la recolección y el

procesamiento de imágenes en estos sistemas pueden sufrir una pérdida significativa de información debido a la obstrucción de la luz por el dosel vegetal, los sensores de imagen de corto alcance suelen estar más cerca del suelo y pueden llevar a cabo inspecciones agrícolas estratégicas. Estos sensores hiperespectrales compactos (de 1 a 2 kg) contienen cientos de bandas estrechas en el rango del infrarrojo cercano y pueden ser desplegados rápidamente en diferentes vehículos, tanto tripulados como no tripulados.

El sistema aéreo de imágenes propuesto fusiona tecnologías de imágenes hiperespectrales con avanzadas técnicas de análisis de datos para predecir enfermedades vegetales con alta precisión, basándose en los cambios en la reflectancia provocados por la presencia de patógenos [27]. Estudios de laboratorio han demostrado que los síntomas de la enfermedad pueden aumentar la reflectancia espectral en el rango visible (400–700 nm) y disminuirla en el infrarrojo cercano (700–1100 nm) [56]. Estos cambios en la reflectancia, asociados con alteraciones en la estructura de la hoja y la composición química del tejido, se observan durante la progresión de la patogénesis, desde el tejido clorótico al necrótico [57]. Plantas presintomáticas que no muestran clorosis ni necrosis pueden ser clasificadas correctamente por el sistema, lo que sugiere a pesar de la ausencia de síntomas visibles, ocurren cambios en las hojas de estas plantas infectadas.

La detección de enfermedades en los cultivos de banano mediante sistemas aéreos de imágenes puede ser complementada eficazmente con un sistema de aplicación de fertilizantes montado en drones. La aplicación de fungicidas constituye una parte fundamental de las estrategias de control implementadas en las etapas tempranas de las enfermedades. La aplicación selectiva y precisa de estos fungicidas permite controlar el daño ambiental, mejorar la salud de los cultivos y reducir los costos de producción. Estas aplicaciones, comúnmente realizadas mediante pulverizadores terrestres y equipos de aplicación aérea, pueden ser llevadas a cabo de manera efectiva utilizando vehículos aéreos no tripulados (UAVs) operados de forma remota. Estos drones pueden ser controlados con contacto visual directo del operador con la aeronave o de forma autónoma a lo largo de trayectorias preprogramadas utilizando tecnología GPS.

Investigaciones futuras deben enfocarse en la implementación del sistema hiperespectral montado en drones para mejorar la detección de diferentes niveles de gravedad de enfermedades en el campo agrícola, considerando otros factores que puedan provocar cambios espectrales. Este estudio tiene el potencial de mejorar el potencial de los drones en la evaluación de enfermedades en plantas para promover una agricultura sostenible, minimizando las pérdidas de rendimiento, reduciendo la aplicación de tratamientos químicos y respaldando estrategias de agricultura informadas y oportunas.

5 Conclusión

Los sistemas de imágenes hiperespectrales ofrecen un enfoque no destructivo y no invasivo para analizar enfermedades en plantas. Los progresos tecnológicos posibilitan contar con computadoras de mayor capacidad de almacenamiento de datos y más rápidas, detectores de mayor resolución y técnicas avanzadas para el análisis de imágenes hiperespectrales, lo que permite detectar enfermedades en las plantas incluso en etapas tempranas. La detección temprana de enfermedades infecciosas desempeña un papel crucial tanto en las estrategias de tratamiento como de prevención.

El objetivo principal de este estudio es proponer un sistema basado en un UAV equipado con cámaras hiperespectrales para la detección temprana de la Sigatoka negra en plantaciones de banano. Se establecen las especificaciones técnicas y configuración de los dispositivos empleados para generar imágenes con la alta resolución espectral necesaria para identificar las plantas infectadas con Sigatoka negra en los campos de banano. Esta propuesta tiene como propósito

fomentar el interés en el uso de drones en la agricultura para la detección de enfermedades en las plantas, respaldado por los resultados experimentales obtenidos en el laboratorio.

Los desafíos principales que enfrentan los vehículos aéreos no tripulados (UAV), específicamente los drones, en la agricultura de precisión abarcan la carga útil, el costo del UAV, la duración del vuelo, el análisis de datos, las condiciones ambientales y los requisitos operativos. En la actualidad, los fabricantes de tecnología ofrecen soluciones compactas con sensores integrados que abordan estos problemas en la utilización de los drones. Los sensores montados en los drones generan grandes volúmenes de datos que requieren ser almacenados, procesados y analizados de manera adecuada mediante software especializado, un desafío que ha sido mitigado con los avances tecnológicos. Asimismo, las condiciones climáticas como las precipitaciones pluviales, las nubes y la niebla constituyen otro factor limitante para las operaciones de los drones, afectando su movilidad y capacidad de percepción.

Contribución de autores: Este trabajo se llevó a cabo en colaboración entre todos los autores: conceptualización, J.U. e A.T.; metodología, J.U. e A.T.; software, J.U.; validación, J.U.; análisis formal, J.U., X.A. A.T.; investigación, J.U., X.A. e A.T.; recursos, A.T.; curaduría de datos, J.U.; redacción-revisión y edición, J.U., X.A. e A.T.; visualización, J.U., X.A.; supervisión, J.U. e A.T.; administración de proyectos, J.U.

Financiamiento: Los autores financiaron a integridad el estudio.

Conflictos de interés: Los autores declaran no tener ningún conflicto de intereses.

Referencias

- [1] A. Kumari et al., "Scope of Banana By-Products: A Potent Human Resource", *Int.J.Curr.Microbiol.App.Sci.*, vol. 11, núm. 9, pp. 104–112, sep. 2022, doi: 10.20546/ijcmas.2022.1109.012.
- [2] Food and Agriculture Organization of the United Nations, "FAOSTAT", Crops and livestock products. Consultado: el 1 de marzo de 2024. [En línea]. Disponible en: <https://www.fao.org/faostat/en/#data/TCL>
- [3] A. Cervantes-Álava, A. Sánchez-Urdaneta, C. Colmenares, y J. Quevedo-Guerrero, "Evaluation of fungicides used in the management of black Sigatoka in banana cultivation", *Revista de la Facultad de Agronomía de la Universidad del Zulia*, vol. 40, núm. 2, Art. núm. 2, may 2023.
- [4] A. Rebollar-Alviter, M. Nita, A. Rebollar-Alviter, y M. Nita, "Optimizing Fungicide Applications for Plant Disease Management: Case Studies on Strawberry and Grape", en *Fungicides - Beneficial and Harmful Aspects*, IntechOpen, 2011. doi: 10.5772/26740.
- [5] D. Luna-Moreno et al., "Early Detection of the Fungal Banana Black Sigatoka Pathogen *Pseudocercospora fijiensis* by an SPR Immunosensor Method", *Sensors*, vol. 19, núm. 3, Art. núm. 3, ene. 2019, doi: 10.3390/s19030465.
- [6] A. Abbas et al., "Drones in Plant Disease Assessment, Efficient Monitoring, and Detection: A Way Forward to Smart Agriculture", *Agronomy*, vol. 13, núm. 6, Art. núm. 6, jun. 2023, doi: 10.3390/agronomy13061524.
- [7] F. Martinelli et al., "Advanced methods of plant disease detection. A review", *Agron. Sustain. Dev.*, vol. 35, núm. 1, pp. 1–25, ene. 2015, doi: 10.1007/s13593-014-0246-1.

- [8] J. Li, "Design and Analysis of Hyperspectral Remote Sensing Satellite System", en *Satellite Remote Sensing Technologies*, J. Li, Ed., en Space Science and Technologies. , Singapore: Springer, 2021, pp. 175–226. doi: 10.1007/978-981-15-4871-0_5.
- [9] C. H. Bock, G. H. Poole, P. E. Parker, y T. R. Gottwald, "Plant Disease Severity Estimated Visually, by Digital Photography and Image Analysis, and by Hyperspectral Imaging", *Critical Reviews in Plant Sciences*, vol. 29, núm. 2, pp. 59–107, mar. 2010, doi: 10.1080/07352681003617285.
- [10] R. Siche, R. Vejarano, V. Aredo, L. Velasquez, E. Saldaña, y R. Quevedo, "Evaluation of Food Quality and Safety with Hyperspectral Imaging (HSI)", *Food Eng Rev*, vol. 8, núm. 3, pp. 306–322, sep. 2016, doi: 10.1007/s12393-015-9137-8.
- [11] A.-K. Mahlein, "Detection, identification, and quantification of fungal diseases of sugar beet leaves using imaging and non-imaging hyperspectral techniques", Thesis, Universitäts- und Landesbibliothek Bonn, 2011. Consultado: el 19 de marzo de 2024. [En línea]. Disponible en: <https://bonndoc.ulb.uni-bonn.de/xmlui/handle/20.500.11811/4713>
- [12] D. Ashourloo, M. R. Mobasheri, y A. Huete, "Developing Two Spectral Disease Indices for Detection of Wheat Leaf Rust (Puccinia triticina)", *Remote Sensing*, vol. 6, núm. 6, Art. núm. 6, jun. 2014, doi: 10.3390/rs6064723.
- [13] J. Abdulridha, Y. Ampatzidis, S. C. Kakarla, y P. Roberts, "Detection of target spot and bacterial spot diseases in tomato using UAV-based and benchtop-based hyperspectral imaging techniques", *Precision Agric*, vol. 21, núm. 5, pp. 955–978, oct. 2020, doi: 10.1007/s11119-019-09703-4.
- [14] M. A. Lara et al., "Aplicación de imagen hiperespectral para observar el efecto de la salinidad en hojas de lechuga.", en *Actas del VII Congreso Ibérico de Agroingeniería y Ciencias Hortícolas / VII Congreso Ibérico de Agroingeniería y Ciencias Hortícolas. | 26/08/2013 - 29/08/2013 | Madrid*, Madrid: E.T.S.I. Agrónomos (UPM), 2013. Consultado: el 7 de febrero de 2024. [En línea]. Disponible en: <http://www.sechaging-madrid2013.org/>
- [15] J. Zhang et al., "Diagnosing the symptoms of sheath blight disease on rice stalk with an in-situ hyperspectral imaging technique", *Biosystems Engineering*, vol. 209, pp. 94–105, sep. 2021, doi: 10.1016/j.biosystemseng.2021.06.020.
- [16] R.-Q. Zhou et al., "Early Detection of Magnaporthe oryzae-Infected Barley Leaves and Lesion Visualization Based on Hyperspectral Imaging", *Frontiers in Plant Science*, vol. 9, 2019, Consultado: el 7 de febrero de 2024. [En línea]. Disponible en: <https://www.frontiersin.org/journals/plant-science/articles/10.3389/fpls.2018.01962>
- [17] Q. Gu et al., "Early detection of tomato spotted wilt virus infection in tobacco using the hyperspectral imaging technique and machine learning algorithms", *Computers and Electronics in Agriculture*, vol. 167, p. 105066, dic. 2019, doi: 10.1016/j.compag.2019.105066.
- [18] J. Gui, J. Fei, Z. Wu, X. Fu, y A. Diakite, "Grading method of soybean mosaic disease based on hyperspectral imaging technology", *Information Processing in Agriculture*, vol. 8, núm. 3, pp. 380–385, sep. 2021, doi: 10.1016/j.inpa.2020.10.006.
- [19] A. F. Cheshkova, "A review of hyperspectral image analysis techniques for plant disease detection and identification", *Vavilovskii Zhurnal Genet Seleksii*, vol. 26, núm. 2, pp. 202–213, mar. 2022, doi: 10.18699/VJGB-22-25.
- [20] W. Liao, D. Ochoa, L. Gao, B. Zhang, y W. Philips, "Morphological Analysis for Banana Disease Detection in Close Range Hyperspectral Remote Sensing Images", en *IGARSS 2019 - 2019*

- IEEE International Geoscience and Remote Sensing Symposium*, jul. 2019, pp. 3697–3700. doi: 10.1109/IGARSS.2019.8899087.
- [21]H. Bendini et al., “Spectral characterization of banana leaves (*Musa spp.*) for detection and differentiation of black Sigatoka and yellow sigatoka”, presentado en XVII Simpósio Brasileiro de Sensoriamento Remoto, João Pessoa, Brazil., abr. 2015.
- [22]V. G. Krishnan, J. Deepa, P. V. Rao, V. Divya, y S. Kaviarasan, “An automated segmentation and classification model for banana leaf disease detection”, *J App Biol Biotech*, vol. 10, núm. 1, pp. 213–220, ene. 2022, doi: 10.7324/JABB.2021.100126.
- [23]J. Ugarte Fajardo et al., “Early detection of black Sigatoka in banana leaves using hyperspectral images”, *Appl Plant Sci*, vol. 8, núm. 8, p. e11383, ago. 2020, doi: 10.1002/aps3.11383.
- [24]L. Priya. S y R. Subhashini, “Different Disease Detection of Paddy Crops using Drones - A Survey”, en *2023 4th International Conference on Smart Electronics and Communication (ICOSEC)*, sep. 2023, pp. 01–07. doi: 10.1109/ICOSEC58147.2023.10275809.
- [25]I. Herrmann, E. Bdolach, Y. Montekyo, S. Rachmilevitch, P. A. Townsend, y A. Karnieli, “Assessment of maize yield and phenology by drone-mounted superspectral camera”, *Precision Agric*, vol. 21, núm. 1, pp. 51–76, feb. 2020, doi: 10.1007/s11119-019-09659-5.
- [26]F. Furukawa, K. Maruyama, Y. K. Saito, y M. Kaneko, “Corn Height Estimation Using UAV for Yield Prediction and Crop Monitoring”, en *Unmanned Aerial Vehicle: Applications in Agriculture and Environment*, R. Avtar y T. Watanabe, Eds., Cham: Springer International Publishing, 2020, pp. 51–69. doi: 10.1007/978-3-030-27157-2_5.
- [27]K. Natarajan, R. Karthikeyan, y S. Rajalingam, “Importance of Drone Technology in Agriculture”, en *Drone Technology*, John Wiley & Sons, Ltd, 2023, pp. 351–374. doi: 10.1002/9781394168002.ch14.
- [28]S. C. Hassler y F. Baysal-Gurel, “Unmanned Aircraft System (UAS) Technology and Applications in Agriculture”, *Agronomy*, vol. 9, núm. 10, Art. núm. 10, oct. 2019, doi: 10.3390/agronomy9100618.
- [29]J. Kurihara, T. Ishida, y Y. Takahashi, “Unmanned Aerial Vehicle (UAV)-Based Hyperspectral Imaging System for Precision Agriculture and Forest Management”, en *Unmanned Aerial Vehicle: Applications in Agriculture and Environment*, R. Avtar y T. Watanabe, Eds., Cham: Springer International Publishing, 2020, pp. 25–38. doi: 10.1007/978-3-030-27157-2_3.
- [30]P. J. Zarco-Tejada, M. L. Guillén-Climet, R. Hernández-Clemente, A. Catalina, M. R. González, y P. Martín, “Estimating leaf carotenoid content in vineyards using high resolution hyperspectral imagery acquired from an unmanned aerial vehicle (UAV)”, *Agricultural and Forest Meteorology*, vol. 171–172, pp. 281–294, abr. 2013, doi: 10.1016/j.agrformet.2012.12.013.
- [31]K. K.-K. Kang, M. Hoekstra, M. Foroutan, A. M. Chegoonian, K. Zolfaghari, y C. R. Duguay, “Operating Procedures and Calibration of a Hyperspectral Sensor Onboard a Remotely Piloted Aircraft System For Water and Agriculture Monitoring”, en *IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium*, jul. 2019, pp. 9200–9203. doi: 10.1109/IGARSS.2019.8900128.
- [32]E. Dyring, “The Principles of Remote Sensing”, *Ambio*, vol. 2, núm. 3, pp. 57–69, 1973.
- [33]A. Roman-Gonzalez y N. I. Vargas-Cuentas, “Análisis de imágenes hiperespectrales”, *Revista Ingeniería & Desarrollo*, vol. Año 9, núm. N° 35, pp. 14–17, sep. 2013.

- [34]D. Landgrebe, "Hyperspectral image data analysis", *IEEE Signal Processing Magazine*, vol. 19, núm. 1, pp. 17–28, ene. 2002, doi: 10.1109/79.974718.
- [35]A. Plaza et al., "Advanced processing of hyperspectral images", en *2006 IEEE International Symposium on Geoscience and Remote Sensing*, jul. 2006, pp. 1974–1978. doi: 10.1109/IGARSS.2006.511.
- [36]G. ElMasry y D.-W. Sun, "CHAPTER 1 – Principles of Hyperspectral Imaging Technology", en *Hyperspectral Imaging for Food Quality Analysis and Control*, D.-W. Sun, Ed., San Diego: Academic Press, 2010, pp. 3–43. doi: 10.1016/B978-0-12-374753-2.10001-2.
- [37]J. Frey, "Evaluating close range remote sensing techniques for the retention of biodiversity-related forest structures", Doctoral thesis, Albert-Ludwigs-Universität Freiburg, 2019. doi: 10.6094/UNIFR/151315.
- [38]T. Adão et al., "Hyperspectral Imaging: A Review on UAV-Based Sensors, Data Processing and Applications for Agriculture and Forestry", *Remote Sensing*, vol. 9, núm. 11, Art. núm. 11, nov. 2017, doi: 10.3390/rs9111110.
- [39]F. Yamazaki y W. Liu, "REMOTE SENSING TECHNOLOGIES FOR POST-EARTHQUAKE DAMAGE ASSESSMENT: A CASE STUDY ON THE 2016 KUMAMOTO EARTHQUAKE", 2016.
- [40]R. Kaur, G. Kaur, K. Singh, y B. Singh, "Plant Growth and Development Under Suboptimal Light Conditions", en *Phyto-Microbiome in Stress Regulation*, M. Kumar, V. Kumar, y R. Prasad, Eds., en *Environmental and Microbial Biotechnology*, Singapore: Springer, 2020, pp. 205–217. doi: 10.1007/978-981-15-2576-6_10.
- [41]L. Fajardo Reina, "Firmas Espectrales", presentado en IGAC-CIAF – Infraestructura Colombiana de Datos Espaciales 2018, Colombia, dic. 2018. doi: 10.13140/RG.2.2.23337.52326.
- [42]P. Mishra, M. S. M. Asaari, A. Herrero-Langreo, S. Lohumi, B. Diezma, y P. Scheunders, "Close range hyperspectral imaging of plants: A review", *Biosystems Engineering*, vol. 164, pp. 49–67, dic. 2017, doi: 10.1016/j.biosystemseng.2017.09.009.
- [43]J. Ma, D.-W. Sun, H. Pu, J.-H. Cheng, y Q. Wei, "Advanced Techniques for Hyperspectral Imaging in the Food Industry: Principles and Recent Applications", *Annual Review of Food Science and Technology*, vol. 10, núm. 1, pp. 197–220, 2019, doi: 10.1146/annurev-food-032818-121155.
- [44]J. A. Richards, *Remote Sensing Digital Image Analysis: An Introduction*. Springer Science & Business Media, 2012.
- [45]V. V. Shipko et al., "Development of a Hyperspectral System with Controlled Spectral, Spatial, and Radiometric Resolution", *L&E*, núm. 05–2022, pp. 31–39, oct. 2022, doi: 10.33383/2022-036.
- [46]C. G. Gomez, L. F. Rocco, y S. Masuelli, "Spectral and Radiometric calibration of a SWIR hyperspectral camera to acquiring spectral signatures", en *2022 IEEE Biennial Congress of Argentina (ARGENCON)*, sep. 2022, pp. 1–8. doi: 10.1109/ARGENCON55245.2022.9940030.
- [47]A.-K. Mahlein, E. Alisaac, A. Al Masri, J. Behmann, H.-W. Dehne, y E.-C. Oerke, "Comparison and Combination of Thermal, Fluorescence, and Hyperspectral Imaging for Monitoring Fusarium Head Blight of Wheat on Spikelet Scale", *Sensors*, vol. 19, núm. 10, Art. núm. 10, ene. 2019, doi: 10.3390/s19102281.

- [48]L. Huang *et al.*, “Combining Random Forest and XGBoost Methods in Detecting Early and Mid-Term Winter Wheat Stripe Rust Using Canopy Level Hyperspectral Measurements”, *Agriculture*, vol. 12, núm. 1, Art. núm. 1, ene. 2022, doi: 10.3390/agriculture12010074.
- [49]A. Abd-Elrahman, R. Pande-Chhetri, y G. Vallad, “Design and Development of a Multi-Purpose Low-Cost Hyperspectral Imaging System”, *Remote Sensing*, vol. 3, núm. 3, Art. núm. 3, mar. 2011, doi: 10.3390/rs3030570.
- [50]L. Huang, T. Li, C. Ding, J. Zhao, D. Zhang, y G. Yang, “Diagnosis of the Severity of Fusarium Head Blight of Wheat Ears on the Basis of Image and Spectral Feature Fusion”, *Sensors*, vol. 20, núm. 10, Art. núm. 10, ene. 2020, doi: 10.3390/s20102887.
- [51]A. T. Espinoza-Fraire, A. E. D. López, R. P. P. Morado, y J. A. S. Esqueda, “3 - Equations of motion of a fixed-wing UAV”, en *Design of Control Laws and State Observers for Fixed-Wing UAVs*, A. T. Espinoza-Fraire, A. E. D. López, R. P. P. Morado, y J. A. S. Esqueda, Eds., Elsevier, 2023, pp. 19–33. doi: 10.1016/B978-0-32-395405-1.00012-1.
- [52]P. K. Garg, “Characterisation of Fixed-Wing Versus Multirotors UAVs/Drones”, *Journal of Geomatics*, vol. 16, núm. 2, Art. núm. 2, oct. 2022, doi: 10.58825/jog.2022.16.2.44.
- [53]E. Pino V., “Los drones una herramienta para una agricultura eficiente: un futuro de alta tecnología”, *Idesia (Arica)*, vol. 37, núm. 1, pp. 75–84, mar. 2019, doi: 10.4067/S0718-34292019005000402.
- [54]D. Ochoa *et al.*, “Hyperspectral imaging system for disease scanning on banana plants”, en *Sensing for Agriculture and Food Quality and Safety VIII*, SPIE, may 2016, pp. 85–90. doi: 10.1117/12.2224242.
- [55]J. Ugarte Fajardo, M. Maridueña-Zavala, J. Cevallos-Cevallos, y D. Ochoa Donoso, “Effective Methods Based on Distinct Learning Principles for the Analysis of Hyperspectral Images to Detect Black Sigatoka Disease”, *Plants*, vol. 11, núm. 19, Art. núm. 19, ene. 2022, doi: 10.3390/plants11192581.
- [56]T. Ayala-Silva y C. A. Beyl, “Changes in spectral reflectance of wheat leaves in response to specific macronutrient deficiency”, *Advances in Space Research*, vol. 35, núm. 2, pp. 305–317, ene. 2005, doi: 10.1016/j.asr.2004.09.008.
- [57]A.-K. Mahlein, “Plant Disease Detection by Imaging Sensors – Parallels and Specific Demands for Precision Agriculture and Plant Phenotyping”, *Plant Disease*, vol. 100, núm. 2, pp. 241–251, feb. 2016, doi: 10.1094/PDIS-03-15-0340-FE.



© 2024 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license <http://creativecommons.org/licenses/by/4.0/>