



Uso de sensores remotos en la agricultura: aplicaciones en el cultivo del banano¹

Use of remote sensing in agriculture: Applications in banana crop

José A. Guzmán-Álvarez², Miguel González-Zuñiga², Jorge A. Sandoval Fernández², Julio Cesar Calvo-Alvarado³

¹ Recepción: 9 de septiembre, 2021. Aceptación: 11 de marzo, 2022. Este trabajo formó parte de la Tesis Doctoral del primer autor, Doctorado en Ciencia Naturales para el Desarrollo (DOCINADE), Instituto Tecnológico de Costa Rica, Universidad Nacional, Universidad Estatal a Distancia, Cartago, Costa Rica y financiado por el proyecto “Análisis temporal del comportamiento de la producción de Banano (*Musa AAA*) a través del uso de sensores remotos” financiado por la Corporación Bananera Nacional (CORBANA).

² CORBANA S.A., Dirección de investigaciones, Apdo. 32-7210, Guápiles, Costa Rica. jguzman@corbana.co.cr (autor para correspondencia, <https://orcid.org/0000-0002-8729-8457>), mgonzale@corbana.co.cr (<https://orcid.org/0000-0003-3144-7123>), jorgeasandoval3@gmail.com (<https://orcid.org/0000-0002-4820-6441>).

³ Instituto Tecnológico de Costa Rica, Escuela de Ingeniería Forestal, Barrio Los Ángeles, Costa Rica. jucalvo@iter.ac.cr (<https://orcid.org/0000-0001-9555-6420>).

Resumen

Introducción. Los sensores remotos ofrecen la capacidad de observar un objeto sin estar en contacto con el mismo, son utilizados en aplicaciones para la agricultura y tienen un gran potencial de desarrollo para el cultivo del banano (*Musa AAA*). Durante las últimas décadas las investigaciones en sensores remotos y agricultura se han incrementado gracias a la disponibilidad de imágenes satelitales de alta resolución y al uso de vehículos aéreos no tripulados que generan información base para las investigaciones. **Objetivo.** Realizar una revisión general sobre las aplicaciones del uso de sensores remotos para el cultivo del banano en tres aspectos específicos: determinación del área de cultivo, estimación de su productividad y en el diagnóstico de enfermedades. **Desarrollo.** Las áreas de plantaciones comerciales de banano son de fácil detección visual o por medio clasificaciones de imágenes, como con las imágenes del radar de apertura sintética (SAR), que pueden alcanzar presiones superiores al 95%. Esto debido a la alta retrodispersión de las hojas grandes de la planta. No obstante, los estudios realizados en cuanto a productividad son escasos para el cultivo de banano y se han limitado al uso de índices de vegetación, con resultados bajos en sus correlaciones. En cuanto la identificación de enfermedades, se ha trabajado en las principales que afectan la producción con niveles de correlación superiores al 90 % para algunas enfermedades. **Conclusión.** La presente revisión evidencia que las plantaciones bananeras pueden ser delimitadas mediante el uso de sensores remotos y, de igual forma, estos permiten la identificación de las principales enfermedades en el cultivo. Sin embargo, los resultados obtenidos para determinar productividad son escasos y con poca precisión.

Palabras clave: radar de apertura sintética, vehículos aéreos no tripulados, imágenes de satelitales, índices de vegetación, radar.

Abstract

Introduction. Remote sensors offer the ability to observe an object without being in contact with it. They are widely used in agricultural applications and have large development potential in banana (*Musa AAA*) plantations.



During the past decades, the research in remote sensing and agriculture has increased through the availability of high-resolution satellite images (spatial, spectral, and temporal) and the use of remotely piloted vehicles that generate base information for research. **Objective.** To carry out a general review on the applications of the use of remote sensors for banana plantations in three specific aspects: determination of the cultivation area, productivity estimation, and disease diagnosis. **Development.** The extension of land covered by commercial banana plantations can be detected visually or easily by means of remote image classifications, such as the Synthetic Aperture Radar (SAR) sensor, which have resulted in classification accuracies of around 95%. This is due to the high backscattering of the large leaves of the plant. However, the studies on productivity are scarce for banana cultivation and have been limited to the use of vegetation index, showing poor results in their correlations. As for the identification of diseases, work has been done on the main diseases affecting production with correlation levels above 90 % for some diseases. **Conclusion.** This review shows that banana plantations can be detected through the use of remote sensors and, likewise, these allow the identification of the main diseases in the crop. However, the results obtained to determine productivity are scarce and with little precision.

Keywords: synthetic aperture radar, unmanned aerial vehicles, satellite images, vegetation index, radar.

Introducción

En la actualidad, la agricultura global enfrenta importantes retos en cuanto al incremento de la productividad, el manejo eficiente de los recursos naturales y al combate de plagas y enfermedades. Para alcanzar dichos retos, se requiere del concurso de tecnologías emergentes como el uso de sensores remotos, vehículos aéreos no tripulados (VANT) y minería de datos, entre otras herramientas (Sishodia et al., 2020).

El monitoreo de los cultivos mediante el uso de sensores remotos, ha probado ser una herramienta valiosa para la formulación de políticas de desarrollo económico a nivel regional y nacional desde hace medio siglo. Este ha sido adoptado por ministerios de agricultura o planificación, universidades y centros de investigación agrícolas para estimar la extensión de los cultivos, la producción, su impacto y la prevención de desastres naturales. Es un insumo importante para el desarrollo de la agricultura de precisión (Weiss et al., 2020).

Debido a la presencia de tres plantas con diferentes fases fenológicas dentro de una misma unidad productiva (asincronía), en el banano no se ha logrado obtener un adecuado nivel de precisión que permita comparar parámetros como la productividad y el crecimiento, como sí se ha logrado en otros cultivos (Lamour et al., 2020).

El banano (*Musa* AAA, subgrupo Cavendish) es la fruta fresca más consumida en todo el mundo, además, es de alta importancia para la seguridad alimentaria y económica de países en desarrollo (Martínez-Solórzano & Rey-Brina, 2021). Es un alimento básico en África, Asia, América Central y las islas del Pacífico. La mayoría de la producción de banano a nivel mundial es para consumo local (85 %) y solo se exporta el 15 % (Israeli & Lahav, 2017). En el 2019 las exportaciones mundiales de banano alcanzaron el récord de 20,2 millones de toneladas. El área total sembrada en el mundo fue de 55 170 km² y los principales exportadores fueron Ecuador y Filipinas (Organización de Naciones Unidas para la Alimentación y la Agricultura, 2020).

En Costa Rica, el banano es uno de los principales productos agroalimentarios de exportación. Este cultivo representa un 8,8 % de las exportaciones totales de bienes del país y un 35,8 % del total del valor de las exportaciones agrícolas. Contribuye con la generación de empleo, con alrededor de 40 000 trabajadores directos y unas 100 000 plazas de manera indirecta (Corporación Bananera Nacional [CORBANA], 2021). El área total sembrada para el 2019 fue de 43 013 ha, todo el cultivo está sembrado en la vertiente del Caribe, en los cantones de Matina, Siquirres, Pocosí y Sarapiquí (CORBANA, 2019).

La siembra del cultivo banano en Costa Rica inicio en el año de 1872 en el valle de Zent, en la provincia de Limón por la compañía de Keith. A partir de 1930 se iniciaron también las plantaciones en el Valle de Coto y el Pacífico Sur,

como consecuencia de las enfermedades del Mal de Panamá y Sigatoka amarilla. La United Fruit Co fue una empresa de capital norteamericano clave para el desarrollo de la actividad bananera en Costa Rica (Soto Ballester, 2014).

El objetivo de este trabajo fue realizar una revisión general sobre las aplicaciones del uso de sensores remotos para el cultivo del banano en tres aspectos específicos: determinación del área de cultivo, estimación de su productividad y en el diagnóstico de enfermedades.

Aplicaciones en la agricultura

Los sensores remotos permiten la adquisición de información sobre un objeto o fenómeno sin estar en contacto con el mismo, esto implica que los instrumentos deben estar acoplados sobre alguna plataforma, como satélites, aviones, VANT, vehículos terrestres o sensores de proximidad. Por lo general, los sensores relacionados con la cobertura de plantas miden la radiación electromagnética que es reflejada o emitida por un objeto. Esto puede variar según los cambios morfológicos, fisiológicos y químicos en las plantas, también pueden ser afectados por factores como edad de las hojas, grosor, contenido de agua, ataque de plagas y enfermedades, deficiencias nutricionales (Usha & Singh, 2013; Weiss et al., 2020).

Entre las principales aplicaciones en agricultura desarrolladas con el uso de sensores remotos pasivos, se encuentran detección de diferentes cultivos y estimación la de cobertura de la superficie, monitoreo del estado de desarrollo temporal de los cultivos con la interpretación de datos de la radiación fotosintética activa, área foliar, fenología, biomasa, acumulación de nitrógeno en las hojas, tasa de evapotranspiración, humedad del suelo, estrés hídrico, productividad estimada, detección de plagas enfermedades y malezas. De forma más elaborada, se pueden generar otras variables de entrada para desarrollar modelos de crecimiento y productividad de cultivos útiles para el manejo adecuado de cada uno (Chemura, 2017; Jin et al., 2018; Sishodia et al., 2020; Weiss et al., 2020).

Los sensores activos como el Radar de Abertura Sintética (SAR), transmiten y reciben energía a frecuencias de microondas. Dichos sensores han demostrado ser sensibles y muy útiles para determinar varios parámetros estructurales de los cultivos como área foliar, biomasa, altura del dosel, además de la humedad de los suelos. La ventaja del uso del SAR, es que además de no ser influenciado significativamente por las condiciones climáticas como la nubosidad, este puede obtener información a través de las vegetación hasta la superficie del terreno con base en la longitud de onda del sensor (Jin et al., 2018; McNairn & Shang, 2016; Steele-Dunne et al., 2017).

En las últimas décadas se ha intensificado el uso de VANT equipados con diferentes sensores, esta tecnología proporciona una mayor flexibilidad en la captura de imágenes con altos niveles de resolución espacial y con la facilidad de adquisición de imágenes el día que se requieran. Además, dichos sensores son portátiles, versátiles, livianos y de bajo costo de operación, comparado con los sensores transportados en plataformas aéreas tripuladas (Colomina & Molina, 2014). Los VANT pueden portar o llevar en su carga útil sensores activos o pasivos, sensores ópticos desde cámaras en las bandas visibles, infrarrojo cercano o hasta infrarrojo térmico, sistemas de microondas (SAR) y escáner láser (LIDAR) (Colomina & Molina, 2014; Hassler & Baysal-Gurel, 2019; Jin et al., 2018; Weiss et al., 2020).

Las características estructurales y fenológicas de las plantas pueden ser categorizadas a nivel espectral por los índices de vegetación, definidos como medidas radiométricas sin unidades. Estos se calculan como ratios o diferencias de dos o más bandas. Las longitudes de onda visible (rojo, verde y azul), ofrecen información sobre el contenido de la clorofila en las plantas. La región del infrarrojo cercano (NIR) es la más adecuada para estimar biomasa o área foliar. Los sectores de onda corta infrarroja (SWIR), proporcionan información sobre el contenido de agua en la vegetación (Clevers & Kooistra, 2012).

La utilidad de los índices de vegetación está determinada por su posible correlación con los parámetros ambientales biofísicos que afectan la respuesta de las plantas, como calidad de suelo, contenido de humedad, efecto

del viento y enfermedades. Por esta razón, esta tecnología genera información indirecta sobre la respuesta del cultivo a los cambios en los factores biofísicos y en la incidencia de plagas o enfermedades (Clevers & Kooistra, 2012; Wójtowicz et al., 2016).

De acuerdo con su función y aplicación, los índices de vegetación se pueden agrupar en cinco categorías: los de variables biofísicas, de concentración de clorofila en hojas, de estimación de pigmentos, los de predicción de biomasa, cobertura vegetal y los relacionados con fotosíntesis. Otros índices se relacionan con mediciones en las regiones termales que describen la conexión existente entre el contenido del agua, el estrés hídrico y las características térmicas de las plantas (Giovos et al., 2021; Hatfield et al., 2019).

Algunos de los índices ya citados incluyen: índice de vegetación ajustada al suelo (SAVI- soil-adjusted vegetation index), índice de vegetación resistente a la atmósfera (VARI- visible atmospheric resistant index), índice de estrés hídrico (MSI- moisture stress index), índice hídrico (WI- water index) y el contenido de clorofila en el dosel (CCC- canopy chlorophyll content) (Wójtowicz et al., 2016).

Aplicaciones en el cultivo del banano

Uno de los factores que ha dificultado el uso de los sensores remotos en el banano, es la asincronía del cultivo. El término asincronía se refiere a que la unidad productiva está conformada de forma simultánea por tres plantas de diferentes edades: la planta madre que fue la primera generación (G1), la planta hija que fue la segunda generación (G2) y la planta nieta que corresponde a la tercera generación (G3) (Figura 1). Debido a que el banano es un cultivo asincrónico, podría presentarse una respuesta espectral diferente por edad para cada una de las plantas que conforman la unidad productiva (Lamour et al., 2020).



Figura 1. Asincronía en el cultivo del banano. Fotografía tomada en una plantación de banano, Finca San Pablo, Costa Rica, 2021.

G1: planta madre que fue la primera generación G2: planta hija que fue la segunda generación. G3: planta nieta que corresponde a la tercera generación.

Figure 1. Asynchrony in the banana crop. Picture taken from a banana plantation, San Pablo farm, Costa Rica, 2021.

G1: mother plant that was the first generation. G2: maiden sucker that was the second generation. G3: sword sucker that corresponds to the third generation.

La asincronía en el cultivo del banano puede sintetizarse en tres fases: a) infantil, que comprende desde la aparición de la yema lateral hasta la emisión de la primera hoja normal (F10), b) fase de juvenil, que es el intervalo entre la emisión de la primera hoja normal y la diferenciación floral y c) fase reproductiva, que inicia desde la diferenciación floral y termina con la cosecha del fruto (Figura 2). Cada nueve meses una planta de banano produce un solo racimo, el cual contiene entre cinco y diez manos y cada mano presenta de diez a veinte frutos (Nyombi, 2010; Tixier et al., 2007).

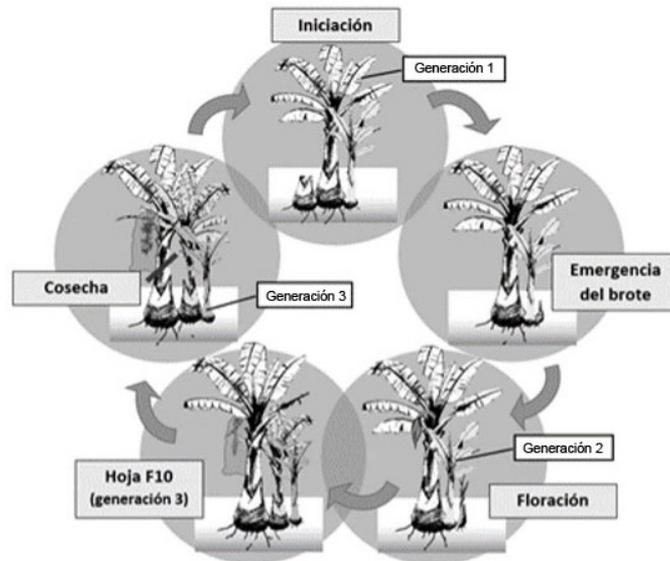


Figura 2. Etapas fenológicas de una unidad productiva de banano. Tomado de Montero-González (2016).

Figure 2. Phenological stages of a banana production unit. Taken from Montero-González (2016).

De acuerdo con publicaciones encontradas sobre el uso de sensores remotos en el cultivo del banano, se pueden agrupar en la delimitación y estimación del área del cultivo, estimación de la productividad, estudio de correlaciones entre las condiciones biofísicas y la productividad, y en el diagnóstico de plagas y enfermedades.

Estimación del área

En la delimitación del área de las plantaciones de banano se han utilizado tanto sensores pasivos como sensores activos. Debido a la forma de la siembra de las plantaciones comerciales con fines de exportación son fáciles de identificar a nivel visual en una imagen satelital (Figura 3); sin embargo, a nivel espectral tienden a confundirse con el cultivo de palma aceitera y los bosques inundados de palmas silvestres (Pedroni, 2003).

En Costa Rica se realizó una clasificación supervisada de una imagen de Landsat TM de 1996, se logró obtener una precisión de un 81,9 % para clasificar fincas de banano de exportación. Dicha precisión aumentó hasta un 97,9 % con el uso de información auxiliar de variables como la elevación, el tiempo de acceso desde una vía principal y la distancia desde la costa pacífica (Pedroni, 2003).

En Australia, realizaron la delimitación de fincas bananeras por medio de una imagen satélite SPOT-5 con una precisión de un 73 % y después de una edición visual esta precisión pudo aumentar hasta un 94 % (Johansen et al., 2009). Otro estudio en Australia para la identificación de la planta y permitir la priorización de las inspecciones de



Figura 3. Fincas bananeras en el cantón de Siquirres, Limón, Costa Rica. Fincas dibujadas sobre una imagen del satélite Sentinel-2, datos del Copernicus Sentinel, mayo 2018.

Figure 3. Banana farms in the Siquirres canton, Limon, Costa Rica. Farms drawn on an image image of Sentinel-2 from Copernicus Sentinel data, May 2018.

la planta afectadas por el virus “Banana Bunchy Top”, lograron delinear individuos y grupos de plantas de banano con precisiones de usuario y productor de 88 % y 79 %, respectivamente, basados en el análisis de ortofotografías. (Johansen et al., 2014).

Al utilizar datos del satélite de teledetección venezolano (VRSS-2 Venezuelan Remote Sensing Satallite) e imágenes de alta resolución de Google Earth (GE) y la fusión de imágenes múltiples, se logró identificar cultivos en Venezuela, los resultados para clasificar banano fueron de una precisión de 89,6 % con imágenes de GE, 85,7 % con imágenes de VRSS-2, al fusionarlas se obtuvo un 91,0 % y con el uso de todas las bandas del satélite se obtuvo hasta un 92,9 % de precisión (Pena et al., 2019).

La detección de áreas sembradas con banano con fotografías aéreas tomadas con un VANT también ha logrado altas precisiones en Indonesia, mediante el método análisis de imágenes basado en objetos se obtuvieron precisiones de un 80 % y un 89 % de precisión de productor (Harto et al., 2019).

Otro método utilizado fue el uso de una red neuronal U-Net para detectar plantaciones de banano en Queensland, Australia, con precisión del usuario del 98 % y una precisión del productor del 96 % (Clark & McKechnie, 2020). Además, se han utilizado imágenes tomadas por drones para el conteo de plantas de banano, con base en las técnicas de aprendizaje profundo (deep learning), con la cual se logró detectar las plantas con un 78,8 % de precisión y al utilizar redes neuronales se aumentó hasta una 96,4 % en la precisión a una altura de 40 m de elevación (Neupane et al., 2019).

Con el objetivo de clasificar áreas del banano de altura (East African highland banana) en DR Congo y Benín, Gomez Selvaraj et al. (2020) realizaron una comparación entre deferentes imágenes multispectrales de los satélite Sentinel 2, PlanetScope y WorldView-2 y una imagen tomada desde un VANT por medio de la cámara MicaSense RedEdge. Las diferentes aplicaciones en este estudio combinaron índices de vegetación (VI), análisis de componentes principales (PCA) y el clasificador Random Forest. La mejor precisión general se obtuvo con los sensores de alta resolución MicaSense (97 %) y WorldView-2 (93 %); mientras que con los sensores de menor resolución se obtuvo un 88 % de precisión para PlanetScope y un 76 % para Sentinel -2.

Los mejores porcentajes de precisión en la clasificación de áreas de banano (97,3 %) fueron obtenidos con imágenes hiperespectrales de HyMap II (un sensor de 125 bandas con radio espectral de 458 a 2491 nm), adquiridas por la misión CARTA II de NASA sobre Costa Rica en el 2005 (Fagan et al., 2015).

El uso de sensores activos como SAR para estimar las áreas de producción de banano han sido muy utilizadas debido a la alta retrodispersión de la señal generada por las grandes hojas de la planta y a la ventaja que poseen las imágenes SAR de no ser afectadas por las condiciones atmosféricas (Beaulieu et al., 1994) (Figura 4).

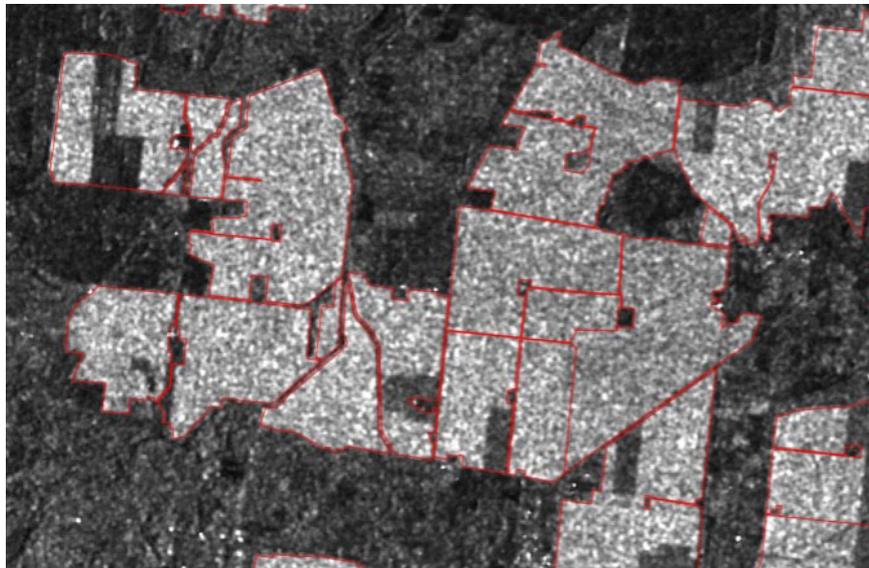


Figura 4. Alta retroscpección en áreas de banano, en el cantón de Siquirres, Limón, Costa Rica, vistas en una imagen de SAR. Imagen tomada por Copernicus Sentinel Sentinel-1, junio 2018.

Figure 4. High retroscpección in banana plantations in the Siquirres Canton, Limon, Costa Rica, seen in a SAR image. Taken from Copernicus Sentinel data Sentinel-1, June 2018.

Con la utilización de imágenes de SAR de un sensor aerotransportado de Banda C (SAREX) en Costa Rica, se detectaron las plantaciones de banano por su forma y brillo en las imágenes, además se identificaron zonas con plantas jóvenes con alturas de 0,5 a 1,5 m y cambios en la tonalidad debido a la densidad de plantaciones (Leclerc & Hall, 2000).

Otras investigaciones realizadas en Costa Rica con imágenes SAR (ERS-1 y 2), obtuvieron precisiones del 85 % en la clasificación de plantaciones de banano, al agrupar el uso del suelo en dos clases (banano versus no banano), la precisión aumentó a un 95 %. Este estudio concluyó que la superficie total de plantaciones de banano en los cantones de Sarapiquí, Pococí, Guácimo, Siquirres y Matina para el año 1993 fue de 44 600 ha (Verhoeve & De Wulf, 1999).

En China, con los datos ENVISAT-ASAR (HH/VV) y el análisis de componentes principales, se clasificaron áreas de banano con una precisión de un 83,5 % (Wang et al., 2009). También en China, pero con datos polarímetros de RADARSAT-2, obtuvieron precisiones de un 67,5 a 95,3 %, mediante el uso de un nuevo método de clasificación que se basa en la integración de la descomposición polarimétrica (PolSAR), interferometría (InSAR), análisis de imágenes orientado a objetos y algoritmos de árbol de decisión. El mejor resultado se presentó cuando se usó el clasificador de vecino más cercano en lugar de algoritmos de árbol de decisión (Qi et al., 2012) .

La disponibilidad reciente de las imágenes de los satélites Sentinel-1 A y B, de la agencia espacial europea, es una gran oportunidad para el monitoreo de cultivos, ya que permiten una mayor revisión de los satélites, Sentinel 1 de 12 días y resoluciones de 10 y 20 m. En Zhanjiang (China), evaluaron tres tipos de modelos de Deep Learning y el clasificador Random Forest para la clasificación de cultivos. En el caso de banano los máximos de precisión del usuario estuvieron entre del 96,2 y 98,1 % y la precisión del productor de entre 94,4 % y 98,1 % (Zhao et al., 2019).

Sensores hiperespectrales de campo con resoluciones entre 350 y 2500 nm tienen el potencial para la identificación de variedades de banano. En Uganda identificaron doce genotipos de *Musa*, entre la cuales se encontraban cultivares del subgrupo Cavendish, subgrupo Gros Michel, Bluggoe, FHIA y Pisang, de importancia para la región con precisiones de general de 64,2 %, las precisiones más altas (>76 %) fueron para variedades Bluggoe, Gonja, Kiwangazi y Gros Michel (Sinha et al., 2020).

Otro sensor remoto activo es el LIDAR (Light Detection and Ranging), fue utilizado en Davao, Las Filipinas, para identificar coberturas de banano con un 98,2 % de precisión, mediante los métodos de clasificación de árboles de decisión y máquinas de soporte vectorial (Novero et al., 2019).

Productividad y condición del cultivo

Para estimar la producción, así como el número y peso de racimos por hectárea en el cultivo, se emplearon sensores remotos con una imagen Landsat TM de febrero de 1986. Los investigadores, compararon índices de vegetación y variables del cultivo para una finca de 370 ha en la Costa Atlántica de Costa Rica. Los mejores resultados los presentó el índice Greenness, la banda 4 (NIR) y NDVI. La producción bruta obtuvo una correlación de 0,46, el número de racimos 0,30 y el peso del racimo 0,24. Al combinar los datos obtenidos de la imagen Landsat TM con información de los muestreos de suelos, las correlaciones aumentaron para la producción a 0,67, número de racimos a 0,52 y el peso a 0,37 (Veldkamp et al., 1990).

En Costa Rica, se obtuvo con una imagen del satélite IKONOS de agosto de 2000 correlaciones entre NDVI y variables del cultivo como pesos de racimo y densidad de siembra. Dichas variables resultaron con muy baja correlación (0,23) en cuanto a la densidad de la plantación y el peso del racimo (Stoorvogel et al., 2001).

Un VANT fue utilizado también en Costa Rica por Machovina et al. (2016), quienes compararon los patrones espaciales derivados del NDVI con la calidad física del suelo y los datos de producción de banano. Como resultado, obtuvieron correlaciones positivas ($R^2 = 0,55-0,65$) sobre variables de rendimiento y calidad de la fruta (peso del racimo, número de manos, la longitud del fruto medio de mayor tamaño y rendimiento).

El VANT ha resultado útil para determinar la existencia de una alta correlación entre el vigor de la planta y su contenido de nitrógeno. Se utilizó esta plataforma en Camerún, equipado con un sensor de imágenes multiespectrales como alternativa a las mediciones del contenido de clorofila en las hojas de banano. Los modelos de estimación de contenidos de clorofila en hojas aisladas en el suelo obtuvieron coeficientes R^2 entre 0,617 y 0,646. Cuando las imágenes en el modelo, incluyeron todas las hojas en el campo, el coeficiente R^2 se redujo a un 0,35 (Rabatel et al., 2019).

Detección de enfermedades

Los sensores remotos se han usado en el monitoreo de enfermedades en diferentes cultivos, de manera eficiente, en etapas tempranas del desarrollo de las enfermedades, cuando es difícil discernir los primeros síntomas en el campo. Esto es posible debido a que las variaciones en la reflectancia de las plantas causadas por cambio en su biomasa o estructuras de las hojas y su coloración, pueden ser captadas por imágenes RGB, multiespectrales, hiperespectrales, térmicas y de fluorescencia, lo que permite identificar enfermedades (Sishodia et al., 2020).

En el cultivo del banano la enfermedad Sigatoka negra (*Pseudocercospora fijiensis*) es considerada la de mayor impacto en la rentabilidad, dado que afecta la productividad comercial por un rápido deterioro del área fotosintética de las plantas (Pérez-Vicente et al., 2018). Los primeros trabajos en el uso de sensores en Costa Rica, se enfocaron en el diagnóstico de esta importante enfermedad.

El uso de imágenes SAR para la detección de enfermedades es factible debido a la alta intensidad del brillo del cultivo de banano en las imágenes, lo que tiende a decrecer cuando aumentan los valores del promedio ponderado de infección. Lo anterior se debe a una alta correlación negativa entre el valor del promedio ponderado de infección (PPT) y el menor brillo en la polarización VV (vertical emitida-vertical recibida) (Beaulieu et al., 1994).

En el estudio de la Sigatoka negra mediante el uso de sensores remotos, las investigaciones se han centrado en discriminar la presencia de la enfermedad. En algunos casos ha sido posible distinguir los grados de severidad, mediante un espectroscopio. En Brasil, se encontraron diferencias significativas en las características espectrales de hojas infectadas con Sigatoka negra y amarilla, en las regiones del infrarrojo cercano y visible. Los índices de vegetación relacionados con la clorofila y el NDVI mostraron una mejor diferenciación entre las plantas infectadas sanas y con diferentes niveles de infestación (Bendini et al., 2015).

Con el estudio de Sigatoka negra mediante sensores remotos, se detectó la presencia de *Pseudocercospora fijiensis* en tejido foliar mediante imágenes hiperespectrales en el rango visible e infrarrojo cercano. Al final, se obtuvo una precisión general del 78,7 % para la discriminación de los estadios de la enfermedad (Morel et al., 2018). Los autores realizaron un monitoreo de las antocianinas, dado que estas pueden ser fundamentales para la detección temprana de esta enfermedad. El contenido de clorofila disminuyó de forma progresiva a medida que se intensificó la enfermedad y aumentó el contenido de pigmentos marrones (Morel et al., 2018).

Con base en imágenes hiperespectrales y un modelo de mínimos cuadrados parciales y regresión logística penalizada (PLS-PLR), Ugarte Fajardo et al. (2020) pudieron predecir la presencia Sigatoka negra con una precisión del 98 % en plantaciones de banano en Ecuador. Las longitudes de onda con mayor contribución a la clasificación oscilaron entre 577 y 651 nm y entre 700 y 1019 nm.

En Brasil, en una plantación comercial de banano Prata se demostró que el uso de imágenes RGB de alta resolución espacial tomadas por un VANT a 60 m sobre el terreno y analizándolas por medio de métodos de aprendizaje automático, pudieron calcular la severidad del ataque de Sigatoka amarilla, con precisiones superiores al 90 % (Campos Calou et al., 2020).

Otra enfermedad muy importante en el cultivo del banano, es la Fusariosis causada por *Fusarium oxysporum* f.sp. *cubense*. Esta ha sido una de las enfermedades más devastadoras del cultivo, la cual impactó la producción comercial de banano 'Gros Michel' (AAA) entre los años 1900 y 1960. Una nueva variante de este patógeno conocido como Fusarium Raza 4 tropical (Foc R4T), que ya ha devastado áreas enteras de banano en Asia y África, amenaza la producción mundial de banano y al cultivar Cavendish (Ploetz, 2018).

Las investigaciones en sensores remotos en esta enfermedad se han enfocado en la identificación de áreas afectadas por Foc R4T por medio de imágenes multispectrales desde un VANT, con base en la clasificación supervisada mediante los algoritmos de Random Forest, Support Vector Machine y Artificial Neural Networks. Con estas herramientas se lograron precisiones entre el 90,0 y 91,4 % a una altura de vuelo de 120 m y una resolución espacial/tamaño de píxel de 8 cm (Ye et al., 2020a). Otra metodología implementada en China, fue el uso de índices de vegetación para la identificación de áreas infectadas con la enfermedad (Ye et al., 2020b). Ocho índices relacionados con la absorción de pigmentos y cambios en el desarrollo de la planta fueron utilizados por Gitelson et al. (2005). Los resultados mostraron que la enfermedad se puede identificar mediante el uso de los índices: de clorofila verde (CI green), de clorofila de borde rojo (CI red edge), de vegetación de diferencia normalizada (NDVI) y de borde rojo de diferencia normalizada (NDRE), con precisiones superiores al 80 %. El índice con mayor precisión fue CI red edge con 91,7 %.

La detección de otras enfermedades como Banana Bunchy Top Virus (BBTV) y *Xanthomonas Wilt of Banana* (XWB), fueron evaluadas mediante el uso de imágenes RGB tomadas desde un VANT y la utilización de modelos de detección de objetos (Deep Learning). En el estudio se observó una alta precisión en la clasificación de las enfermedades: BXWB con un 92,8 % y BBTD con un 99,4 % (Gomez Selvaraj et al., 2020).

Conclusiones

Esta revisión evidencia las investigaciones del uso de sensores remotos en la agricultura y el gran potencial para asistir a las prácticas de gestión y manejo en fincas en el cultivo de banano con fines de exportación.

El uso de los sensores remotos en el cultivo del banano se ha centrado en tres grandes ramas: a) en el mapeo, delimitación y de indefinición de áreas bananeras desde satélites, aviones y vehículos aéreos no tripulados, b) en la estimación de la productividad y las condiciones biofísicas que influyen sobre ella, y c) en la identificación y diagnóstico de enfermedades en el banano.

El número de publicaciones referentes a delimitación de áreas bananeras aumentó en la última década, ya que antes del 2010 solo se habían publicado cuatro artículos y después del 2020 hay dieciséis artículos publicados. Las áreas de plantaciones comerciales son detectadas y clasificadas con una mayor precisión con imágenes de SAR (95 %). Por lo tanto, este tipo de sensores pueden convertirse en la tendencia para conocer el área del cultivo de banano de un país o incluso a nivel mundial, dado los recursos disponibles en la actualidad.

Los resultados obtenidos al combinar diferentes índices de vegetación para estimación de variables fenológicas y de producción son bajos y no permiten determinar con certeza alguna variable independiente para establecer una relación directa con la productividad.

Se realizaron ocho publicaciones en el uso de sensores remotos y en enfermedades del banano, cinco de ellos fueron publicados en el 2020. Para el caso de Sigatoka negra los estudios se basaron en sensores de proximidad como los espectroradiómetros donde lograron presiones superiores al 90 %. En el caso de Foc R4T se identificaron áreas afectadas por la enfermedad con precisiones mayores al 90 %, por medio de imágenes obtenidas con un vehículo aéreo no tripulado (VANT).

Es necesario impulsar más las investigaciones en las aplicaciones emergentes de sensores remotos que integren plataformas visibles e infrarrojas cercanas con datos de SAR para la obtención predicción del comportamiento de la producción. Asimismo el monitoreo de los parámetros de la evapotranspiración, humedad del suelo y biomasa por medio de imágenes de SAR e imágenes térmicas, proporciona una estimación confiable basados en el balance energético.

Dado los nuevos reportes del impacto de Foc R4T en Latinoamérica, el uso de los sensores remotos será de gran utilidad para la identificación de la presencia y avance de la enfermedad, dado que una de las principales ventajas es no tener que ingresar a las fincas para la adquisición de las imágenes y así evitar la propagación de hongo.

Referencias

- Beaulieu, N., Leclerc, N., Velásquez, S., Pigeonnat, S., Gripius, N., Escalant, J. V., & Bonn, F. (1994). *Investigations at CATIE on the potential of high-resolution radar images for monitoring of agriculture in Central America*. Centro Agronómico Tropical de Investigación y Enseñanza. <https://bit.ly/3Qbaw5t>
- Bendini, H. N., Jacon, A. D., Moreira Pessôa, A. C., Pompeu Pavenelli, J. A., Moraes, W. S., Ponzoni, F. J., & Fonseca, L. M. (2015). Caracterização espectral de folhas de bananeira (*Musa spp.*) para detecção e diferenciação da Sigatoka Negra e Sigatoka Amarela. In D. F. Marcolino Gherardi, & L. E. Oliveira e Cruz de Aragão (Eds.), *Anais XVII Simpósio*

- Brasileiro de Sensoriamento Remoto* (pp. 2536–2543). Instituto Nacional de Pesquisas Espaciais. <http://urlib.net/rep/8JMKD3MGP6W34M/3JM4A5H>
- Campos Calou, V. B., dos Santos Teixeira, A., Moreira, L. C. J., Souza Lima, C., de Oliveira, J. B., & Rabelo de Oliveira, M. R. (2020). The use of UAVs in monitoring yellow sigatoka in banana. *Biosystems Engineering*, *193*, 115–125. <https://doi.org/10.1016/j.biosystemseng.2020.02.016>
- Chemura, A. (2017). *Modelling spatial variability of coffee (Coffea Arabica L.) crop condition with multispectral remote sensing data* [Doctoral Dissertation, University of KwaZulu-Natal]. University of KwaZulu-Natal Repository. <https://researchspace.ukzn.ac.za/xmlui/handle/10413/16233>
- Clark, A., & McKechnie, J. (2020). Detecting banana plantations in the wet tropics, Australia, using aerial photography and U-net. *Applied Sciences*, *10*(6), Article 2017. <https://doi.org/10.3390/app10062017>
- Clevers, J. G. P. W., & Kooistra, L. (2012). Using Hyperspectral Remote Sensing Data for Retrieving Canopy Chlorophyll and Nitrogen Content. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, *5*(2), 574–583. <https://doi.org/10.1109/JSTARS.2011.2176468>
- Colomina, I., & Molina, P. (2014). Unmanned aerial systems for photogrammetry and remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, *92*, 79–97. <https://doi.org/10.1016/j.isprsjprs.2014.02.013>
- Corporación Bananera Nacional. (2019). *Estadísticas de exportación bananera 2019*. CORBANA S.A.
- Corporación Bananera Nacional. (2021, 15 mayo). *Banano de Costa Rica: Estadísticas*. <http://www.corbana.co.cr/banano-de-costa-rica/#estadistica>
- Fagan, M. E., DeFries, R. S., Sesnie, S. E., Arroyo-Mora, J. P., Soto, C., Singh, A., Townsend, P. A., & Chazdon, R. L. (2015). Mapping species composition of forests and tree plantations in northeastern Costa Rica with an integration of hyperspectral and multitemporal landsat imagery. *Remote Sensing*, *7*(5), 5660–5696. <https://doi.org/10.3390/rs70505660>
- Giovos, R., Tassopoulos, D., Kalivas, D., Lougkos, N., & Priovolou, A. (2021). Remote sensing vegetation indices in viticulture: A critical review. *Agriculture*, *11*(5), Article 457. <https://doi.org/10.3390/agriculture11050457>
- Gitelson, A. A., Viña, A., Ciganda, V., Rundquist, D. C., & Arkebauer, T. J. (2005). Remote estimation of canopy chlorophyll content in crops. *Geophysical Research Letters*, *32*(8), Article L08403. <https://doi.org/https://doi.org/10.1029/2005GL022688>
- Gomez Selvaraj, M., Vergara, A., Montenegro, F., Alonso Ruiz, H., Safari, N., Raymaekers, D., Ocimati, W., Ntamwira, J., Tits, L., Bonaventure Omondi, A., & Blomme, G. (2020). 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 Journal of Photogrammetry and Remote Sensing*, *169*, 110–124. <https://doi.org/10.1016/j.isprsjprs.2020.08.025>
- Harto, A. B., Dwi Prastiwi, P. A., Ariadji, F. N., Suwardhi, D., Dwivany, F. M., Nuarsa, I. W., & Wikantika, K. (2019). Identification of banana plants from unmanned aerial vehicles (UAV) photos using object based image analysis (OBIA) method (a case study in Sayang Village, Jatinangor District, West Java). *HAYATI Journal of Biosciences*, *26*(1), 7–14. <https://doi.org/10.4308/hjb.26.1.7>
- Hassler, S. C., & Baysal-Gurel, F. (2019). Unmanned aircraft system (UAS) technology and applications in agriculture. *Agronomy*, *9*(10), Article 618. <https://doi.org/10.3390/agronomy9100618>

- Hatfield, J. L., Prueger, J. H., Sauer, T. J., Dold, C., O'Brien, P., & Wacha, K. (2019). Applications of vegetative indices from remote sensing to agriculture: Past and future. *Inventions*, 4(4), Article 71. <https://doi.org/10.3390/inventions4040071>
- Israeli, Y., & Lahav, E. (2017). Banana. In B. Thomas, B. G. Murray, & D. J. Murphy (Eds.), *Encyclopedia of applied plant sciences* (2nd ed., pp. 363–381). Academic Press. <https://doi.org/10.1016/B978-0-12-394807-6.00072-1>
- Jin, X., Kumar, L., Li, Z., Feng, H., Xu, X., Yang, G., & Wang, J. (2018). A review of data assimilation of remote sensing and crop models. *European Journal of Agronomy*, 92, 141–152. <https://doi.org/10.1016/j.eja.2017.11.002>
- Johansen, K., Phinn, S., Witte, C., Philip, S., & Newton, L. (2009). Mapping Banana Plantations from Object-oriented Classification of SPOT-5 Imagery. *Photogrammetric Engineering & Remote Sensing*, 75(9), 1069–1081. <https://doi.org/10.14358/pers.75.9.1069>
- Johansen, K., Sohlbach, M., Sullivan, B., Stringer, S., Peasley, D., & Phinn, S. (2014). Mapping banana plants from high spatial resolution orthophotos to facilitate plant health assessment. *Remote Sensing*, 6(9), 8261–8286. <https://doi.org/10.3390/rs6098261>
- Lamour, J., Naud, O., Lechaudel, M., Le Moguédec, G., Taylor, J., & Tisseyre, B. (2020). Spatial analysis and mapping of banana crop properties: issues of the asynchronicity of the banana production and proposition of a statistical method to take it into account. *Precision Agriculture*, 21(4), 897–921. <https://doi.org/10.1007/s11119-019-09700-7>
- Leclerc, G., & Hall, C. A. S. (2000). Remote sensing and land use analysis for agriculture in Costa Rica. In G. L. Charles, A. S. Hall, & C. Leon-Perez (Eds.), *Quantifying sustainable development* (pp. 295–346). Academic Press. <https://doi.org/10.1016/b978-012318860-1/50017-4>
- Machovina, B. L., Feeley, K. J., & Machovina, B. J. (2016). UAV remote sensing of spatial variation in banana production. *Crop and Pasture Science*, 67(12), 1281–1287. <https://doi.org/10.1071/CP16135>
- Martínez-Solórzano, G. E., & Rey-Brina, J. C. (2021). Bananas (*Musa AAA*): Importancia, producción y comercio en tiempos de Covid-19. *Agronomía Mesoamericana*, 32(3), 1034–1046. <https://doi.org/10.15517/am.v32i3.43610>
- McNairn, H., & Shang, J. (2016). A review of multitemporal synthetic aperture radar (SAR) for crop monitoring. In Y. Ban (Ed.), *Multitemporal remote sensing. Methods and applications* (pp. 317–340). Springer International. https://doi.org/10.1007/978-3-319-47037-5_15
- Montero González, H. J. (2016). *Simulación de la floración del cultivo de banano (Musa AAA cv. 'Grande Naine') mediante el modelo "SIMBA-CR" adaptado a la vertiente Caribe de Costa Rica* [Tesis de Licenciatura, no publicada]. Universidad de Costa Rica.
- Morel, J., Jay, S., Féret, J.-B., Bakache, A., Bendoula, R., Carreel, F., & Gorretta, N. (2018). Exploring the potential of PROCOSINE and close-range hyperspectral imaging to study the effects of fungal diseases on leaf physiology. *Scientific Reports*, 8, Article 15933. <https://doi.org/10.1038/s41598-018-34429-0>
- Neupane, B., Horanont, T., & Hung, N. D. (2019). Deep learning based banana plant detection and counting using high-resolution red-green-blue (RGB) images collected from unmanned aerial vehicle (UAV). *PLoS ONE*, 14(10), Article e0223906. <https://doi.org/10.1371/journal.pone.0223906>
- Novero, A. U., Pasaporte, M. S., Aurelio Jr, R. M., Madanguit, C. J. G., Tinoy, M. R. M., Luayon, M. S., Oñez, J. P. L., Daquiado, E. G. B., Diez, J. M. A., Ordaneza, J. E., Riños, L. J., Capin, N. C., Pototan, B. L., Tan, H. G., Polinar, M. D. O., Nebres, D. I., & Nañola Jr, C. L. (2019). The use of light detection and ranging (LiDAR) technology and

- GIS in the assessment and mapping of bioresources in Davao Region, Mindanao Island, Philippines. *Remote Sensing Applications: Society and Environment*, 13, 1–11. <https://doi.org/10.1016/j.rsase.2018.10.011>
- Nyombi, K. (2010). *Understanding growth of East Africa highland banana: experiments and simulation* [Doctoral Dissertation, Wageningen University]. Wageningen University Repository. <https://edepot.wur.nl/132641>
- Organización de Naciones Unidas para la Alimentación y la Agricultura. (2020). *Análisis del mercado del banano: resultados preliminares 2019*. <https://www.fao.org/3/ca7567es/CA7567ES.pdf>
- Pedroni, L. (2003). Improved classification of Landsat Thematic Mapper data using modified prior probabilities in large and complex landscapes. *International Journal of Remote Sensing*, 24(1), 91–113. <https://doi.org/10.1080/01431160304998>
- Pena, J., Tan, Y., & Boonpook, W. (2019). Semantic segmentation based remote sensing data fusion on crops detection. *Journal of Computer and Communications*, 7(7), 53–64. <https://doi.org/10.4236/jcc.2019.77006>
- Pérez-Vicente, L., Guzmán, M., Pasberg-Gauhl, C., Gauhl, F., & Jones, D. R. (2018). Fungal diseases of the foliage: Sigatoka leaf spot. In D. R. Jones (Ed.), *Handbook of diseases of banana, abacá and enset* (pp. 41–206). CABI.
- Ploetz, R. C. (2018). Fungal diseases of the root, corm and pseudostem. In D. R. Jones (Ed.), *Handbook of diseases of banana, abacá and enset* (pp. 207–228). CABI. <https://doi.org/10.1079/9781780647197.0207>
- Qi, Z., Yeh, A. G.-O., Li, X., & Lin, Z. (2012). A novel algorithm for land use and land cover classification using RADARSAT-2 polarimetric SAR data. *Remote Sensing of Environment*, 118, 21–39. <https://doi.org/10.1016/J.RSE.2011.11.001>
- Rabatel, G., Lamour, J., Moura, D., & Naud, O. (2019). A multispectral processing chain for chlorophyll content assessment in banana fields by UAV imagery. In J. V. Stafford (Ed.), *Precision agriculture '19* (pp. 413–419). Wageningen Academic Publishers. https://doi.org/10.3920/978-90-8686-888-9_51
- Sinha, P., Robson, A., Schneider, D., Kilic, T., Mugeru, H. K., Ilukor, J., & Tindamanyire, J. M. (2020). The potential of *in-situ* hyperspectral remote sensing for differentiating 12 banana genotypes grown in Uganda. *ISPRS Journal of Photogrammetry and Remote Sensing*, 167, 85–103. <https://doi.org/10.1016/j.isprsjprs.2020.06.023>
- Sishodia, R. P., Ray, R. L., & Singh, S. K. (2020). Applications of remote sensing in precision agriculture: A review. *Remote Sensing*, 12(19), Article 3136. <https://doi.org/10.3390/rs12193136>
- Soto Ballestero, M. (2014). *Bananos I: conceptos básicos* (1ª ed.). Editorial Tecnológica de Costa Rica.
- Steele-Dunne, S. C., McNairn, H., Monsivais-Huertero, A., Judge, J., Liu, P. -W., & Papathanassiou, K. (2017). Radar remote sensing of agricultural canopies: A review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(5), 2249–2273. <https://doi.org/10.1109/JSTARS.2016.2639043>
- Stoorvogel, J. J., Verhoeven, R., van Leeuwen, H., & Orlich, R. (2001). *AeroBanMan: the aerial detection of plant distribution and fungus infection for precision banana management*. Lab of Soil Science and Geology WAU.
- Tixier, P., Dorel, M., & Malézieux, E. (2007). A model-based Approach to maximise gross income by selection of banana planting date. *Biosystems Engineering*, 96(4), 471–476. <https://doi.org/10.1016/j.biosystemseng.2007.01.003>
- Ugarte Fajardo, J., Bayona Andrade, O., Criollo Bonilla, R., Cevallos Cevallos, J., Mariduena-Zavala, M., Ochoa Donoso, D., & Vicente Villardón, J. L. (2020). Early detection of black Sigatoka in banana leaves using hyperspectral images. *Applications in Plant Sciences*, 8(8), Article e11383. <https://doi.org/10.1002/aps3.11383>
- Usha, K., & Singh, B. (2013). Potential applications of remote sensing in horticulture—A review. *Scientia Horticulturae*, 153, 71–83. <https://doi.org/10.1016/j.scienta.2013.01.008>

- Veldkamp, E., Huising, E. J., Stein, A., & Bouma, J. (1990). Variation of measured banana yields in a Costa Rican plantation as explained by soil survey and thematic mapper data. *Geoderma*, 47(3–4), 337–348. [https://doi.org/10.1016/0016-7061\(90\)90037-A](https://doi.org/10.1016/0016-7061(90)90037-A)
- Verhoeve, J., & De Wulf, R. (1999). An image processing chain for land-cover classification using multitemporal ERS-1 data. *Photogrammetric Engineering and Remote Sensing*, 65(10), 1179–1186.
- Wang, X., Wang, Q., Ling, F., Zhu, X., & Jiang, H. (2009). Principal component analysis and its application on banana fields mapping using ENVISAT ASAR data in Zhangzhou, Fujian Province. *Geo-Spatial Information Science*, 12(2), 142–145. <https://doi.org/10.1007/s11806-009-0035-1>
- Weiss, M., Jacob, F., & Duveiller, G. (2020). Remote sensing for agricultural applications: A meta-review. *Remote Sensing of Environment*, 236, Article 111402. <https://doi.org/10.1016/j.rse.2019.111402>
- Wójtowicz, M., Wójtowicz, A., & Piekarczyk, J. (2016). Application of remote sensing methods in agriculture. *Communications in Biometry and Crop Science*, 11(1), 31–50.
- Ye, H., Huang, W., Huang, S., Cui, B., Dong, Y., Guo, A., Ren, Y., & Jin, Y. (2020a). Identification of banana fusarium wilt using supervised classification algorithms with UAV-based multi-spectral imagery. *International Journal of Agricultural and Biological Engineering*, 13(3), 136–142. <https://doi.org/10.25165/j.ijabe.20201303.5524>
- Ye, H., Huang, W., Huang, S., Cui, B., Dong, Y., Guo, A., Ren, Y., & Jin, Y. (2020b). Recognition of banana Fusarium wilt based on UAV remote sensing. *Remote Sensing*, 12(6), Article 938. <https://doi.org/10.3390/rs12060938>
- Zhao, H., Chen, Z., Jiang, H., Jing, W., Sun, L., & Feng, M. (2019). Evaluation of three deep learning models for early crop classification using Sentinel-1A imagery time series—A case study in Zhanjiang, China. *Remote Sensing*, 11(22), Article 2673. <https://doi.org/10.3390/rs11222673>