



## Evaluación de Flecha Seca en palma aceitera (*Elaeis guineensis* Jacq.) mediante imágenes multispectrales, Costa Rica<sup>1</sup>

### Bud rot evaluation in oil palm (*Elaeis guineensis* Jacq.) using multispectral imaging, Costa Rica

Bryan Alemán-Montes<sup>2</sup>, Carlos Henríquez-Henríquez<sup>2,3</sup>, Kenneth Largaespada-Zelaya<sup>3</sup>,  
Tatiana Ramírez-Rodríguez<sup>2</sup>

- <sup>1</sup> Recepción: 24 de junio, 2021. Aceptación: 18 de octubre, 2021. Esta investigación se desarrolló bajo el convenio entre el Instituto Nacional de Fomento Cooperativo (INFOCOOP) y la Universidad de Costa Rica, en cumplimiento de los objetivos de los proyectos VI-733-B5-508 y VI-733-B5-A11. Además, contó con la colaboración de las empresas GEOINN en la toma de información multispectral y de CoopeCalifornia R.L. en la logística para las evaluaciones con criterio experto.
- <sup>2</sup> Universidad de Costa Rica, Centro de Investigaciones Agronómicas. C.P. 11501, San José, Costa Rica. bryan.aleman@ucr.ac.cr (autor para la correspondencia; <https://orcid.org/0000-0003-4349-2255>), carlos.henriquez@ucr.ac.cr (<https://orcid.org/0000-0003-1487-4246>), tatiana.ramirezrodriguez@ucr.ac.cr (<https://orcid.org/0000-0001-8598-1247>).
- <sup>3</sup> Universidad de Costa Rica, Sede Atlántico, Carrera de Agronomía. C.P. 30501, Cartago, Costa Rica. kenneth.largaespada@ucr.ac.cr (<https://orcid.org/0000-0003-4651-443X>).

## Resumen

**Introducción.** El uso de la teledetección para identificar los diferentes estados de la salud de los cultivos, así como su relación con el rendimiento, constituye una herramienta muy importante en la implementación de la Agricultura de Precisión. **Objetivo.** Relacionar el estado fitosanitario, obtenido por expertos mediante la evaluación visual, de plantas de palma de aceite (*Elaeis guineensis* Jacq.) afectadas por el síndrome de Flecha Seca (SFS), con los índices de vegetación calculados a partir de imágenes multispectrales obtenidas con un vehículo aéreo no tripulado (VANT). **Materiales y métodos.** El estudio se desarrolló en una plantación de cuatro hectáreas con palma de aceite de tres años de trasplantada, propiedad de CoopeCalifornia R.L. ubicada en Parrita, Costa Rica. Se realizaron cuatro evaluaciones visuales del estado del SFS de diciembre de 2014 a febrero de 2017. Con estas evaluaciones se obtuvo la evolución espacio-temporal de la incidencia de la SFS durante veintiséis meses. En la última evaluación se realizó un vuelo con un VANT que portaba una cámara multispectral Parrot Sequoia, con la cual se calcularon los índices de vegetación que luego fueron relacionados con el estado de SFS de las plantas. **Resultados.** Se encontró una alta variabilidad espacial y temporal del SFS durante todas las evaluaciones visuales. También se logró encontrar una fuerte relación entre los datos de las evaluaciones obtenidas en campo con los datos generados a partir de sensores remotos. El índice de vegetación Simple Ratio (SR) mostró diferencias significativas entre las plantas clasificadas como sanas y las plantas clasificadas con SFS, con grados 2 y 3 de severidad. **Conclusiones.** Es posible relacionar datos de campo, obtenidos mediante criterio experto, con información multispectral de alta resolución espacial para identificar el SFS en plantaciones comerciales de palma aceitera.

**Palabras clave:** teledetección, índices de vegetación, índice simple ratio.



## Abstract

**Introduction.** The use of remote sensing to identify the different plant health conditions, and its relationship with crop yield, constitutes a very important tool in the implementation of Precision Agriculture. **Objective.** To relate the phytosanitary status, obtained by experts through visual assessment, of oil palm (*Elaeis guineensis* Jacq.) plants affected by bud rot (BR), with the vegetation indices calculated with multispectral images obtained with an unmanned aerial vehicle (UAV). **Materials and methods.** The study was conducted in a four-hectare plantation with oil palm three-year-old, owned by CoopeCalifornia R.L., located in Parrita, Costa Rica. Four visual assessments of the BR state were conducted from December 2014 to February 2017. With these assessments, the spatial-temporal evaluation of the incidence of BR during 26 months was obtained. In the last evaluation, a flight was performed with a UAV carrying a Parrot Sequoia multispectral camera, with which vegetation indexes were calculated and then related to the BR status of the oil palm plants. **Results.** A high spatial and temporal variability of BR was found during all visual evaluations performed. A strong relationship was also found between data from field assessments and data generated from remote sensing. The Simple Ratio (SR) vegetation index showed significant differences between plants classified as healthy and plants classified with BR, with degrees 2 and 3 of severity. **Conclusions.** Field data, obtained through expert judgment, can be linked to high spatial resolution multispectral information to identify BR in commercial oil palm plantations.

**Keywords:** remote sensing, vegetation index, simple ratio index.

## Introducción

La evaluación y el monitoreo de los cultivos durante el ciclo de crecimiento, es de vital importancia en la producción agrícola (Tao et al., 2020). En los últimos años se han desarrollado nuevas metodologías para el monitoreo de los sistemas agroproductivos que incluyen el uso de sensores remotos mediante la teledetección; esto permite la rápida identificación de estados de estrés causados por factores bióticos y abióticos que impactan de forma negativa los cultivos. Una respuesta agronómica pronta y oportuna afecta de forma positiva la productividad (Sachs et al., 2012; Sishodia et al., 2020).

Múltiples estudios confirman la versatilidad y aplicabilidad que tienen las herramientas geoespaciales para monitorear el comportamiento espacial y temporal de las plantaciones agrícolas (Calera et al., 2017; Pinter et al., 2003; Weiss et al., 2020). La teledetección ha permitido caracterizar y evaluar objetos localizados sobre la superficie a través de comportamientos espectrales (Chuvieco, 2008). Las principales aplicaciones agrícolas han aprovechado la información espectral localizada desde el espectro visible (400 nm) hasta el infrarrojo térmico (14 000 nm), porque en este rango espectral la vegetación aprovecha de formas distintas la energía recibida del sol (Ferguson & Rundquist, 2018; Lillesand et al., 1987).

En las plantas, la reflectividad en el espectro visible es controlada por la clorofila, causante de manifestar el color verde en las plantas, debido a su mayor reflectividad en la región espectral del verde (500 a 600 nm), mientras tanto, las regiones espectrales del azul (400 a 500 nm) y el rojo (600 a 700 nm) presentan los puntos de mayor absorción de energía incidente (Campbell & Wynne, 2011; Chuvieco, 2008; Petropoulos & Kalaitzidis, 2012).

En la región del infrarrojo cercano (700 – 1300 nm), la reflectividad de los tejidos vegetales está controlada por la estructura interna de la hoja, donde la radiación incidente es reflejada con mayor magnitud por los tejidos mesófilos y las cavidades internas; en esta región del infrarrojo hay un bajo porcentaje de absorción y un alto porcentaje de energía reflejada. Entre ambas regiones espectrales (visible e infrarrojo cercano), se localiza el

borde de rojo que manifiesta un aumento acelerado del porcentaje de reflectancia, lo cual ha sido relacionado con vigorosidad de la vegetación (Campbell & Wynne, 2011; Chuvieco, 2008; Petropoulos & Kalaitzidis, 2012).

Investigaciones han demostrado que el infrarrojo medio (1300 – 2500 nm) posee dos regiones espectrales con alta absorción de energía (1350-1450 nm y 1800-2000 nm), dicha absorción ha sido vinculada a la humedad contenida en las hojas verdes de la vegetación (Ceccato et al., 2001; Fernández-Arango et al., 2015; Hennessy et al., 2020; Ustin et al., 2004).

Diversos estudios, que aprovechan el espectro visible en longitudes de onda superiores, han permitido evaluar propiedades de la vegetación, como por ejemplo: contenido de clorofila, humedad de la planta, condiciones generales de estrés, entre otras (Thenkabail et al., 2011). Dichos comportamientos espectrales pueden manifestarse en propiedades biofísicas o bioquímicas de las plantas, lo cual permite la identificación de alteraciones de forma temprana (Chuvieco, 2008; Mahlein, 2016). Para adquirir esa información se han utilizado sensores multiespectrales y/o hiperespectrales incorporados a plataformas satelitales, vehículos aéreos no tripulados, plataformas terrestres o radiómetros de campo, los cuales han mostrado su utilidad para la identificación temprana de condiciones de estrés en rangos espectrales imperceptibles para el ojo humano (Ferguson & Rundquist, 2018).

La teledetección también podría, por ejemplo, ser utilizada en la protección de cultivos, ya que el enfoque de radiodiagnóstico es capaz de proporcionar un monitoreo de plagas y enfermedades sin contacto, también considera la variabilidad espacial de forma eficiente, siempre y cuando existan síntomas discernibles en las plantas (Zhang et al., 2019). Las plantas con estrés por la afectación de algún patógeno disminuyen la producción de clorofila por una menor absorción de energía en las bandas rojas y azul, ello reduce la diferencia con la banda verde y ocasiona los colores amarillos en la vegetación. Además, en el infrarrojo cercano, la energía deja de ser reflejada y es absorbida por las hojas muertas o estresadas (Gogoi et al., 2018).

En muchos casos esas condiciones de estrés han sido analizadas a través de índices de vegetación como indicadores de la abundancia y actividad relativa de la vegetación (Petropoulos & Kalaitzidis, 2012). Los índices de vegetación que pueden medir distintas regiones espectrales, pueden utilizarse para detectar características vitales de la vegetación en respuesta a diferentes fenómenos como humedad, contenido de clorofila, índices de área foliar, incidencia de patógenos, etc. (Santoso et al., 2016).

Las aplicaciones del sensoramiento remoto en la agricultura han sido muy diversas como lo ha sido en los cultivos utilizados. Se han utilizado índices de vegetación en la discriminación de plantas de manzana sanas y afectadas por un inóculo de mancha foliar (Gröll et al., 2007). Con investigaciones realizadas en plantas de remolacha azucarera lograron establecer diferencias entre plantas sanas y otras afectadas por *Cercospora* (*Cercospora beticola*), mediante el uso de información hiperespectral (Mahlein et al., 2013). Se determinó que el índice de vegetación mejorado (EVI, por sus siglas en inglés) permite discriminar de mejor manera las áreas más afectadas por pudrición de raíz en plantaciones de algodón (Zhao et al., 2020).

En el cultivo de la palma de aceite (*Elaeis guineensis* Jacq.), las aplicaciones de sensores remotos han sido variadas y cubren diversos aspectos del cultivo como son la determinación y cambios de cobertura, estimación de la edad de las plantaciones, evaluación de indicadores ambientales y fijación de carbono, detección de enfermedades y estimación de producción (Loong Chong et al., 2017). Además, se evaluó el uso de imágenes multiespectrales para el conteo de plantas de palma de aceite, debido a la importancia de esta variable para el manejo de las plantaciones, con precisiones entre 90 y 95 % en el conteo de plantas (Santoso et al., 2016).

Otras investigaciones plantean el uso de análisis espectral y modelos estadísticos para detectar de forma temprana, plantas afectadas por Pudrición Basal de Tallo (PBT), lo cual confirma una reducción de la reflectancia en el sector del infrarrojo cercano y un aumento de la reflectancia en el espectro visible cuando aumentaba la severidad de la enfermedad, caso contrario sucede en plantas sanas (Liaghat et al., 2014). Mediante imágenes multiespectrales QuickBird se identificaron plantas afectadas por PBT con un 85 % de precisión e identificaron dos patrones espaciales de la enfermedad, el primero aleatorio y dendrítico en plantas adultas (Santoso et al., 2011).

Mediante espectroscopía de campo se ha logrado confirmar la menor reflectividad en el infrarrojo cercano en plantas bajo distintos grados de afectación del síndrome de Flecha Seca (SFS) (Chinchilla, 2008) en comparación con plantas sanas (Martínez-Barbáchano & Solís-Miranda, 2018).

Es necesario desarrollar más investigaciones sobre el uso de técnicas de detección remota del SFS para orientar los procesos de toma de decisiones en cuanto al avance y la evolución espacial del SFS. De esta forma, la presente investigación tuvo como objetivo relacionar el estado fitosanitario, obtenido por expertos mediante evaluación visual, de plantas de palma de aceite (*Elaeis guineensis* Jacq.) afectadas por el síndrome de flecha seca (SFS), con criterio experto, con los índices de vegetación calculados con imágenes multiespectrales obtenidas con un vehículo aéreo no tripulado (VANT).

## Materiales y métodos


La investigación de tipo observacional se desarrolló en los terrenos de la cooperativa CoopeCalifornia R.L., ubicada en el cantón Parrita de la provincia Puntarenas, Costa Rica, dedicada al cultivo de palma africana o aceitera (*Elaeis guineensis* Jacq.). El estudio se realizó en un área aproximada de cuatro hectáreas del lote Los 15 ubicado entre las coordenadas 9,536839° - 9,533168° latitud norte y 84,335819° - 84,334713° longitud oeste. La plantación se sembró en julio de 2013 con el material genético Compacta x Nigeria, a una densidad de siembra de 160 plantas por hectárea. Al inicio de este estudio la plantación tenía un año de sembrada, lo cual corresponde al inicio del ciclo vegetativo.

La plantación estaba sembrada en suelos del orden Inceptisol, con un régimen ústico de humedad, originado por depósitos aluviales del río Parrita (Mata et al., 2020). La región del Pacífico Central tiene precipitación media anual de 3750 mm, distribuidos en una estación seca y una lluviosa, con una temperatura promedio de 27 °C (Instituto Meteorológico Nacional de Costa Rica, 2021). La distribución espacial de las plantas evaluadas durante la investigación y su respectiva localización se muestra en la Figura 1.

Todas las plantas del lote se codificaron con el fin de facilitar la sistematización de la información relacionada a su estado fitosanitario, en particular con el SFS y su ubicación geográfica. Las cuatro evaluaciones de campo del SFS se realizaron entre diciembre 2014 y febrero 2017 a cargo de personal capacitado y con experiencia en la detección del SFS en las fincas; de esta forma las evaluaciones se realizaron bajo un criterio experto y en forma cualitativa mediante la observación, con la codificación que se muestra en el Cuadro 1, para clasificar las plantas según su estado sanitario con relación al SFS. Durante el año 2016 no fue posible realizar evaluaciones de campo por dificultades logísticas. A partir de la información obtenida se analizaron las tendencias espaciales y temporales de las plantas clasificadas como sanas o bajo algún grado de afectación del SFS.

Los distintos grados o escalas de afectación sobre la planta de palma se muestran en la Figura 2. Hubo un incremento en la afectación sobre las hojas cuando el daño avanzó de F1 hacia F3; en plantas con grado de afectación F1 la hoja bandera mostró lesiones cloróticas en los folíolos, mientras que las plantas con grado de afectación F3 perdieron toda el área foliar cercana a la hoja bandera. Las plantas clasificadas en FR presentaron lesiones en las hojas intermedias pero la hoja bandera emergió ya sin daños, lo cual demuestra su estado de recuperación.

En la última evaluación de campo, que fue en febrero de 2017 (cuando el cultivo tenía tres años y siete meses de plantado), se realizó un vuelo sobre el área de estudio, con un vehículo aéreo no tripulado (VANT) modelo Aibot X6V2 con un sensor multiespectral Parrot Sequoia con capacidad de captar información en las longitudes de onda verde (en 550 nm y con un ancho de banda de 40 nm), rojo (en 660 nm y con un ancho de banda de 40 nm), borde de rojo (en 735 nm y con un ancho de banda de 10 nm) e infrarrojo cercano (en 790 nm y con un ancho de banda de 40 nm), además de imágenes en RGB. Esto se hizo con el fin de relacionar los datos de campo obtenidos con imágenes multiespectrales.



**Figura 1.** (A) Distribución espacial de las plantas de palma de aceite (*Elaeis guineensis* Jacq.), evaluadas en lote Los 15. (B - C) Ubicación geográfica del área de estudio en el contexto de Parrita y Costa Rica, respectivamente. Cooperativa CoopeCalifornia R.L., Parrita, Puntarenas, Costa Rica, 2014-2017.


**Figure 1.** (A) Spatial distribution of the oil palms (*Elaeis guineensis* Jacq.) plants, evaluated in the plot Los 15. (B - C). Geographic location of the study area in the context of Parrita and Costa Rica respectively. CoopeCalifornia R.L. cooperative, Parrita, Puntarenas, Costa Rica, 2014-2017.

**Cuadro 1.** Criterios de clasificación del estado sanitario de las plantas de palma de aceite (*Elaeis guineensis* Jacq.), evaluadas en relación con el Síndrome de Flecha Seca (SFS). Cooperativa CoopeCalifornia R.L., Parrita, Puntarenas, Costa Rica, 2014-2017.

**Table 1.** Classification criteria of the oil palm (*Elaeis guineensis* Jacq.) plants health evaluated in relation to the Bud Rot (BR). CoopeCalifornia R.L. cooperative, Parrita, Puntarenas, Costa Rica, 2014-2017.

Símbolo	Descripción
S	Plantas sanas
F1	Plantas con afectación por Flecha seca en grado 1 (severidad baja)
F2	Plantas con afectación por Flecha seca en grado 2 (severidad media)
F3	Plantas con afectación por Flecha seca en grado 3 (severidad alta)
FR	Plantas que sufrieron Flecha seca pero que se encuentran en recuperación

La captura de imágenes se realizó mediante planes de vuelo programados y cubrieron la totalidad del área de estudio en dirección suroeste-noreste. Las imágenes contaban con traslape frontal y lateral de 80 %. Las imágenes obtenidas se corrigieron de forma automática con el sensor de irradiancia que portaba la cámara, lo cual permitió obtener la información en reflectancia calibrada y de forma automática, en todas las imágenes y bandas. La información multispectral se procesó con el software Pix4DMapper® (Pix4D SA, 2021), en el cual se alinearon todas las imágenes para construir los ortomosaicos individuales para cada una de las bandas, los cuales cubrían la totalidad del área de estudio y se utilizaron para el cálculo de los índices de vegetación analizados en esta investigación (Cuadro 2).



**Figura 2.** Plantas de palma de aceite (*Elaeis guineensis* Jacq.), bajo diferentes condiciones de afectación del SFS. (S) Sana, (F1) Flecha seca grado 1, (F2) Flecha seca grado 2, (F3) Flecha seca grado 3 y (FR) plantas en recuperación. Cooperativa CoopeCalifornia R.L., Parrita, Puntarenas, Costa Rica, 2014-2017.

**Figure 2.** Oil palm (*Elaeis guineensis* Jacq.) plants with different BR conditions. (S) Healthy, (F1) Bud Rot degree 1, (F2) Bud Rot degree 2, (F3) Bud Rot degree 3, and (FR) recovery plants. CoopeCalifornia R.L. cooperative, Parrita, Puntarenas, Costa Rica, 2014-2017.

Mediante técnicas de geoprocésamiento (extracción por máscara, estadísticas de zona) se extrajo el promedio de cada índice de vegetación para cada planta, los cuales se analizaron en relación con el estado sanitario reportado durante la evaluación con criterio experto de febrero de 2017. Dicha información se analizó estadísticamente mediante la prueba no-paramétrica Krustal Wallis, porque la cantidad de observaciones (definida por el número de plantas), varió entre grados de afectación del SFS. La aparición del SFS en las plantas se presentó de manera natural y no hubo inoculación inducida, factor que limitó la obtención de un número homogéneo de plantas según grados de afectación.

Se realizó un análisis de autocorrelación espacial para determinar si el fenómeno de afectación tenía una agrupación por *clusters* o el comportamiento espacial de afectación presentaba comportamientos aleatorios. Este análisis se ejecutó con el estadístico Índice de Moran integrado en el entorno de ArcGIS 10.7, que mide la autocorrelación espacial basada en ubicaciones y valores de las entidades de interés de manera simultánea (Environmental Systems Research Institute, 2021).

## Resultados

### Evolución espacio-temporal de la incidencia del SFS

Durante el período de evaluación (diciembre 2014 a febrero 2017), se encontró en el área de experimentación variaciones, tanto espaciales como temporales, del SFS. El porcentaje de plantas afectadas con SFS (en los grados

**Cuadro 2.** Índices de vegetación calculados a partir de la información multispectral obtenida de las imágenes de la cámara Parrot Sequoia, en la plantación de palma aceitera (*Elaeis guineensis* Jacq.). Cooperativa CoopeCalifornia R.L., Parrita, Puntarenas, Costa Rica, 2014-2017.

**Table 2.** Vegetation indices calculated from the multispectral information obtained from the Parrot Sequoia camera images, in the oil palm (*Elaeis guineensis* Jacq.) plantation. CoopeCalifornia R.L. cooperative, Parrita, Puntarenas, Costa Rica, 2014-2017.

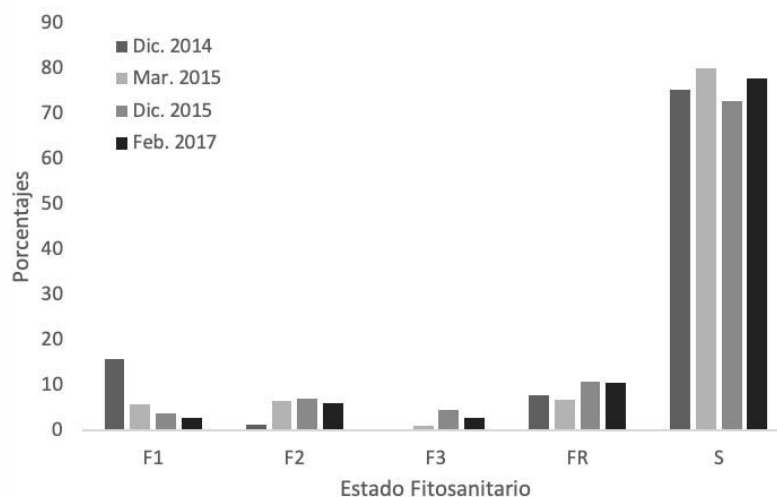
Índice	Fórmula
Índice de reflectancia antocianina (ARI - <i>Anthocyanin Reflectance Index</i> )	$\frac{1}{Green} - \frac{1}{Red\ Edge}$
Índice de vegetación resistente a la atmósfera (ARVI - <i>Atmosferical Resistant Vegetation Index</i> )	$\frac{-0,18 + 1.17 \times (NIR - Red)}{NIR + Red}$
Diferencia entre NIR y el índice de vegetación de diferencia verde (GDVI - <i>Difference NIR/Green Green Difference Vegetation Index</i> )	$NIR - Green$
Índice de vegetación de diferencia normalizada verde (GNDVI - <i>Green Normalized Difference Vegetation Index</i> )	$\frac{NIR - Green}{NIR + Green}$
Índice de vegetación de proporción verde (GRVI - <i>Green Ratio Vegetation Index</i> )	$\frac{NIR}{Green}$
Índice de vegetación de diferencia normalizada (NDVI - <i>Normalized Difference Vegetation Index</i> )	$\frac{NIR - Red}{NIR + Red}$
Índice de vegetación ajustada al suelo (SAVI - <i>Soil-Adjusted Vegetation Index</i> )	$\frac{NIR - Red}{(NIR + Red + 0,5) \times (1 + 0,5)}$
Proporción simple o índice de proporción de vegetación (SR - <i>Simple Ratio o RVI (Ratio Vegetation Index)</i> )	$\frac{NIR}{Red}$
Índice de vegetación de diferencia renormalizada (RDVI - <i>Renormalized Difference Vegetation Index</i> )	$\frac{NIR - Red}{(NIR + Red)^{0,5}}$

Fuente / Source: Birth y McVey (1968), Exelis Visual Information Solutions, Inc. (2016), Huete (1988), Gitelson y Merzlyak (1998), Gitelson et al. (2001), Kaufman y Tanre (1992), Roujean y Breon (1995), Rouse et al. (1974) y Sripada et al. (2006).

de afectación F1, F3) varió durante el periodo de evaluación en ambas dimensiones, lo que dejó en evidencia la fuerte dinámica del SFS en el campo en plantas jóvenes de palma aceitera.

Al inicio de las evaluaciones (diciembre 2014) el 15,6 % de las plantas estaban afectadas por SFS en grado 1 y el 7,6 % presentaron un estado de recuperación de la afectación. En la evaluación de marzo del 2015, el porcentaje de plantas en la condición F1 disminuyó con respecto a la primera evaluación; dicha disminución estuvo relacionada con el aumento en las condiciones F2 (6,4 %) y S (80 %). Durante la tercera evaluación (diciembre 2015), la variación más significativa sucedió la condición F3, donde fue evidente un aumento en el porcentaje de plantas afectadas (4,5 %), el porcentaje de plantas en la categoría FR aumentó a 10,4 %. En la evaluación de febrero de 2017 se observaron disminuciones en el porcentaje de plantas en las condiciones F1, F2, F3 y FR, y un aumento en el porcentaje de plantas sanas (Figura 3).

La variación espacial del SFS presentó la mayor incidencia de plantas con categoría F1 en diciembre de 2014, en el sector noroeste del área de estudio, de igual manera se observó en dicha área la mayor incidencia de plantas en categoría FR. En marzo de 2015, se encontró una reducción de las plantas en condición F1 y un aumento de las clasificadas como F2, F3 y FR, este comportamiento se focalizó en el sector noroeste. En diciembre de 2015 la



**Figura 3.** Variación temporal de la incidencia del SFS en palma aceitera (*Elaeis guineensis* Jacq.), en el lote Los 15, durante las evaluaciones realizadas en diciembre de 2014, marzo de 2015, diciembre de 2015 y febrero de 2017. Cooperativa CoopeCalifornia R.L., Parrita, Puntarenas, Costa Rica, 2014-2017.

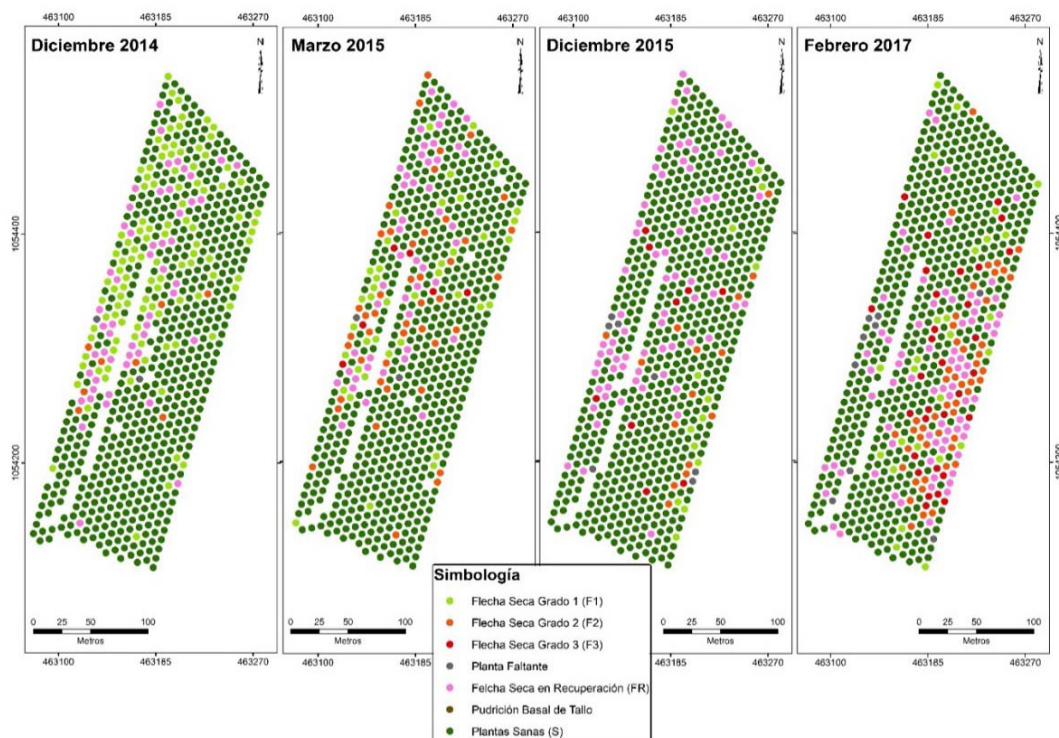
**Figure 3.** Temporal variation in the oil palm (*Elaeis guineensis* Jacq.) BR incidence, in Los 15 plot, during the valuations carried out in December 2014, March 2015, December 2015, and February 2017. CoopeCalifornia R.L. cooperative, Parrita, Puntarenas, Costa Rica, 2014-2017.

presencia de plantas en condición F1 en el sector noroeste fue casi nulo y resaltó el aumento de esta categoría en el sector sureste, así como el agrupamiento de plantas FR en el sector central. En febrero de 2017 hubo un cambio evidente del foco de afectación, las plantas localizadas al sureste presentaron la mayor incidencia de afectación (F1, F2 o F3) o bien presencia de plantas recuperadas (FR) (Figura 4). Todo lo anterior, demuestra la evolución espacial del SFS en el área de estudio en un período de veintiséis meses.

### Índices de vegetación para la identificación del estado sanitario de las plantas

Los índices de vegetación utilizados en este estudio presentaron diferentes grados de sensibilidad en la discriminación del estado sanitario de las plantas (Cuadro 3). El índice SR fue el que, desde el punto de vista agronómico, permitió hacer una discriminación más directa, al separar las plantas sanas (S) de las afectadas (F2 y F3). Las plantas enfermas en forma leve (F1) tuvieron semejanza estadística con las plantas en recuperación (letras bc y ab en el análisis, respectivamente). Los índices NDVI (*Normalized Difference Vegetation Index*) y GNDVI (*Green Normalized Difference Vegetation Index*), lograron discriminar el conjunto de plantas en dos grupos que fueron las plantas sanas o afectadas de forma leve (S, FR y F1) de las plantas con mayores grados de afectación (F2 y F3).

Los restantes índices de vegetación no presentaron valores estadísticos cuya significancia estadística permitiera la separación de los estados de afectación de una forma más contundente (Cuadro 3). De esta manera, los índices de vegetación ARI (*Anthocyanin Reflectance Index*), ARVI (*Atmosferical Resistant Vegetation Index*), GDVI (*Difference NIR/Green Green Difference Vegetation Index*), GRVI (*Green Ratio Vegetation Index*), SAVI (*Soil-Ajusted Vegetation Index*) y RDVI (*Renormalized Difference Vegetation Index*), no presentaron resultados satisfactorios en la separación de las condiciones evaluadas, ya que no lograron establecer diferencias estadísticamente significativas y congruentes entre las condiciones fitosanitarias; por ejemplo, estos índices de



**Figura 4.** Variación espacio y temporal de la incidencia del Síndrome de Flecha Seca en palma aceitera (*Elaeis guineensis* Jacq.) el lote Los 15. Cooperativa CoopeCalifornia R.L., Parrita, Puntarenas, Costa Rica, 2014-2017.

**Figure 4.** Spatial and temporal variation of oil palm (*Elaeis guineensis* Jacq.) Bud Rot incidence in Los 15 plot. CoopeCalifornia R.L. cooperative, Parrita, Puntarenas, Costa Rica, 2014-2017.

**Cuadro 3.** Resultado de la prueba de Kruskal Wallis para la identificación de diferencias en los índices de vegetación, según estado sanitario de las plantas de palma aceitera (*Elaeis guineensis* Jacq.). Cooperativa CoopeCalifornia R.L., Parrita, Puntarenas, Costa Rica, 2014-2017.

**Table 3.** The Kruskal Wallis test result to identify differences between the vegetation indexes, according to the oil palm (*Elaeis guineensis* Jacq.) plants health. CoopeCalifornia R.L. cooperative, Parrita, Puntarenas, Costa Rica, 2014-2017.

Condición	Índices de vegetación								
	ARI	ARVI	GDVI	GNDVI	GRVI	NDVI	SAVI	SR	RDVI
S	b	b	b	b	b	b	b	c	b
F1	b	ab	ab	b	b	b	ab	bc	ab
FR	ab	ab	ab	ab	ab	b	ab	ab	ab
F2	ab	a	a	a	ab	a	a	a	a
F3	a	ab	ab	a	a	a	ab	a	a

Medias con igual letra no poseen diferencias significativas ( $p > 0.05$ ). ARI: índice de reflectancia antocianina; ARVI: índice de vegetación resistente a la atmósfera; GDVI: diferencia entre NIR y el índice de vegetación de diferencia verde; GNDVI: diferencia entre NIR y el índice de vegetación de diferencia verde; GRVI: índice de vegetación de proporción verde; NDVI: índice de vegetación de diferencia normalizada; SAVI: índice de vegetación ajustada al suelo; SR: proporción simple; RDVI: índice de vegetación de diferencia renormalizada / The indexes with the same letter do not a significative difference ( $p > 0.05$ ). ARI: Anthocyanin Reflectance Index; ARVI: Atmosferical Resistant Vegetation Index; GDVI: Difference NIR/Green Green Difference Vegetation Index; GRVI: Green Ratio Vegetation Index; NDVI: Normalized Difference Vegetation Index; SAVI: Soil-Ajusted Vegetation Index; SR: Simple Ratio; RDVI: Renormalized Difference Vegetation Index.

vegetación presentaron letras similares (a o b) en cuatro de las cinco categorías analizadas, razón por la cual fueron excluidos del análisis detallado que sigue a continuación.

Se encontró que el índice de vegetación proporción simple (SR), mostró diferencias significativas entre las plantas clasificadas como sanas (S) y las plantas clasificadas con SFS con grados 2 y 3 de severidad (F2 y F3). Pese a ello, no se encontraron diferencias significativas entre las plantas sanas y aquellas que estaban con afectación de SFS en grado 1 (F1); esto parece una carencia del índice al no tener la capacidad de predecir un estado previo o predisposición de la planta, antes de que aparezcan los síntomas más severos. Las plantas clasificadas como F1 presentaron diferencias significativas cuando se compararon con plantas que presentaron grados de severidad mayor del SFS; no sucedió lo mismo al comparar plantas en recuperación con plantas en grado 1 de afectación (Cuadro 4).

**Cuadro 4.** Resultado de la prueba de Kruskal Wallis para la identificación de diferencias en el índice “proporción simple”, según estado sanitario de las plantas de palma aceitera (*Elaeis guineensis* Jacq.). Cooperativa CoopeCalifornia R.L., Parrita, Puntarenas, Costa Rica, 2014-2017.

**Table 4.** Kruskal Wallis test result to identify differences in the “Simple Ratio” index, according to the oil palm (*Elaeis guineensis* Jacq.) plants health. CoopeCalifornia R.L. cooperative, Parrita, Puntarenas, Costa Rica, 2014-2017.

Condición	N	Media	D.E	Mediana	P
S	505	11,39 c	4,11	10,88	0,0001
F1	26	11,28 bc	4,91	11,94	
FR	75	10,47 ab	4,34	9,77	
F2	49	9,16 a	3,65	8,43	
F3	29	9,01 a	3,99	7,47	

Medias con igual letra no poseen diferencias significativas. N: población; D.E: desviación estándar. / Means with the same letter do not have significant differences. N: population; D.E: standard deviation.

Con base en el índice de Moran, se calculó la autocorrelación espacial de los valores del índice de vegetación SR con el fin de determinar de forma indirecta la autocorrelación de la variable cualitativa incidencia del SFS. Se logró determinar que la distribución espacial de los valores obtenidos con el SR se debió en más de un 99 % a una agrupación por *clusters* y no a un ordenamiento al azar de los datos, lo cual concuerda con la distribución observada (Figura 4) y explica el posible comportamiento del SFS en el campo. El índice SR determinó a nivel espacial patrones dentro del área de estudio, así la afectación por el SFS respondió a *clusters* discernibles a nivel espacial con técnicas de sensoramiento remoto.

El índice de vegetación NDVI, separó el conjunto de plantas en dos grupos, el primero estuvo conformado por las plantas clasificadas como S, FR y F1, mientras en el segundo agrupó las plantas clasificadas como F2 y F3 (Cuadro 5). El índice NDVI logró separar plantas con alta afectación del SFS y las plantas con nulo o menor deterioro foliar. Al igual que el índice SR, el NDVI no fue capaz de predecir el estado de afectación de SFS previo a la aparición de síntomas, esto es en el estado F1.

Con el índice GNDVI se separaron los grados de afectación en dos grupos, el primero incluyó las plantas S y F1 y el segundo las plantas F2 y F3; hubo una clara separación entre plantas sanas o con afectación leve, de aquellas con grados de afectación alto. Además, posicionó las plantas en recuperación (FR) en una condición intermedia

**Cuadro 5.** Resultado de la prueba de Kruskal Wallis para la identificación de diferencias en el índice de vegetación de diferencia normalizada (NDVI), según estado sanitario de las plantas de palma aceitera (*Elaeis guineensis* Jacq.). Cooperativa CoopeCalifornia R.L., Parrita, Puntarenas, Costa Rica, 2014-2017.

**Table 5.** Kruskal Wallis test result to identify differences in the Normalized Difference Vegetation Index (NDVI), according to the oil palm (*Elaeis guineensis* Jacq.) plants health. CoopeCalifornia R.L. cooperative, Parrita, Puntarenas, Costa Rica, 2014-2017.

Condición	N	Media	D.E	Mediana	P
S	505	0,78 b	0,08	0,79	0,0004
F1	26	0,77 b	0,11	0,80	
FR	75	0,77 b	0,09	0,77	
F2	49	0,74 a	0,08	0,74	
F3	29	0,73 a	0,09	0,71	

Medias con igual letra no poseen diferencias significativas. N: población; D.E: desviación estándar. / Means with the same letter do not have significant differences. N: Population; D.E: Standard deviation.

que no permitió separarlas de ninguno de los grupos, lo cual tendría cierta lógica desde el punto de sanidad de las plantas (Cuadro 6).

**Cuadro 6.** Resultado de la prueba de Kruskal Wallis para la identificación de diferencias en el índice de vegetación de diferencia normalizada verde (GNDVI), según estado sanitario de las plantas de palma aceitera (*Elaeis guineensis* Jacq.). Cooperativa CoopeCalifornia R.L., Parrita, Puntarenas, Costa Rica, 2014-2017.

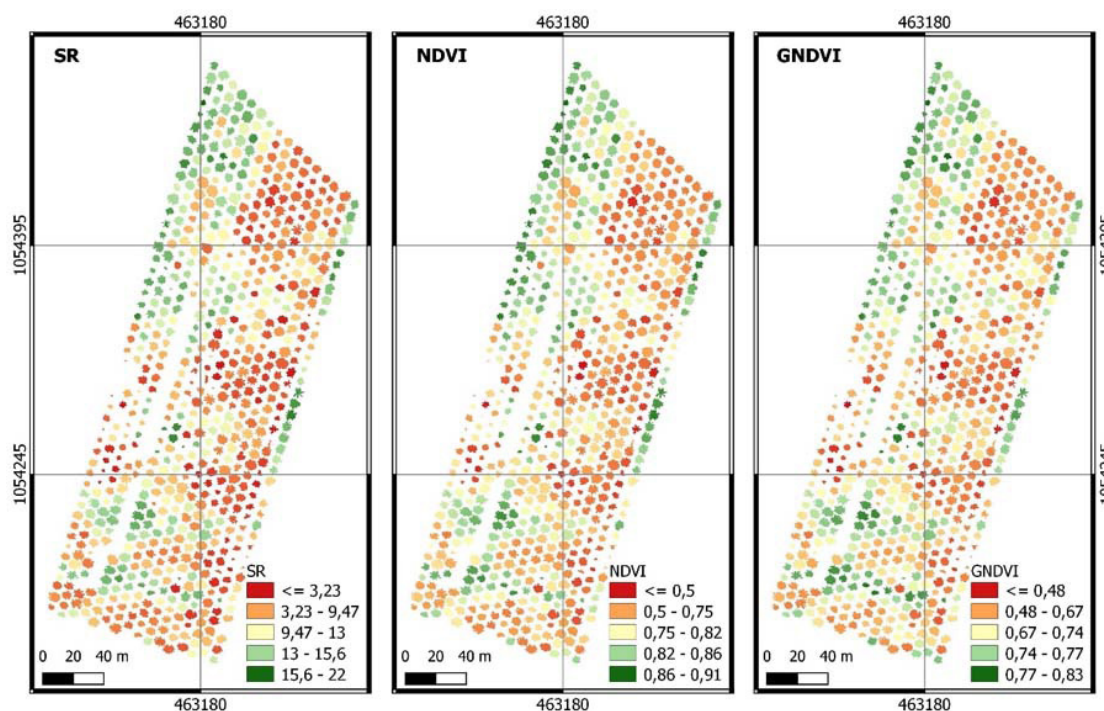
**Table 6.** Kruskal Wallis test results to identify differences in the Green Normalized Difference Vegetation (GNDVI), according to the health status of oil palm (*Elaeis guineensis* Jacq.) plants. CoopeCalifornia R.L. cooperative, Parrita, Puntarenas, Costa Rica, 2014-2017.

Condición	N	Media	D.E	Mediana	P
S	505	0,71 b	0,07	0,71	0,0027
F1	26	0,70 b	0,09	0,74	
FR	75	0,70 ab	0,07	0,70	
F2	49	0,68 a	0,07	0,67	
F3	29	0,67 a	0,07	0,65	

Medias con igual letra no poseen diferencias significativas. N: población; D.E: desviación estándar. / Means with the same letter do not have significant differences. N: Population; D.E: Standard deviation.

Los índices de vegetación SR, NDVI y GNDVI, tuvieron similitudes en los patrones de variación espacial, las plantas con valores más altos se localizaron en el sector noroeste y en un cluster localizado al sur del área de estudio; además, los patrones espaciales fueron similares entre los diferentes índices de vegetación (Figura 5).

Al comparar la información de la evaluación visual de febrero de 2017 con los índices de vegetación SR, NDVI y GNDVI fue posible observar la mayor incidencia del SFS en áreas donde se reportó menor porción fotosintética activa de la vegetación a través de los diversos índices identificados como favorables en el estudio.



**Figura 5.** Variación espacial de la proporción simple (SR), el índice de vegetación de diferencia normalizada (NDVI) y el índice de vegetación de diferencia normalizada verde (GNDVI) en el área de estudio en febrero 2017 (IV evaluación del Síndrome de Flecha Seca) en la palma aceitera (*Elaeis guineensis* Jacq.). Cooperativa CoopeCalifornia R.L., Parrita, Puntarenas, Costa Rica.

**Figure 5.** Spatial and temporal variation of the Simple Ratio (SR), Normalized Difference Vegetation Index (NDVI), and Green Normalized Difference Vegetation Index (GNDVI) in the study area in February 2017 (IV evaluation of oil palm (*Elaeis guineensis* Jacq.) Bud rot). Cooperativa CoopeCalifornia R.L., Parrita, Puntarenas, Costa Rica.

## Discusión

La incidencia del SFS en la plantación presentó múltiples variaciones espaciales y temporales durante el estudio; es importante considerar que se presentaron casos de recuperación de plantas en estados intermedios de afectación del SFS. Cuando ocurre esta recuperación, puede tardar entre cuatro meses y seis años (Acosta & Munévar, 2003). Plantas que fueron catalogadas como sanas en una evaluación previa, resultaron con algún grado de afectación meses después, lo cual demuestra el alto grado de evolución y dinámica del SFS.

El comportamiento espacio-temporal de la incidencia del SFS tuvo dos etapas marcadas. Al inicio de las evaluaciones, el sector noroeste estuvo más afectado, pero se logró recuperar; caso contrario sucedió en el sector sureste, donde en las primeras evaluaciones se presentó alto porcentaje de plantas sanas, y en la última evaluación se encontró el mayor porcentaje de plantas afectadas. Además, la prueba de autocorrelación espacial permitió definir que dicho comportamiento respondió a una agrupación por clusters alrededor de las primeras plantas reportadas como afectadas, lo cual permite afirmar que las plantas cercanas a una planta afectada, tienen mayor probabilidad ser afectadas por el SFS. El mismo comportamiento fue identificado en plantaciones de palma de aceite afectadas por flecha seca en Surinam (Van de Lande & Zadoks, 1999).

Los datos obtenidos por sensores remotos a bordo de VANT, mostraron diferencias significativas en cuanto a los niveles de afectación por SFS. La mejor diferenciación entre plantas sanas y plantas afectadas por SFS, en

los grados de severidad 2 y 3 (F2 y F3), fue posible al utilizar el índice de vegetación proporción simple (SR), por considerar regiones espectrales contrastantes en la energía reflejada y absorbida, variaciones en estos rangos espectrales están relacionados con modificaciones fisiológicas de la vegetación (color, densidad, forma, variación con la interacción de la energía solar) (Mahlein et al., 2018). En una plantación de palma aceitera de dieciséis años, se logró obtener un 85 % de precisión en la clasificación de plantas afectadas y sanas con el índice SR (Santoso et al., 2011). De igual manera se han reportado precisiones superiores al 80 % en la clasificación de plantas sanas y afectadas con el empleo del índice de vegetación proporción simple (SR) (Shafri & Hamdan, 2009). Otros autores, han determinado los índices VARI, RDVI, NDVI, SAVI y OSAVI como promisorios en la detección de plantas afectadas (Shafri & Hamdan, 2009; Viera-Torres et al., 2020).

Los índices NDVI y GNDVI presentaron, de acuerdo con los resultados estadísticos, una menor capacidad de separación de categorías de afectación del SFS al compararlas con el índice de vegetación SR; sin embargo, lograron separar las plantas sanas o con afectaciones leves (S y F1), de aquellas con grados de afectación mayor (F2 y F3). Además, estos índices de vegetación no lograron separar las plantas en condiciones de recuperación (FR).

Los datos obtenidos reafirman la aplicabilidad potencial de esta metodología en la evaluación del estado fitosanitario de los cultivos agrícolas. Se propone llevar a cabo más investigación con el fin de verificar si el aumentar la resolución espacial y/o el número de evaluaciones mediante imágenes multispectrales, pudiese incidir en una mejor diferenciación entre las categorías con afectación de SFS. En seguimiento de enfermedades mediante información multispectral se deben solventar retos como: ruido de fondo, condiciones de campo desfavorables, limitaciones de sensores, variaciones de síntomas (Arnal Barbedo, 2019). Se requiere el uso de sensores hiperespectrales para evaluar las particularidades imposibles de capturar con sensores RGB-NIR (Khanal et al., 2020).

## Conclusiones

Fue posible relacionar datos de campo, obtenidos mediante criterio experto, con información multispectral de alta resolución espacial para identificar el síndrome de Flecha Seca en plantaciones comerciales de palma aceitera.

Esta investigación se realizó en una plantación de palma de aceite de cuatro años, sin embargo, los resultados encontrados en este trabajo, así como en otras investigaciones, permiten sugerir que la herramienta de teledetección de alta resolución espacial y temporal podría ser utilizada en forma exitosa para el monitoreo remoto del cultivo de palma aceitera y su potencial afectación del SFS, así como su evolución espacial. Se lograron los mejores resultados con el índice de vegetación SR, se confirma la utilidad de las longitudes de onda del rojo (660 nm) y el infrarrojo cercano (790 nm), en la detección de problemas sanitarios en plantaciones de palma. Estas mismas técnicas pueden ser valoradas para determinar áreas de mayor incidencia y a una mayor escala con el fin reducir costos, aumentar la eficiencia productiva y aumentar el conocimiento espacio temporal del SFS. Esta técnica podría servir previa calibración de los índices, para abordar detecciones de otras características como son por ejemplo de vigor de planta, una etapa que podría ser cubierta con futuras investigaciones.

## Referencias

- Acosta, A., & Munévar, F. (2003). Bud rot in oil palm plantations: link to soil physical properties and nutrient status. *Better Crops International*, 17(2), 22–25.
- Arnal Barbedo, J. G. (2019). A review on the use of unmanned aerial vehicles and imaging sensors for monitoring and assessing plant stresses. *Drones*, 3(2), Article 40. <https://doi.org/10.3390/drones3020040>

- Birth, G. S., & McVey, G. R. (1968). Measuring the color of growing turf with a reflectance spectrophotometer. *Agronomy Journal*, 60(6), 640–643. <https://doi.org/10.2134/agronj1968.00021962006000060016x>
- Calera, A., Campos, I., Osann, A., D'Urso, G., & Menenti, M. (2017). Remote sensing for crop water management: From ET modelling to services for the end users. *Sensors*, 17(5), Article 1104. <https://doi.org/10.3390/s17051104>
- Campbell, J. B., & Wynne, R. H. (2011). *Introduction to remote sensing* (5<sup>th</sup> Ed.). Guilford Press.
- Ceccato, P., Flasse, S., Tarantola, S., Jacquemoud, S., & Grégoire, J. M. (2001). Detecting vegetation leaf water content using reflectance in the optical domain. *Remote Sensing of Environment*, 77(1), 22–33. [https://doi.org/10.1016/S0034-4257\(01\)00191-2](https://doi.org/10.1016/S0034-4257(01)00191-2)
- Chinchilla, C. M. (2008). Las muchas caras de las pudriciones del cogollo (y de flechas) en palma aceitera y la importancia de un enfoque integral para su manejo. *ASD Oil Palm Papers*, 32, 11–23. <https://bit.ly/31aSUCx>
- Chuvieco, E. (2008). *Teledetección ambiental* (3<sup>a</sup> ed.). Ariel Ciencia.
- Environmental Systems Research Institute. (2021). *Cómo funciona Autocorrelación espacial (I de Moran global)*. ArcGIS. <https://bit.ly/350f63Z>
- Exelis Visual Information Solutions, Inc. (2016). *Broadband Greenness*. L3HARRIS. <https://bit.ly/3LP8czl>
- Fernández-Arango, D., Martín-Isabel, P., Vilar del Hoyo, L., & Pacheco-Labrador, J. (2015). Estimación del contenido de humedad de la vegetación a partir de imágenes hiperespectrales adquiridas por el sensor aeroportado CASI (Compact Airborne Spectrographic Imager). *Geofocus: Revista Internacional de Ciencia y Tecnología de la Información Geográfica*, 16, 177–204. <http://www.geofocus.org/index.php/geofocus/article/view/399>
- Ferguson, R., & Rundquist, D. (2018). Remote sensing for site-specific crop management. In D. K. Shannon, D. E. Clay, & N. R. Kitchen (Eds.), *Precision agriculture basics* (pp. 103–117). American Society of Agronomy, Crop Science Society of America, & Soil Science Society of America. <https://doi.org/10.2134/precisionagbasics.2016.0092>
- Gitelson, A. A., & Merzlyak, M. N. (1998). Remote sensing of chlorophyll concentration in higher plant leaves. *International Journal of Remote Sensing*, 18(12), 2691–2697. <https://doi.org/10.1080/014311697217558>
- Gitelson, A. A., Merzlyak, M. N., & Chivkunva, O. B. (2001). Optical properties and nondestructive estimation of anthocyanin content in plant leaves. *Photochemistry and Photobiology*, 74(1), 38–45. [https://doi.org/10.1562/0031-8655\(2001\)074<0038:opaneo>2.0.co;2](https://doi.org/10.1562/0031-8655(2001)074<0038:opaneo>2.0.co;2)
- Gogoi, N. K., Deka, B., & Bora, L. C. (2018). Remote sensing and its use in detection and monitoring plant diseases: A review. *Agricultural Reviews*, 39(4), 307–313. <https://doi.org/10.18805/ag.r-1835>
- Gröll, K., Graeff, S., & Claupein, W. (2007, März 5-7). *Use of vegetation indices to detect plant diseases* [Conference presentation Referate der 27]. Agrarinformatik im Spannungsfeld zwischen Regionalisierung und globalen Wertschöpfungsketten, Stuttgart, Germany. <https://bit.ly/33JE72Y>
- Hennessy, A., Clarke, K., & Lewis, M. (2020). Hyperspectral classification of plants: A review of waveband selection generalisability. *Remote Sensing*, 12(1), Article 113. <https://doi.org/10.3390/rs12010113>
- Huete, A. R. (1988). A Soil-Adjusted Vegetation Index (SAVI). *Remote Sensing of Environment*, 25, 295–309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- Instituto Meteorológico Nacional del Costa Rica. (2021). *Datos climáticos estación de Damas en Aguirre*. <https://www.imn.ac.cr/mapa>

- Kaufman, Y. J., & Tanre, D. (1992). Atmospherically Resistant Vegetation Index (ARVI) for EOS-MODIS. *IEEE Transactions on Geoscience and Remote Sensing*, 30(2), 261–270. <https://doi.org/10.1109/36.134076>
- Khanal, S., Kushal, K. C., Fulton, J. P., Shearer, S., & Ozkan, E. (2020). Remote sensing in agriculture—accomplishments, limitations, and opportunities. *Remote Sensing*, 12(22), Article 3783. <https://doi.org/10.3390/rs12223783>
- Liaghat, S., Ehsani, R., Mansor, S., Shafri, H. Z. M., Meon, S., Sankaran, S., & Azam, S. H. M. N. (2014). Early detection of basal stem rot disease (Ganoderma) in oil palms based on hyperspectral reflectance data using pattern recognition algorithms. *International Journal of Remote Sensing*, 35(10), 3427–3439. <https://doi.org/10.1080/01431161.2014.903353>
- Lillesand, T. M., Kiefer, R. & Chipman, J. (1987). *Remote sensing and image interpretation* (2<sup>nd</sup> ed.). John Wiley & Sons.
- Loong Chong, K., Devi Kanniah, K., Pohl, C., & Pang Tan, K. (2017). A review of remote sensing applications for oil palm studies. *Geo-Spatial Information Science*, 20(2), 184–200. <https://doi.org/10.1080/10095020.2017.1337317>
- Mahlein, A. K. (2016). Present and future trends in plant disease detection. *Plant Disease*, 100(2), 241–251. <https://doi.org/10.1094/PDIS-03-15-0340-FE>
- Mahlein, A. K., Kuska, M. T., Behmann, J., Polder, G., & Walter, A. (2018). Hyperspectral sensors and imaging technologies in phytopathology: state of the art. *Annual Review of Phytopathology*, 56, 535–558. <https://doi.org/10.1146/annurev-phyto-080417-050100>
- Mahlein, A. K., Rumpf, T., Welke, P., Dehne, H. W., Plümer, L., Steiner, U., & Oerke, E. C. (2013). Development of spectral indices for detecting and identifying plant diseases. *Remote Sensing of Environment*, 128, 21–30. <https://doi.org/10.1016/j.rse.2012.09.019>
- Martínez-Barbáchano, R., & Solís-Miranda, G. A. (2018). Caracterización espectral y detección de Flecha Seca en palma africana en Puntarenas, Costa Rica. *Revista Geográfica de América Central*, 61(2), 349–377. <https://doi.org/10.15359/rgac.61-2.13>
- Mata, R., Rosales, A., Sandoval, D., Vindas, E., & Alemán, B. (2020). *Subórdenes de suelos de Costa Rica* [mapa digital, escala 1:200000]. Universidad de Costa Rica. [http://www.cia.ucr.ac.cr/?page\\_id=139](http://www.cia.ucr.ac.cr/?page_id=139)
- Petropoulos, G., & Kalaitzidis, C. (2012). Multispectral vegetation index in remote sensing: An overview. In W. Zhang (Ed.), *Ecological modeling* (pp. 15–34). Nova Science Publishers, Inc.
- Pinter, P. J., Hatfield, J. L., Schepers, J. S., Barnes, E. M., Moran, M. S., Daughtry, C. S., & Upchurch, D. R. (2003). Remote sensing for site-specific crop management. *Photogrammetric Engineering & Remote Sensing*, 69(6), 647–664.
- Pix4D SA. (2021). *Pix4DMapper@*. <https://www.pix4d.com/es/acerca-de-pix4d>
- Roujean, J. L., & Breon, F. M. (1995). Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote Sensing of Environment*, 51(3), 375–384. [https://doi.org/10.1016/0034-4257\(94\)00114-3](https://doi.org/10.1016/0034-4257(94)00114-3)
- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the great plains with ERTS (Paper A 20). In S. C. Freden, E. P. Mercanti, & M. A. Becker (Eds.), *Third Earth Resources Technology Satellite-1 Symposium. Volume 1: Technical Presentations, section A* (pp. 301–317). NASA. <https://ntrs.nasa.gov/citations/19740022614>
- Sachs, J. D., Remans, R., Smukler, S. M., Winowiecki, L., Andelman, S. J., Cassman, K. G., Castle, D., DeFries, R., Denning, G., Fanzo, J., Jackson, L. E., Leemans, R., Lehmann, J., Milder, J. C., Naeem, S., Nziguheba, G., Palm, C. A.,

- Pingali, P. L., Reganold, J. P., ... Sanchez, P. A. (2012). Effective monitoring of agriculture: A response. *Journal of Environmental Monitoring*, 14(3), 738–742. <https://doi.org/10.1039/c2em10584e>
- Santoso, H., Gunawan, T., Jatmiko, R. H., Darmosarkoro, W., & Minasny, B. (2011). Mapping and identifying basal stem rot disease in oil palms in North Sumatra with QuickBird imagery. *Precision Agriculture*, 12(2), 233–248. <https://doi.org/10.1007/s11119-010-9172-7>
- Santoso, H., Tani, H., & Wang, X. (2016). A simple method for detection and counting of oil palm trees using high-resolution multispectral satellite imagery. *International Journal of Remote Sensing*, 37(21), 5122–5134. <https://doi.org/10.1080/01431161.2016.1226527>
- Shafri, H. Z. M., & Hamdan, N. (2009). Hyperspectral imagery for mapping disease infection in oil palm plantation using vegetation indices and red edge techniques. *American Journal of Applied Sciences*, 6(6), 1031–1035. <https://doi.org/10.3844/ajassp.2009.1031.1035>
- 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>
- Sripada, R. P., Heiniger, R. W., White, J. G., & Meijer, A. D. (2006). Aerial color infrared photography for determining early in-season nitrogen requirements in corn. *Agronomy Journal*, 98(4), 968–977. <https://doi.org/10.2134/agronj2005.0200>
- Tao, H., Feng, H., Xu, L., Miao, M., Long, H., Yue, J., Li, Z., Yang, G., Yang, X., & Fan, L. (2020). Estimation of crop growth parameters using UAV- based hyperspectral remote sensing data. *Sensors*, 20(5), Article 1296. <https://doi.org/10.3390/s20051296>
- Thenkabail, P., Lyon, J., & Huete, A. (2011). Advances in hyperspectral remote sensing of vegetation and agricultural croplands. In P. Thenkabail, J. Lyon, & A. Huete (Eds.), *Hyperspectral remote sensing of vegetation* (pp. 3–36). CRC Press.
- Ustin, S. L., Roberts, D. A., Gamon, J. A., Asner, G. P., & Green, R. O. (2004). Using imaging spectroscopy to study ecosystem processes and properties. *BioScience*, 54(6), 523–534. [https://doi.org/10.1641/0006-3568\(2004\)054\[0523:UISTSE\]2.0.CO;2](https://doi.org/10.1641/0006-3568(2004)054[0523:UISTSE]2.0.CO;2)
- Van de Lande, H. L., & Zadoks, J. C. (1999). Spatial patterns of spear rot in oil palm plantations in Surinam. *Plant Pathology*, 48(2), 189–201. <https://doi.org/10.1046/j.1365-3059.1999.00331.x>
- Viera-Torres, M., Sinde-González, I., Gil-Docampo, M., Bravo-Yandún, V., & Toulkeridis, T. (2020). Generating the baseline in the early detection of bud rot and red ring disease in oil palms by geospatial technologies. *Remote Sensing*, 12(19), Article 3229. <https://doi.org/10.3390/rs12193229>
- 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>
- Zhang, J., Huang, Y., Pu, R., Gonzalez-Moreno, P., Yuan, L., Wu, K., & Huang, W. (2019). Monitoring plant diseases and pests through remote sensing technology: A review. *Computers and Electronics in Agriculture*, 165, Article 104943. <https://doi.org/10.1016/j.compag.2019.104943>
- Zhao, H., Yang, C., Guo, W., Zhang, L., & Zhang, D. (2020). Automatic estimation of crop disease severity levels based on vegetation index normalization. *Remote Sensing*, 12(12), Article 1930. <https://doi.org/10.3390/rs12121930>