

Aplicación de técnicas geomáticas para la detección de patologías y estimación de biomasa en cultivos mediante UAV

Application of geomatic techniques for pathology detection and biomass estimation in crops using UAVs

Izar Sinde-González¹

Recibido 11 de noviembre de 2024; aceptado 19 de mayo de 2025

RESUMEN

Actualmente, la utilización de Vehículos Aéreos No Tripulados (UAV) para fines agrícolas se encuentra generalizada en todo el planeta. Entre sus aplicaciones más destacadas se encuentran la generación de cartografía, la vigilancia de bosques o la gestión de cultivos mediante agricultura de precisión. En este estudio se pretende poner de manifiesto la utilidad de las metodologías de análisis de cultivos mediante UAV, de forma que sirvan como apoyo a la toma de decisiones en el sector agrícola. Estas metodologías comprenden temáticas relacionadas con el análisis de crecimiento en cuanto a generación de biomasa en cultivos de raygrass y kikuyo, análisis del estado de salud de plantaciones de lupino en la zona andina mediante su respuesta espectral y la detección de enfermedades en palma africana mediante el estudio de la variabilidad de su respuesta espectral, todas ellas aplicadas en la República de Ecuador. Para la casuística de todos los cultivos mencionados se emplearon equipos como los UAV y los espectrorradiómetros generando productos geoespaciales de alta resolución a través de técnicas de fotogrametría SfM y teledetección de baja altura. Con estos productos se pudieron extraer valores espectrales a nivel de planta e inferir resultados satisfactorios a través de la aplicación de pruebas estadísticas. Es así, que se pudo detectar de forma temprana la afectación de Pudrición de Cogollo (PC) en palma africana, determinar qué tratamiento

¹ Departamento de Ingeniería Topográfica y Cartográfica, E.T.S.I. en Topografía, Geodesia y Cartografía, Universidad Politécnica de Madrid, España, correo electrónico: i.sinde@upm.es.
ORCID: <https://orcid.org/0000-0001-8540-7974>

de desinfección de semilla para lupino es el más adecuado en el control de la antracnosis y evidenciar que el cultivo de ryegrass perenne es el que genera mejores rendimientos en la producción de biomasa para suelos que se encuentran en la zona andina ecuatorial. Con todo esto se puso de manifiesto el potencial de los sistemas UAV a la hora de estudiar y gestionar cultivos de gran importancia económica.

Palabras clave: *agricultura de precisión, UAV, análisis multiespectral, biomasa, fotogrametría SfM.*

RESUMEN

Nowadays, the use of Unmanned Aerial Vehicles (UAV) or drones is a reality. Among their most notable applications are the generation of cartography, forest surveillance, and crop management through precision agriculture. This doctoral thesis investigates the methodologies currently employed in precision agriculture within the field of remote sensing using UAVs to assist rural development processes in developing areas. These methodologies encompass topics related to growth analysis in terms of biomass generation in ryegrass and kikuyu crops, health status analysis of lupine plantations in the Andean region through their spectral response, and disease detection in African palm through the study of the variability of its spectral response, all applied in the Republic of Ecuador. For the case studies of all the mentioned crops, equipment such as UAVs and spectroradiometers were used, generating high-resolution geospatial products through SfM photogrammetry and low-altitude remote sensing techniques. From these products, spectral values at the plant level were extracted and satisfactory results were inferred through the application of statistical tests. Thus, it was possible to detect early the impact of Bud Rot (PC) in African palm, determine which seed disinfection treatment for lupine is the most suitable for controlling Anthracnose, and show that perennial ryegrass is the crop that generates the best biomass yields for soils in the equatorial Andean region. This demonstrated the potential of UAV systems in studying and managing key crops in the economies of developing countries.

Key words: *Precision agriculture, UAV, multispectral analysis, biomass, SfM photogrammetry.*

1. Introducción

La agricultura de precisión consiste en la aplicación de las tecnologías geoespaciales como los sistemas de información geográfica (SIG), la teledetección, los sistemas de posicionamiento por satélite (GNSS) y otros sensores similares, de forma que permitan la detección de variaciones en un cultivo con el objetivo de optimizar las aplicaciones de fertilizantes o pesticidas permitiendo minimizar el impacto sobre el medio ambiente y reducir la cantidad de producto aplicado (Ferrández-Pastor *et al.*, 2018; Zhang & Kovacs, 2012). Cabe mencionar que el

rendimiento del cultivo no solo está influenciado por las variaciones espaciales de las propiedades del suelo, sino también por la susceptibilidad a ciertas patologías presentes en el ciclo vegetativo de cada cultivo (Di Gennaro *et al.*, 2016; Mahlein, 2016; Dash *et al.*, 2017).

En la literatura científica, se pueden encontrar casos de éxito en la aplicación de imágenes satelitales de alta resolución para estudiar variaciones en el cultivo y las condiciones del suelo (Metternicht, 2003; Siart *et al.*, 2009), sin embargo, la resolución, disponibilidad y costos de las imágenes de satélite pueden ser un obstáculo en el uso de esta alternativa de análisis. Para sobrellevar estos problemas, algunos autores han aplicado imágenes tomadas a baja altitud mediante vehículos aéreos no tripulados UAV (*Unmanned Aerial Vehicle*), también denominados drones (Everaerts, 2008; Rango *et al.*, 2009 y Swain *et al.*, 2010).

Como resultado de la aplicación de estas tecnologías se obtienen productos confiables y precisos, útiles para los técnicos agrícolas, cuya labor depende directamente del desarrollo de las tecnologías UAV y de la estandarización y la implementación de procesos de georreferenciación de imágenes y creación de ortomosaicos (Colomina & Molina, 2014). Además, una de las principales consideraciones a tener en cuenta para aplicar un estudio de agricultura de precisión, es involucrar a los técnicos agropecuarios, cuya visión y conocimiento son fundamentales para el diseño muestral en campo, adquisición, interpretación y análisis de las imágenes (Zhang & Kovacs, 2012).

1.1 Fotogrametría y teledetección en la agricultura

En la última década, se ha presenciado la fusión de la fotogrametría digital convencional con algoritmos de visión por ordenador, como por ejemplo, el algoritmo de transformación de elementos sin variación de escala (SIFT) (Lowe, 2004), el de estructura a partir de movimiento (SfM) (Westoby *et al.*, 2012) y el de estereopsis basado en vistas múltiples (MVS) (Furukawa & Ponce, 2007), etc., que han mejorado ampliamente el enlace de procesos y que han hecho que la forma en la que se toma las fotografías sea mucho más flexible. Esta técnica es la comúnmente denominada fotogrametría "SfM" o en inglés *Structure from Motion*. La principal ventaja de la fotogrametría SfM sobre la fotogrametría digital convencional es que permite generar modelos fotogramétricos a partir de imágenes RGB sin un nivel muy riguroso de homogeneidad en sus traslajos, ubicación de sus centros de exposición o sus calibraciones (Fonstad *et al.*, 2013). En contraste con el flujo de trabajo de la fotogrametría convencional, con la fotogrametría SfM se puede resolver simultáneamente la posición de los centros de exposición y la geometría de la escena. Es posible emplear un ajuste de conjunto altamente redundante, fundamentado en la vinculación geométrica de elementos comunes identificados en imágenes con solape. Se puede utilizar un ajuste de conjunto muy redundante basado en el enlace de elementos geométricos de imágenes traslapadas (Westoby *et al.*, 2012). Seguidamente, se implementa el enlace denso entre elementos de imágenes traslapadas con un algoritmo MVS, que permite procesar y generar una nube de puntos densa a partir de las imágenes orientadas y por tanto permite obtener una geometría

3D. La principal ventaja de este tipo de procesamiento es su habilidad para obtener resultados con calidad fotorrealista, con una exactitud posicional buena y un alto grado de automatización (Frankl *et al.*, 2015; Micheletti *et al.*, 2015).

Como se mencionó anteriormente, el flujo de trabajo de la fotogrametría SfM puede en última instancia estimar una nube densa de puntos 3D, muy similar a la producida por la tecnología LiDAR, y a partir de esta se pueden generar otros productos como el modelo digital de superficies, la ortofotografía y con una adecuada depuración de puntos, el modelo digital de elevaciones y las curvas de nivel del terreno. Por ejemplo, a partir de la nube de puntos 3D, se pueden obtener el modelo digital de elevaciones (MDE) y el modelo digital del cultivo (MDC) y calcular alturas de cultivos y diferencias de volúmenes entre ambos (Belton *et al.*, 2019; Calou *et al.*, 2019; d'Oleire-Oltmanns *et al.*, 2012).

Las técnicas de fotogrametría aérea han sido recientemente utilizadas para el acopio de información sobre cultivos para mejorar la caracterización y el manejo de zonas con ecosistemas con un alto interés en investigación (Cuchopadín *et al.*, 2020; Meneses *et al.*, 2015; Mukherjee *et al.*, 2019). Este tipo de estudios han permitido la caracterización de áreas con vegetación densa y campos de cultivos permitiendo un manejo eficiente de la información de forma que se pueden mejorar los procesos de conservación y desarrollo de estas áreas (Acevo-Herrera *et al.*, 2010; Guo *et al.*, 2012; Maresma *et al.*, 2016).

Los datos multiespectrales e hiperespectrales obtenidos desde plataformas aéreas no tripuladas pueden reemplazar a las técnicas actuales. Las bandas del visible, del infrarrojo cercano (NIR) y del infrarrojo medio (SWIR) han generado una nueva perspectiva en este tópico (Jenal *et al.*, 2020; Hart *et al.*, 2020). Mediante la construcción de modelos de regresión entre medidas de campo e índices de vegetación (p. ej., NDVI o EVI), se ha podido en algunas ocasiones cuantificar la biomasa aérea en pastos (Stroppiana *et al.*, 2015; Selsam *et al.*, 2017). Otra de las aplicaciones actuales más novedosas en esta temática son los algoritmos de aprendizaje profundo o *deep learning*, que hallaron grandes resultados, mejorando la construcción de modelos y la interpretación de resultados en la estimación de biomasa a partir de datos multiespectrales (Castro *et al.*, 2020; Viljanen *et al.*, 2018; Näsi *et al.*, 2018; Grüner *et al.*, 2020).

Entre los diferentes campos de aplicación de la fotogrametría SfM-MVS desde UAV para la agricultura de precisión, la estimación de la biomasa aérea es probablemente uno de los más explorados, ya que está directamente relacionada con la producción primaria neta. Entre los ejemplos de esto se incluyen los realizados en cultivos como la cebada (Bendig *et al.*, 2014), en avena negra (Acorsi *et al.*, 2019), en maíz, (Zhu *et al.*, 2019) o en cebolla (Ballesteros *et al.*, 2018). A pesar de que estos estudios obtuvieron información continua, completa y multitemporal a nivel de parcela, ninguno de los métodos propuestos puede eliminar completamente la necesidad de utilizar métodos destructivos para el muestreo. Por otro lado, un pequeño número de estudios han trabajado específicamente en la estimación de la biomasa en pasto con fotogrametría (Batistoti *et al.*, 2019; Grüner *et al.*, 2019; Lussem *et al.*, 2020; Michez *et al.*, 2019) utilizando la correlación entre la altura del cultivo obtenida con el MDE y el MDC

y la toma de muestras en campo. La mayoría de los resultados mostraron que la altura del cultivo es un estimador muy robusto de la biomasa aérea, y la alta resolución espacial de los conjuntos de datos MDE y MDC ayudó mucho a la correcta estimación de la biomasa (Zhu *et al.*, 2019). Gil-Docampo *et al.* (2020) propuso la utilización del factor de densidad (FD) como un método simplificado de enlazar los datos de campo con los datos de volumen que se obtienen de restar el MDC del MDE. Este método relaciona el peso de la muestra de campo con el volumen de vegetación en cada punto de muestreo, de esta forma se proporciona una relación empírica entre los volúmenes de vegetación de cada parcela con la biomasa aérea total.

Existen diversos estudios en los que se pretende dar seguimiento al desarrollo de la palma, como es el caso de Zheng *et al.* (2021) o Tugi *et al.* (2015), en los que a través de UAV logran monitorear el crecimiento de la palma de aceite. Aunque ambos acercamientos logran, con cierto éxito, su cometido, el primero emplea simplemente imágenes en RGB y el segundo utiliza imágenes en Infrarrojo cercano con las que calcula índices de vegetación. En este sentido, la detección automática y conteo de palma con algoritmos de machine learning es un tópico habitual dentro de la literatura científica. Un ejemplo de esto es el estudio de Xia *et al.* (2019) que logra realizar la detección de palmas en una imagen de 500 x 500 píxeles, en un tiempo de 12.81 ms con un índice de acierto del 90.91%. Por otro lado, Liu *et al.* (2020), logró la detección de plantas de palma africana con una eficacia de entorno al 97%, pero con técnicas de *Deep Learning*.

1.2 Definición del problema abordado

El sector agrícola tiene una gran influencia en la economía de Ecuador, pero el nivel educativo y la tecnificación de las labores agrícolas son todavía retos importantes a la hora de maximizar la productividad. En este estudio se han considerado tres cultivos insignia del agro ecuatoriano, el pasto en cuanto a producción de biomasa, el lupino o “chocho” andino y la palma africana.

Hasta hace poco, la mayor parte de los métodos de estimación de biomasa aérea a nivel local se basaban en métodos de muestreo destructivo (Catchpole & Wheeler, 2010) o simplemente en estimaciones visuales (Waite, 1994). Sin embargo, las nuevas tecnologías basadas en todo tipo de sensores (RGB, multiespectrales, Lidar y Radar) y la aparición de nuevas plataformas que permiten integrar estos sensores, están actualmente ganando mucha popularidad. El bajo rendimiento y alto costo que generalmente requieren los métodos terrestres hace que los vehículos aéreos no tripulados o drones (UAV), se postulen como una alternativa muy apta para este propósito (Acorsi *et al.*, 2019; Niu *et al.*, 2019; Michez *et al.*, 2020).

Por otro lado, el lupino es un cultivo susceptible a la antracnosis, una patología generada por un hongo denominado *colletotrichum acutatum* (Falconí *et al.*, 2013). Este patógeno ataca la zona apical de la planta, haciendo que la planta sea incapaz de producir el grano de forma correcta, de forma que genera pérdidas significativas en la cosecha final (Guaytarrilla & Falconí, 2014). Considerando que no existen variedades de lupino andino con resistencia a la antracnosis

(Falconí, 2012), se vuelve indispensable la implementación de métodos alternativos que permitan eliminar o al menos reducir y prevenir la transmisión del hongo a las semillas (Falconí & Yáñez-Mendizábal, 2019). En este contexto, es necesario implementar métodos fitosanitarios que mejoren el manejo de las patologías y que, con el apoyo y la aceptación de las comunidades rurales, permitan la erradicación de la antracnosis del lupino andino la agricultura local de las comunidades rurales. Un método de para evaluar la efectividad de estos tratamientos se erige en el análisis espectral. A pesar de que existen estudios que analizan la reflectancia del lupino (Mogensen *et al.*, 1996), en Ecuador y a lo largo de la zona andina, los mencionados estudios son escasos y por tanto las bondades de la espectroradiometría no han sido estudiadas o estos estudios todavía se hayan en fases iniciales. Además, las librerías espectrales oficiales no contienen registros del lupino andino (Kokaly *et al.*, 2017), e incluso en Alemania (Wijesingha *et al.*, 2020), el lupino es considerado una hierba invasiva y se estudia en este sentido.

Por último, en cuanto a la palma africana, se puede mencionar que una de las principales enfermedades que asolan a los cultivos de palma africana en el continente americano es la denominada pudrición de cogollo (PC) o *bud rot* en inglés. Para Ecuador, es sin duda actualmente, desde un punto de vista económico, el patógeno que genera un mayor número de pérdidas en el cultivo de palma africana. Según el censo palmero nacional realizado en el año 2017, la presencia de la PC había afectado a un total de 148.433,8 ha, lo que representaba el 57,7% de todas las plantaciones de palma africana del país. Estos datos de afectación se pueden materializar en la pérdida de 50.000 empleos directos e indirectos, 200 millones de dólares en pérdidas por daños a plantas maduras que producían fruta en buen estado y 600 millones de dólares en inversiones (ANCUPA, 2019). La detección de patologías en plantas en general y en palma africana en particular es un tópico que actualmente se encuentra en desarrollo, pero para el que todavía no se logran encontrar resultados del todo satisfactorios. Esto es debido a la cantidad de variables que entran en juego en el desarrollo de un cultivo y a la variabilidad de las condiciones climatológicas que se pueden dar a lo largo de un estudio multitemporal, por ejemplo, una patología en muchas ocasiones se puede confundir con otros problemas como la deficiencia de nutrientes o el estrés hídrico. La existencia de estudios referentes a la detección de enfermedades en palma africana mediante cámaras multispectrales a bordo de UAV es escasa a pesar de los grandes avances de la tecnología actual. Los que existen se centran en la detección de la afectación por el hongo ganoderma, algunos a través de índices espectrales de la región del visible tal y como muestra Wiratmoko *et al.* (2020) y otros basados en otras bandas del espectro como el Red Edge o el NIR (Izzuddin *et al.*, 2020). La detección temprana de la enfermedad permite al agricultor implementar medidas oportunas para mitigar la afectación en toda su plantación.

Con la finalidad de demostrar la viabilidad del uso y las potencialidades de las técnicas UAV en el análisis de cultivos que permitan resolver problemáticas del campo agrícola, se plantean en el presente estudio los siguientes objetivos

principales: monitorear el crecimiento y la generación de biomasa en cultivos de pasto (*Lolium perenne*, *Lolium multiflorum* y *Pennisetum clandestinum*) mediante fotogrametría de objeto cercano con imágenes captadas desde UAV; evaluar el desarrollo del lupino, *Lupinus Mutabilis Sweet*, mediante la obtención de firmas espectrales e imágenes multiespectrales con sensores de bajo costo portados por UAV que permitan caracterizar los efectos de la desinfección de las semillas en el desarrollo de la planta; y la detección de forma temprana de enfermedades críticas en el cultivo de palma africana, *Elaeis guineensis*, mediante el análisis de la variabilidad espectral encontrada en índices de vegetación generados a partir de imágenes obtenidas con sensores multiespectrales a bordo de UAV de bajo costo.

2. Metodología

2.1 Materiales

El desarrollo de los estudios se realizó con equipos UAV comerciales de costo relativamente bajo, estos equipos fueron el DJI Phantom 4, DJI Mavic Pro 1 y DJI Matrice 100. Se utilizaron las cámaras RGB propias de cada dron y cámaras RGB modificadas, (RGNIR y BGNIR), para el estudio multiespectral. En el caso del estudio del lupino, también se utilizó un espectrorradiómetro de mano. El compendio de *software* utilizado va desde Pix4D, QGIS, Agisoft Photoscan Profesional, ENVI 5.5, Trimble Business Center, RS3 y Mapir Camera control.

2.2 Áreas de estudio

Dos de las áreas de estudio se ubican en Instituto Agropecuario Superior Andino IASA (Lupino y pasto), Ecuador, perteneciente a la Universidad de las Fuerzas Armadas ESPE y ubicadas a una altitud aproximada de 2722 msnm, una temperatura media anual de 13.89 °C, precipitación acumulada de 1285 mm y humedad relativa de 69.03% (0° 23' 20"S, 78° 24'51"W). Por otro lado, el estudio sobre palma se realizó en un sector de la costa ecuatoriana, con una altitud aproximada de 400 msnm, una temperatura media anual de 24.5 °C, humedad relativa cercana al 90% y una precipitación acumulada de 728.8 mm (0.0421° N y 79.41329° W).

2.3 Toma de datos

Para la estimación de biomasa en pasto, se subdividió una parcela de 8210 m² en 72 subparcelas, de las cuales finalmente se utilizaron 54. Estas parcelas contaron con un tamaño aproximado de 40m². Se realizó la siembra de ryegrass perenne (*Lolium perenne*) (RP), ryegrass anual (*Lolium multiflorum*) (RA) y kikuyo (*Pennisetum clandestinum*) (Kk), aplicando en el 50% de las parcelas un tratamiento fertilizante compuesto de 10-30-10 de N – P – K con una distribución de los tratamientos completamente al azar.

Se realizaron vuelos con el UAV un día antes de la siembra y a los 3 meses, fecha del primer corte del pasto. La altura de vuelo fueron 70 m. con traslapo

70/80, consiguiendo un GSD de 3.06 cm. Anterior al vuelo se posicionaron 8 puntos de control terrestre (GCP), con tecnología GNSS, para georreferenciar los productos del UAV.

El mismo día del segundo vuelo, se realizó un muestreo aleatorio en campo teniendo en cuenta que todo el material orgánico recolectado estaba dentro de la superficie de las parcelas. Para cada parcela, la muestra fue tomada siguiendo la metodología de Bending *et al.* (2014). Esta metodología consiste en utilizar un anillo de metal de 0.25 m² que define los límites de la muestra y georreferenciar para cada caso el punto que se muestrea. Las muestras se llevaron al laboratorio, donde inicialmente fueron pesadas en húmedo y seguidamente en seco, después de haber sido secadas en un horno durante 24 horas. Se tomó una muestra de pasto en cada una de las 54 parcelas, de forma aleatoria dentro de ellas, y se reservaron 10 muestras para verificar los resultados.

Para el estudio del lupino se realizó una parcelación que permitiera contener un total de seis tratamientos con tres repeticiones cada uno. Se empleó una parcela de 200 m², con parcelas de 8 m². El detalle de los tratamientos de las semillas puede visualizarse en la Tabla 1.

Tabla 1. Descripción de los tratamientos

<i>Tratamiento</i>	<i>Tiempo (min.)</i>	<i>Descripción</i>	<i>Nomenclatura</i>
T1	30	Horno solar	30min_horno
T2	45	Horno solar	45min_horno
T3	30	Ambiente	30min_amb
T4	45	Ambiente	45min_amb
T5	0	Control	Control
T6	Vitavax	Sin exposición	Carboxin + Thiram, 2g/kg por semilla

Los pretratamientos de desinfección de semilla se aplicaron en el entorno de las semillas con radiación UV-B más temperatura ambiente (UV-B 3.6 o 5.4 kJ m⁻² ≈ 21°C) y radiación UV-B en un horno solar más temperatura ambiente (UV-B 1.8 o 2.7 kJ m⁻² ≈ 76°C) durante 30 y 45 minutos, respectivamente, como se detalla en Falconí & Yáñez-Mendizábal (2019) y desinfección química con Vitavax (Carboxin + Thiram, 2g/kg por semilla) (Falconí & Yáñez-Mendizábal 2019). Una vez, sembradas las 18 parcelas se tomaron datos con un espectrorradiómetro de mano en cada uno de los estados fenológicos del cultivo (cotiledonar, desarrollo vegetativo 1 y 2, floración, reproducción y cosecha).

Se utilizó el método de medición radiométrico pasivo, de forma que el cabezal del equipo no estaba en contacto con la planta y utilizó la radiación electromagnética proveniente del sol para la generación de las firmas espectrales. El campo de visión del equipo fue de 8°, lo que permitía la toma de datos sobre la hoja a una distancia de 1.4 cm. En este contexto, un total de 10 mediciones fueron realizadas en cada planta y se pudo estimar que el escenario

de escaneo fue similar a la resolución de las imágenes del UAV (1.15 cm). Cabe recalcar, que cada muestra tomada fue georreferenciada con el método de posicionamiento RTK.

Además de las mediciones con espectrorradiómetro, se realizaron vuelos fotogramétricos con UAV y cámara multispectral RGB modificada, modelo Mapiir 3W (RG NIR). Se utilizaron 4 GCPs, medidos con GNSS de precisión, para georreferenciar el ortomosaico generado a partir del *software* SfM. El vuelo se realizó a 30 m de altura, con traslapeo 70/80, garantizando un tamaño de píxel en el terreno (GSD) de 1 cm.

Para el estudio de la pudrición de cogollo (PC) en palma, se seleccionaron dos lotes con plantaciones de palma africana, uno de ellos sin afectación detectada de PC (52 ha), Lote CIPAL y otro con un avance de aproximadamente el 30% de la enfermedad (40 ha), Lote Arteaga.

El primero contaba con 6 variedades de palma africana, dos de ellas con una antigüedad de 15 años (INIAP, CIRAD y ASD) y en pleno pico de rendimiento de producción y otras 3 variedades de carácter híbrido Oleífera x guineensis (OxG) con dos años de antigüedad (Taisha, Unipalma y Amazon) a punto de comenzar a producir (véase Figura 1). En el caso del segundo contaba tan solo con palmas de 15 años de antigüedad de variedad INIAP.

La toma de datos consistió en realizar vuelos en épocas diferentes para cada lote, con cámaras RGB modificadas.




Figura 1. Distribución de variedades del Lote CIPAL.

En el lote CIPAL, se realizaron dos vuelos, con una diferencia de tres meses, con dos sensores diferentes (BRNIR y RGNIR). Los vuelos fueron realizados a 120 m de altura, con traslapo 70/80 generando un GSD de 5 cm.

En el lote Arteaga, se realizaron tres vuelos con cámara RGNIR y una diferencia de entre mes y medio y dos meses entre ellos. Los vuelos fueron realizados con los mismos parámetros en ambos lotes. Para poder comparar entre épocas, se realizó una georreferenciación de las dos últimas épocas, respecto a la inicial, tomando puntos en común entre las imágenes. Las imágenes fueron procesadas en *software* SfM para obtener los ortomosaicos de las diferentes épocas y se realizó la corrección atmosférica con el algoritmo QUAC® de ENVI.

Finalmente se georreferenciaron con un GPS navegador los datos de las palmas con diferentes grados de afectación. Esta toma se realizó con la ayuda de expertos en la detección de patologías en palma africana.

2.4 Obtención de datos

Para el estudio en pasto, se calculó El factor de densidad (FD) definido por Gil-Docampo *et al.* (2020) es una constante que se deriva de la cantidad de biomasa por unidad de volumen, que permite corregir las variaciones de volumen (suponiendo que se obtiene un mayor volumen si la capa de vegetación es alta y densa, y se obtiene un menor volumen si la capa de vegetación es baja y con calvas) y calcular biomasa en extensiones más grandes.

El FD para cada punto de muestreo se calcula como se muestra en la Ecuación 1.

$$FD = \frac{B_S}{V_S} \quad (1)$$

Donde:

FD: Factor de Densidad [kg · m⁻³]

BS: Biomasa en el punto de muestreo de 0.25 m² [kg]

VS: Volumen (determinado por la diferencia entre el MDT y el MDC) con el cultivo crecido [m³]

La biomasa aérea fue calculada con base en la diferencia de volumen por parcela que se obtuvo de los MDT Y MDC generados con el UAV y del FD calculada en cada parcela. Extrayendo el ráster de cada parcela en cada uno de los modelos, se pudo calcular el volumen total, parcela a parcela. De este modo, cada parcela obtuvo su volumen correspondiente, con el que se pudo calcular la biomasa total a través de la Ecuación 2.

$$B_p = FD \cdot V_p \quad (2)$$

Donde:

BP: Biomasa de cada parcela [kg]

FD: Factor de Densidad [kg · m⁻³]

VP: Volumen (determinado por la diferencia entre el MDT y MDC) con el cultivo crecido [m³] en cada parcela

El FD permite la corrección de la correlación entre el peso y la biomasa de acuerdo con el volumen que se extrae de las imágenes del UAV.

Para el proceso de validación del procedimiento, primero se comprobó el acople entre el MDT y el MDC. Esto se hizo a través de la selección de 30 puntos aleatorios, homólogos entre los dos modelos, en zonas de suelo desnudo y se obtuvo el error medio cuadrático para asegurar que se hizo un buen ajuste entre épocas.

Seguidamente, se validó la estimación de la biomasa aérea a través de 10 muestras aleatorias en campo, reservadas para este fin. Se obtuvo la biomasa de estas muestras destinadas a validación, la diferencia entre el MDT Y MDC en estas muestras georreferenciadas y con la Ecuación 2 se pudo obtener la biomasa estimada. Finalmente se aplicó un análisis de correlación a través del coeficiente de correlación de Pearson y estadísticas descriptivas entre los valores medidos y los valores estimados.

Para determinar si el método de estimación de biomasa expuesto en este estudio pudo diferenciar entre tipos de cultivo o entre tratamientos, se aplicó un análisis de varianza ANOVA con test de Fisher a los datos de biomasa obtenidos en cada una de las unidades experimentales. Cabe mencionar que se realizaron pruebas de normalidad y homocedasticidad a los datos para determinar si era factible la aplicación del método paramétrico ANOVA. En la Figura 2 se puede ver un resumen gráfico de la metodología.

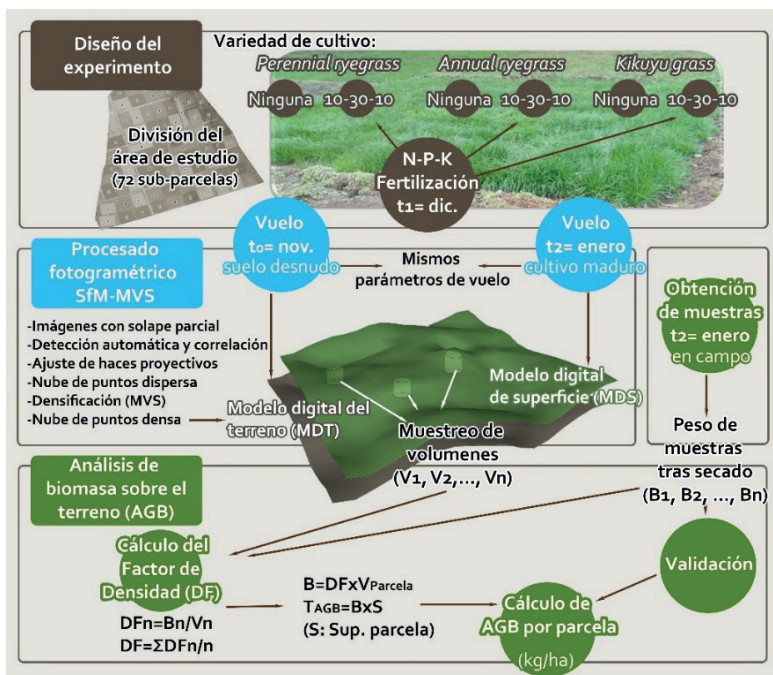


Figura 2. Diagrama de flujo para la estimación de biomasa en pasto.

En cuanto al estudio de lupino, se calcularon los índices de vegetación NDVI, TNDVI, SR-RE y NDRE para cada medición de cada planta. Los resultados obtenidos superaron un proceso de validación estadística mediante el uso de diagramas de cajas y bigotes, con el que se pudieron descartar valores atípicos. Los valores de longitud de onda tomados para el cálculo de estos índices se corresponden a los canales de la cámara multispectral Parrot Sequoia 550 nm, 660nm, 735 nm, y 790 nm para el azul, verde, rojo e infrarrojo cercano respectivamente.

Seguidamente también se calculó el NDVI para los ortomosaicos generados desde el vuelo del UAV. Se realizó su calibración radiométrica a través de la diana de calibración proporcionada por el fabricante y se extrajeron en el *software* SIG los valores de NDVI presentes en cada planta muestreada anteriormente. Esto para cada estado fenológico de la planta.

Para finalizar se realizó el análisis bioestadístico de los datos para determinar si la tecnología de análisis espectral fue capaz de diferenciar que tratamiento fue mejor.

En la Figura 3 se puede ver un resumen gráfico de la metodología.




Figura 3. Diagrama de flujo para el análisis espectral del lupino.

Para el estudio en palma africana, una vez obtenidos los ortomosaicos calibrados atmosféricamente, se calcularon los índices de vegetación NDVI, GNDVI, GVI y VARI. Se realizó además un conteo automático de las plantas con el módulo “Crop science from ENVI”, que permitió obtener una capa vectorial de polígonos, que representan toda la superficie de la planta. Con esta capa, se aplicó una operación de media zonal, para obtener el promedio de los valores de los píxeles de cada planta para cada índice. A estos valores se les aplicó una prueba estadística ANOVA con test LSD de Fisher, para determinar si existían diferencias significativas entre variedades. Este proceso se repitió para el Lote Arteaga, pero en ese caso, las variables que define las clases son los diferentes grados de afectación de la planta.

Finalmente se realizó un estudio multitemporal comparando el valor de los histogramas de los índices y se implementó una validación estadística de los resultados. En la Figura 4 se esquematiza la metodología implementada.

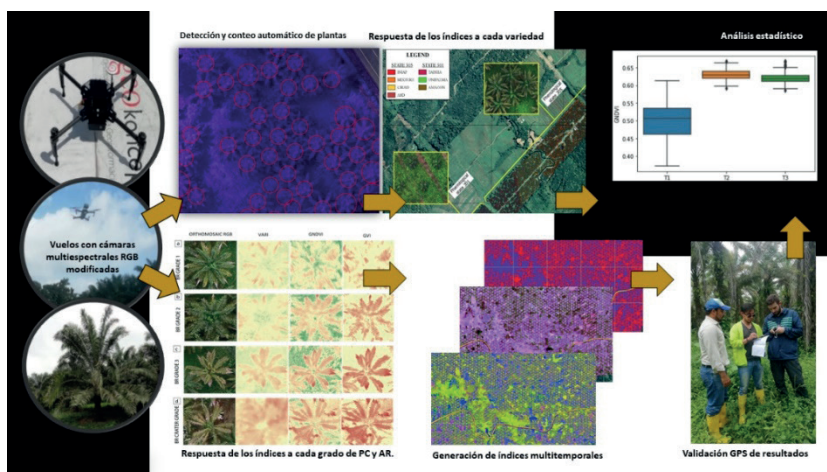


Figura 4. Diagrama de flujo para la detección temprana de la pudrición de cogollo en palma africana.

3. Resultados y discusión

Para el estudio del lupino, se obtuvieron un total de 4232 valores de índice de vegetación con el espectrorradiómetro, y 1058 obtenidos a partir de los productos que ofrece el UAV. El análisis de valores atípicos permitió excluir un total de 119 valores debidos a errores en la medición.

Se extrajeron los valores de NDVI de los ortomosaicos a partir del posicionamiento RTK y se aplicó una prueba ANOVA, tanto a los datos del espectrorradiómetro como a los del UAV.

Se pudo detectar que, para los datos del espectrorradiómetro, existen diferencias significativas con los índices NDVI y TNDVI entre los tratamientos,

destacando que la desinfección con 45 minutos en horno es fue la que tuvo un menor valor, respecto al resto de tratamientos. El tratamiento que tuvo un mejor rendimiento fue la desinfección 45 minutos al ambiente, aunque tras aplicar la prueba de Fisher, no se puede distinguir correctamente de la planta control.

Estos datos fueron corroborados con el índice NDVI del UAV, indicó que el tratamiento térmico de 45 minutos al horno presentó diferencias estadísticamente significativas, siendo inferior al resto de los tratamientos.

Al analizar los estados fenológicos, los índices de vegetación basados en la banda del Infrarrojo Cercano (NDVI y TNDVI), tuvieron un incremento lógico a medida que pasan los estados fenológicos del cultivo, excepto en la etapa de floración que sufre un decrecimiento. Los índices basados en la banda del borde rojo fueron más eficientes para diferenciar entre estados fenológicos, excepto entre las etapas de floración y reproductivo. Sin embargo, los índices basados en el Infrarrojo Cercano, fueron más eficientes para detectar el estrés de la planta generado por patógenos en el estado de floración. El NDVI obtenido con el UAV no fue capaz de distinguir el decrecimiento del valor en la etapa de floración, pero podría ser útil para diferenciar estados fenológicos iniciales de la planta.

En consecuencia, se pudo demostrar que las técnicas multispectrales aplicadas desde plataformas UAV constituyen una fuente de información valiosa para el análisis del desarrollo fenológico de los cultivos, así como para la detección temprana de anomalías en su crecimiento. Asimismo, estas herramientas permiten identificar diferencias significativas derivadas de la aplicación de distintos tratamientos agronómicos, lo que refuerza su utilidad en la toma de decisiones para la gestión de cultivos.

En cuanto al estudio del pasto se obtuvo que el ryegrass perenne, ryegrass anual y el kikuyo, generaron una biomasa seca total de 1471 kg/Ha, 2121 kg/ha y 1666 kg/ha respectivamente, y sus homónimas, pero con fertilización 1483 kg/ha, 2632 kg/ha y 1244 kg/ha. Los parámetros promedios en la producción de biomasa se muestran en la Tabla 2.

Tabla 2. Resumen de los promedios de la producción de biomasa

<i>Tipo de cultivo</i>	<i>Fert.</i>	<i>N° de parcelas</i>	<i>Volumen promedio (m³)/parcela</i>	<i>FD promedio (g/m³)</i>	<i>Biomasa promedio (kg)/parcela</i>	<i>Biomasa promedio (kg/ha)</i>
RP	Sí	11	41.75	328.94	11.30	1483
RP	No	12	44.09	284.78	11.45	1471
Ryegrass anual	Sí	13	48.46	488.66	20.41	2632
Ryegrass anual	No	11	45.91	376.13	16.25	2121
Kikuyo	Sí	2	43.71	225.70	9.53	1244
Kikuyo	No	5	37.7	315.70	11.58	1666

Para validar todos los productos obtenidos se comenzó con la comprobación de diferencias entre el MDE y el MDC, para esto se tomaron un total de 30 puntos en zonas de suelo desnudo, que deberían mostrar la misma altitud sobre el nivel del mar entre los dos modelos. Estos puntos se correspondieron a los pasillos entre los cultivos. El análisis de las diferencias entre las alturas generadas de los dos modelos arrojó un error medio cuadrático en el acople entre modelos menor en todos los casos a 6 cm, lo que confirma la precisión altimétrica alcanzada en los levantamientos realizados con UAV.

Con la metodología propuesta para la validación en la estimación de la biomasa se obtuvo un R^2 de 0.78 entre valores estimados y valores medidos en 10 muestras. Este valor fue similar al de otros estudios que aplican metodologías similares como el de Batistoti *et al.* (2019) y Grüner *et al.* (2019).

Se obtuvo un p-valor menor a 0.05, por tanto, existe alguna diferencia significativa entre tratamientos o variedades. Para distinguir dónde están esas diferencias, se utilizó el test LSD de Fisher, que arrojó las clases diferenciadas (véase Tabla 3).

Tabla 3. Resumen del Test de Fisher para producción de biomasa de las parcelas

<i>Variedad</i>	<i>Promedio</i>	<i>N</i>	<i>e. e.</i>	<i>Clase</i>
Kk con fertilización	9.53	2	3.23	A
RP sin fertilización	11.30	12	1.32	A
RP con fertilización	11.45	11	1.38	A
Kk sin fertilización	11.69	5	2.04	A
RA sin fertilización	16.25	11	1.38	A
RA con fertilización	20.42	13	1.27	B

*Kikuyo (Kk), RP (Ryegrass Perenne), RA (Ryegrass Anual).

Como se puede evidenciar en la Tabla 3, la fertilización mejoró el desarrollo de los cultivos de ryegrass anual y perenne, que mostraron un incremento en promedio en su biomasa estimada de 16.25 a 20.42 y de 11.30 a 11.45 kg·Ha⁻¹ respectivamente, comparado con las parcelas sin fertilizar. El test de Fisher permitió dilucidar que la biomasa del ryegrass anual con fertilización fue significativamente diferente al de las otras especies y de los otros tratamientos aplicados.

Es muy difícil establecer una comparación de los resultados de este estudio con otros que hayan realizado la estimación de biomasa aérea con UAV y cámaras RGB en ryegrass perenne de la zona Andina, pero existen algunos estudios en zonas con clima oceánico, como el de Borra-Serrano *et al.* (2019) en Bélgica, que obtuvo un R^2 de 0.67 con el mejor estimador de la altura del cultivo de ryegrass perenne, y el de Lussem *et al.* (2020) en Alemania, que obtuvo un R^2 de 0.65 entre las estimaciones de biomasa predichas y observadas. En ambos casos, sus resultados obtuvieron correlaciones inferiores a las de este estudio, lo que demuestra la potencialidad de la metodología propuesta.

La metodología aplicada en el ensayo con pasto representa un avance significativo en la estimación no destructiva de biomasa, evidenciando la viabilidad de realizar estimaciones precisas en cultivos de reducido porte mediante imágenes adquiridas con vehículos aéreos no tripulados (UAV). La progresiva reducción de los costos asociados a estos sistemas UAV refuerza el potencial de esta técnica como una herramienta accesible para los agricultores, facilitando una comprensión más detallada de la dinámica de crecimiento y desarrollo de sus cultivos.

Para el estudio de palma en el lote sano se pudo obtener una línea base con la respuesta espectral de las diferentes variedades de palma y que existen diferencias significativas detectadas con el sensor RGNIR en plantas con mayor tiempo de desarrollo. El BGNIR fue más eficiente en diferenciar variedades ecuatorianas respecto a las costarricenses.

Al igual que en otros estudios como los de Yuan *et al.* (2014), se utilizaron métodos de discriminación avanzados basados en estadística con el objetivo de obtener diferencias significativas entre categorías. Se puede observar que existen diferencias significativas entre especies para los dos sensores, aunque uno de ellos, el RGNIR, obtiene resultados más nítidos que el otro.

En cuanto al lote enfermo, se obtuvieron tres ortomosaicos con separación de dos meses entre tomas. En las tres etapas de medición se pudo evidenciar que el rango que ocuparon los índices de vegetación no era el mismo. A pesar de la corrección atmosférica realizada, los índices GVI y GNDVI siguen afectados por otras condiciones como la humedad del suelo o las condiciones ambientales de ese momento, mientras que el índice VARI, al ser un índice que reduce los efectos de la atmósfera, obtuvo una respuesta espectral más coherente con el comportamiento de la enfermedad.

Los puntos que se rastrearon en campo permitieron determinar que, efectivamente, los focos de afectación de las enfermedades de PC y AR tienen valores bajos con relación al rango manejado dentro de cada índice de vegetación para palma africana sana, lo que revela afectaciones en el vigor de las plantas.

Los resultados obtenidos a la hora de detectar las patologías indicaron que los índices calculados a partir de los sensores RGB y BGNIR utilizados con las cámaras de modelo Zenmuse del UAV Matrice 100, tuvieron la habilidad de diferenciar entre los grados de severidad, coincidiendo con algunos estudios previos donde se demostró la posibilidad de algunos sensores RGB e infrarrojos montados sobre UAV de diferenciar los grados de severidad por afectación de ganoderma (Khosrokhani *et al.*, 2018). Sin embargo, los análisis realizados en este estudio fueron realizados tan solo a nivel de dosel, sin tener en cuenta ningún estudio de los efectos de los suelos del área de estudio. Por lo tanto, se pudo deducir que es posible detectar la enfermedad y sus efectos a través de UAV con suficiente precisión y anticipación. Esto podría permitir desarrollar métodos efectivos de control y mitigación de problemas.

Con el objetivo de validar el análisis multitemporal, se tomaron un total de 47 muestras, que corresponden al número total de puntos de validación que se pudieron registrar en campo debido a las dificultades topográficas y climáticas

que existen en la zona. Estos puntos medidos con GPS se corresponden a zonas en las que, según lo obtenido en los resultados anteriores, existe un decrecimiento alto en el índice de vegetación. Con base en lo anterior, el índice VARI fue el considerado para generar los puntos de muestreo. De todos los puntos analizados, solo dos mostraron otro tipo de afectación que necesitaba ser considerada aparte cuando se analizan los índices de vegetación. La deficiencia de boro detectada en un punto es una de las afecciones que puede generar confusión con la pudrición de cogollo, es por ello que siempre se debe realizar la visita de campo con un experto en el sector palmero. Por tanto, se puede decir que con la metodología aplicada no se encontró ningún tipo de patrón espacial en la distribución de la enfermedad, más bien se puede observar que el avance de la enfermedad tiene una distribución totalmente aleatoria, perfilándose aún como un dilema sin solución, debido al desconocimiento que todavía actualmente existe sobre el vector que genera la enfermedad de la pudrición de cogollo.

Con el índice VARI se pudo evidenciar que cuanto mayor es la afectación sobre la planta mayor es el decrecimiento del índice, esto para todos los monitoreos realizados. Esta tendencia se confirma de cierta manera al aplicar el índice GNDVI.

Se pudo demostrar que es factible la pronta detección de patologías en cultivos de acuerdo con los síntomas que presenten y el análisis del patrón espacial que pudieran seguir a través de estudios multitemporales. En el caso particular de este trabajo, se pudo observar que, en los bordes de los lotes con afectación, existe un mayor número de casos de PC, probablemente por la presencia de la enfermedad en las fincas contiguas. Para el lote CIPAL, se pudieron detectar al final del estudio, algunas plantas que padecían la enfermedad, en concreto cerca de los lotes con palmas híbridas de dos años de edad. Es por ello necesario realizar un estudio en el que se genere una franja de separación de unos 200 m entre cultivos para que los unos no afecten a los otros (Hurtado & Rincón, 2009).

En la Tabla 4 se puede observar el resumen estadístico de las muestras de validación tomadas cada época y en la Tabla 5 se ilustran los valores promedio totales de la respuesta espectral de las palmas del lote enfermo, para cada índice respecto a cada tipo de afectación.

Tabla 4. Resumen estadístico de las muestras de validación

	<i>VARI1</i>	<i>VARI2</i>	<i>VARI3</i>	<i>GNDVI1</i>	<i>GNDVI2</i>	<i>GNDVI3</i>	<i>GVI1</i>	<i>GVI2</i>	<i>GVI3</i>
MEDIA	0.069	0.060	0.097	0.425	0.578	0.462	2.558	3.878	2.556
Desv. EsT.	0.051	0.035	0.075	0.052	0.045	0.054	0.340	0.527	0.626
MÍN. IV	0.001	0.000	0.003	0.305	0.490	0.280	1.920	3.010	1.020
25%	0.025	0.036	0.033	0.394	0.540	0.428	2.345	3.438	2.165
50%	0.060	0.059	0.080	0.432	0.580	0.470	2.510	3.730	2.610
75%	0.108	0.080	0.147	0.458	0.613	0.500	2.778	4.353	3.085
MÁX. IV	0.221	0.157	0.299	0.545	0.660	0.550	3.350	5.030	3.600

Tabla 5. Valores base de índices de vegetación para los diferentes niveles de daño en la planta

<i>Affectation</i>	<i>VARI</i>	<i>GNDVI</i>	<i>GVI</i>
Línea base	0.183	0.667	5.214
Deficiencia de boro	0.094	0.432	2.938
PC grado 1 Y 2	0.091	0.499	3.090
PC grado 3	0.087	0.487	2.997
PC grado cráter	0.041	0.479	3.014
Muerta por PC	0.053	0.488	2.980

En el ensayo realizado en Palma, se demostró que el análisis de la respuesta espectral de *Elaeis guineensis* mediante sensores multispectrales montados en vehículos aéreos no tripulados (UAV) constituye una herramienta eficaz para la detección temprana de patologías. Esta metodología no invasiva ofrece una alternativa eficiente para el monitoreo fitosanitario, con el potencial de optimizar el uso de recursos humanos en labores de vigilancia agrícola.

4. Conclusiones

En el presente estudio se aborda con un enfoque innovador el análisis de cultivos en zonas andinas y de la costa ecuatoriana. Se emplean los vehículos aéreos no tripulados (UAV) con cámaras multispectrales para la detección de enfermedades, estimación de biomasa y monitoreo en cultivos de alta importancia económica para la República de Ecuador.

Se pudo determinar que es factible el empleo de tecnologías geoespaciales con equipos de bajo costo y sus productos de información geográfica, para la caracterización espectral de cultivos, tanto andinos como tropicales, de forma que suponga una fuente de información útil para el manejo más eficiente de cultivos.

La aplicación de índices de vegetación permite la caracterización del *lupinus mutabilis sweet* a lo largo de su evolución fenológica. El NDVI y el TNDVI con espectrorradiómetro fueron eficientes a la hora de identificar características relacionadas con los pretratamientos de desinfección de semilla, revelando que el mejor pretratamiento fue el de 45 minutos al ambiente, pero identificando pequeñas diferencias entre las semillas de control y las que fueron desinfectadas con químicos. Por otro lado, hubo diferencias significativas para la desinfección a 45 minutos en el horno, convirtiéndose en el peor pretratamiento de los planteados.

El uso de fotogrametría con UAVs permite la estimación de la biomasa total en pasto determinando el rendimiento total de una parcela (con unas cuantas muestras destructivas en campo) a través de la cuantificación del volumen. A través de medidas indirectas, sin prácticamente tocar el cultivo y con la ayuda de los modelos digitales del cultivo y de la superficie del terreno, se pudo

estimar una variable tan complicada de obtener como la biomasa seca, con una fiabilidad alta.

Se pudo desarrollar una metodología exitosa que permitió el procesamiento digital de imágenes obtenidas con UAV, con el objetivo de obtener una evaluación multitemporal del comportamiento de las afectaciones de pudrición de cogollo. Esta metodología permitió detectar cambios en la distribución de las enfermedades estudiadas y se concluyó que las condiciones climáticas son un escollo para el correcto análisis de las imágenes, pero que el índice VARI puede ayudar a paliar estos efectos.

Bibliografía

- Acevo-Herrera, R., Aguasca, A., Bosch-Lluis, X., Camps, A., Martínez-Fernández, J., Sánchez-Martín, N. & Pérez-Gutiérrez, C. (2010). Design and first results of an UAV-borne L-band radiometer for multiple monitoring purposes. *Remote Sensing*, 2 (7), 1662-1679. <https://doi.org/10.3390/rs2071662>
- Acorsi, M. G., das Dores Abati Miranda, F., Martello, M., Smaniotto, D. A. & Sartor, L. R. (2019). Estimating biomass of black oat using UAV-based RGB imaging. *Agronomy*, 9 (7), 344. <https://doi.org/10.3390/agronomy9070344>
- ANCUPA (2019). Executive Report on Agronomic Management, Pests and Diseases of CIPAL; Ecuador, 44 pp., Documento técnico no publicado.
- Ballesteros, R., Ortega, J. F., Hernandez, D. & Moreno, M. A. (2018). Onion biomass monitoring using UAV-based RGB imaging. *Precision agriculture*, 19 (5), 840-857. <https://doi.org/10.1007/s11119-018-9560-y>
- Batistoti, J., Marcato Junior, J., Ítavo, L., Matsubara, E., Gomes, E., Oliveira, B., Souza, M., Siqueira, H., Salgado, G., Akiyama, T., Goncalves, W., Liesenberg, V., Li, J. & Dias, A. (2019). Estimating pasture biomass and canopy height in Brazilian savanna using UAV photogrammetry. *Remote Sensing*, 11 (20), 2447. <https://doi.org/10.3390/rs11202447>
- Belton, D., Helmholz, P., Long, J. & Zerihun, A. (2019). Crop Height Monitoring Using a Consumer-Grade Camera and UAV Technology. *PFG-Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, 87 (5), 249-262. <https://doi.org/10.1007/s41064-019-00087-8>
- Bendig, J., Bolten, A., Bennertz, S., Broscheit, J., Eichfuss, S. & Bareth, G. (2014). Estimating biomass of barley using crop surface models (CSMs) derived from UAV-based RGB imaging. *Remote Sensing*, 6 (11), 10395-10412. <https://doi.org/10.3390/rs61110395>
- Calou, V. B., Teixeira, A. D. S., Moreira, L. C., Rocha, O. C. D. & Silva, J. A. D. (2019). Estimation of maize biomass using Unmanned Aerial Vehicles. *Engenharia Agrícola*, 39, 744-752. <https://doi.org/10.1590/1809-4430-Eng.Agric.v39n6p744-752/2019>
- Castro, W., Marcato Junior, J., Polidoro, C., Osco, L. P., Gonçalves, W., Rodrigues, L., Santos, M., Jank, L., Barrios, S., Valle, C., Simeao, R., Carromeu, C., Silveira, E., Castro, L., Matsubara, E. (2020). Deep learning applied to phenotyping of biomass in forages with UAV-based RGB imagery. *Sensors*, 20 (17), 4802. <https://doi.org/10.3390/s20174802>
- Catchpole, W. R. & Wheeler, C. J. (2010). Estimating plant biomass: a review of techniques. *Australian Journal of Ecology*, 17 (2), 121-131. <https://doi.org/10.1111/j.1442-9993.1992.tb00790.x>

- 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>
- Cucho-Padin, G., Loayza, H., Palacios, S., Balcazar, M., Carbajal, M. & Quiroz, R. (2020). Development of low-cost remote sensing tools and methods for supporting smallholder agriculture. *Applied Geomatics*, 12 (3), 247-263. <https://doi.org/10.1007/s12518-019-00292-5>
- Dash, J. P., Watt, M. S., Pearse, G. D., Heaphy, M. & Dungey, H. S. (2017). Assessing very high-resolution UAV imagery for monitoring forest health during a simulated disease outbreak. *ISPRS Journal of Photogrammetry and Remote Sensing*, 131, 1-14. <https://doi.org/10.1016/j.isprsjprs.2017.07.007>
- Di Gennaro, S. F., Battiston, E., Di Marco, S., Facini, O., Matese, A., Nocentini, M., Palliotti A. & Mugnai, L. (2016). Unmanned Aerial Vehicle (UAV)-based remote sensing to monitor grapevine leaf stripe disease within a vineyard affected by esca complex. *Phytopathologia Mediterranea*, 262-275. https://doi.org/10.14601/Phytopathol_Mediterr-18312
- D'Oleire-Oltmanns, S., Marzloff, I., Peter, K. D. & Ries, J. B. (2012). Unmanned aerial vehicle (UAV) for monitoring soil erosion in Morocco. *Remote Sensing*, 4 (11), 3390-3416. <https://doi.org/10.3390/rs4113390>
- Everaerts, J. (2008). The use of unmanned aerial vehicles (UAVs) for remote sensing and mapping. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 37 (B1), 1187-1192.
- Falconí, C. E. (2012). *Lupinus mutabilis* in Ecuador with special emphasis on anthracnose resistance [Tesis doctoral, Wageningen University]. Wageningen University and Research. <https://library.wur.nl/WebQuery/wurpubs/417449>
- Falconí, C. E. & Yáñez-Mendizábal, V. (2019). Solar UV-B radiation limits seedborne anthracnose infection and induces physiological and biochemical responses in *Lupinus mutabilis*. *Plant Pathology*, 68 (9), 1635-1644. <https://doi.org/10.1111/ppa.13086>
- Falconí, C. E., Visser, R. G. & van Heusden, A. W. (2013). Phenotypic, molecular, and pathological characterization of *Colletotrichum acutatum* associated with Andean lupin and tamarillo in the Ecuadorian Andes. *Plant disease*, 97 (6), 819-827. <https://doi.org/10.1094/PDIS-02-12-0175-RE>
- Falconi, C. E., Visser, R. G. & Van Heusden, S. (2015). Influence of plant growth stage on resistance to anthracnose in Andean lupino (*Lupinus mutabilis*). *Crop and Pasture Science*, 66 (7), 729-734. <https://doi.org/10.1071/CP14104>
- Ferrández-Pastor, F. J., García-Chamizo, J. M., Nieto-Hidalgo, M. & Mora-Martínez, J. (2018). Precision agriculture design method using a distributed computing architecture on internet of things context. *Sensors*, 18 (6), 1731. <https://doi.org/10.3390/s18061731>
- Fonstad, M. A., Dietrich, J. T., Courville, B. C., Jensen, J. L. & Carbonneau, P. E. (2013). Topographic structure from motion: a new development in photogrammetric measurement. *Earth surface processes and Landforms*, 38 (4), 421-430. <https://doi.org/10.1002/esp.3366>
- Frankl, A., Seghers, V., Stal, C., De Maeyer, P., Petrie, G. & Nyssen, J. (2015). Using image-based modelling (SfM-MVS) to produce a 1935 ortho-mosaic of the Ethiopian highlands. *International Journal of Digital Earth*, 8 (5), 421-430. <https://doi.org/10.1080/17538947.2014.942715>

- Furukawa, Y., & Ponce, J. (2007, July). Accurate, dense, and robust multi-view stereopsis (PMVS). *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, vol. 2. <https://doi.org/10.1109/CVPR.2007.383246>
- Gil-Docampo, M. D. L. L., Arza-García, M., Ortiz-Sánz, J., Martínez-Rodríguez, S., Marcos-Robles, J. L. & Sánchez-Sastre, L. F. (2020). Above-ground biomass estimation of arable crops using UAV-based SfM photogrammetry. *Geocarto International*, 35 (7), 687-699. <https://doi.org/10.1080/10106049.2018.1552322>
- Grüner, E., Astor, T. & Wachendorf, M. (2019). Biomass prediction of heterogeneous temperate grasslands using an SfM approach based on UAV imaging. *Agronomy*, 9 (2), 54. <https://doi.org/10.3390/agronomy9020054>
- Grüner, E., Wachendorf, M., & Astor, T. (2020). The potential of UAV-borne spectral and textural information for predicting aboveground biomass and N fixation in legume-grass mixtures. *PLoS one*, 15 (6), e0234703. <https://doi.org/10.1371/journal.pone.0234703>
- Guaytarrilla, P. & Falconí, C. (2014, mayo). Selección por arquitectura de la planta y resistencia a la antracnosis de 7 genotipos de chocho (*Lupinus mutabilis*). *Congreso de Ciencia y Tecnología ESPE*, 9 (1), 63-70.
- Guo, T., Kujirai, T. & Watanabe, T. (2012). Mapping crop status from an unmanned aerial vehicle for precision agriculture applications. *ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 39, 485-490. <https://doi.org/10.5194/isprsarchives-XXXIX-B1-485-2012>
- Hart, L., Huguenin-Elie, O., Latsch, R., Simmler, M., Dubois, S. & Umstatter, C. (2020). Comparison of Spectral Reflectance-Based Smart Farming Tools and a Conventional Approach to Determine Herbage Mass and Grass Quality on Farm. *Remote Sensing*, 12 (19), 3256. <https://doi.org/10.3390/rs12193256>
- Hurtado, R. E. & Rincón, V. O. (2009). La geomática como instrumento para modelar y hacer seguimiento a la pudrición del cogollo (PC) y al insecto plaga: *Rhynchophorus palmarum*. Zona Occidental-Tumaco (Colombia). *Revista Palmas*, 30 (3), 21-35.
- Izzuddin, M. A., Hamzah, A., Nisfariza, M. N. & Idris, A. S. (2020). Analysis of multispectral imagery from unmanned aerial vehicle (UAV) using object-based image analysis for detection of Ganoderma disease in oil palm. *J. Oil Palm Res*, 32 (3), 497-508. <https://doi.org/10.21894/jopr.2020.0035>
- Jenal, A., Lussem, U., Bolten, A., Gnyp, M. L., Schellberg, J., Jasper, J., Bongartz, J. & Bareth, G. (2020). Investigating the potential of a newly developed UAV-based VNIR/SWIR imaging system for forage mass monitoring. *PFG-Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, 88 (6), 493-507. <https://doi.org/10.1007/s41064-020-00128-7>
- Khosrokhani, M., Khairunniza-Bejo, S. & Pradhan, B. (2018). Geospatial technologies for detection and monitoring of Ganoderma basal stem rot infection in oil palm plantations: a review on sensors and techniques. *Geocarto International*, 33 (3), 260-276. <https://doi.org/10.1080/10106049.2016.1243410>
- Kokaly, R. F., Clark, R. N., Swayze, G. A., Livo, K. E., Hoefen, T. M., Pearson, N. C., Wise, R., Benzel, W., Lowers, H. & Klein, A. J. (2017). *USGS spectral library version 7 data: US geological survey data release*. United States Geological Survey (USGS): Reston, VA, USA. <https://doi.org/10.3133/ds1035>
- Liu, X., Ghazali, K. H., Han, F. & Mohamed, I. I. (2021). Automatic Detection of Oil Palm Tree from UAV Images Based on the Deep Learning Method. *Applied Artificial Intelligence*, 35 (1), 13-24. <https://doi.org/10.1080/08839514.2020.1831226>

- Lowe, D. G. (2004). Distinctive image features from scale-invariant keypoints. *International Journal of Computer Vision*, 60 (2), 91-110.
<https://doi.org/10.1023/B:VISI.0000029664.99615.94>
- Lussem, U., Schellberg, J. & Bareth, G. (2020). Monitoring forage mass with low-cost UAV data: case study at the Rengen grassland experiment. *PGF-Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, 88 (5), 407-422.
<https://doi.org/10.1007/s41064-020-00117-w>
- Mahlein, A. K. (2016). Plant disease detection by imaging sensors—parallels and specific demands for precision agriculture and plant phenotyping. *Plant Disease*, 100 (2), 241-251. <https://doi.org/10.1094/PDIS-03-15-0340-FE>
- Maresma, Á., Ariza, M., Martínez, E., Lloveras, J. & Martínez-Casasnovas, J. A. (2016). Analysis of vegetation indices to determine nitrogen application and yield prediction in maize (*Zea mays* L.) from a standard UAV service. *Remote Sensing*, 8 (12), 973.
<https://doi.org/10.3390/rs8120973>
- Meneses, V. A. B., Téllez, J. M. & Velasquez, D. F. A. (2015). Uso de drones para el análisis de imágenes multiespectrales en agricultura de precisión. @ limentech, *Ciencia y Tecnología Alimentaria*, 13 (1), 28-40.
<https://doi.org/10.24054/limentech.v13i1.1600>
- Metternicht, G. (2003). Vegetation indices derived from high-resolution airborne videography for precision crop management. *International Journal of Remote Sensing*, 24 (14), 2855-2877. <https://doi.org/10.1080/01431160210163074>
- Micheletti, N., Chandler, J. H. & Lane, S. N. (2015). Investigating the geomorphological potential of freely available and accessible structure-from-motion photogrammetry using a smartphone. *Earth Surface Processes and Landforms*, 40 (4), 473-486. <https://doi.org/10.1002/esp.3648>
- Michez, A., Lejeune, P., Bauwens, S., Herinaina, A. A. L., Blaise, Y., Castro Muñoz, E. & Bindelle, J. (2019). Mapping and monitoring of biomass and grazing in pasture with an unmanned aerial system. *Remote Sensing*, 11 (5), 473.
<https://doi.org/10.3390/rs11050473>
- Michez, A., Philippe, L., David, K., Sébastien, C., Christian, D. & Bindelle, J. (2020). Can Low-Cost Unmanned Aerial Systems Describe the Forage Quality Heterogeneity? Insight from a Timothy Pasture Case Study in Southern Belgium. *Remote Sensing*, 12 (10), 1650. <https://doi.org/10.3390/rs12101650>
- Mogensen, V. O., Jensen, C. R., Poulsen, H. H., Mortensen, G., Thage, J. H. & Koribidis, J. (1996). Reflectance index for early determination of water stress. *II International Symposium on Irrigation of Horticultural Crops 449* (pp. 393-400).
<http://doi.org/10.17660/ActaHortic.1997.449.55>
- Mukherjee, A., Misra, S. & Raghuwanshi, N. S. (2019). A survey of unmanned aerial sensing solutions in precision agriculture. *Journal of Network and Computer Applications*, 148, 102461. <https://doi.org/10.1016/j.jnca.2019.102461>
- Näsi, R., Viljanen, N., Kaivosoja, J., Alhonoja, K., Hakala, T., Markelin, L. & Honkavaara, E. (2018). Estimating biomass and nitrogen amount of barley and grass using UAV and aircraft based spectral and photogrammetric 3D features. *Remote Sensing*, 10 (7), 1082. <https://doi.org/10.3390/rs10071082>
- Niu, Y., Zhang, L., Zhang, H., Han, W. & Peng, X. (2019). Estimating above-ground biomass of maize using features derived from UAV-based RGB imagery. *Remote Sensing*, 11 (11), 1261. <https://doi.org/10.3390/rs11111261>

- Rango, A., Laliberte, A., Herrick, J. E., Winters, C., Havstad, K., Steele, C. & Browning, D. (2009). Unmanned aerial vehicle-based remote sensing for rangeland assessment, monitoring, and management. *Journal of Applied Remote Sensing*, 3 (1), 033542. <https://doi.org/10.1117/1.3216822>
- Selsam, P., Schaeper, W., Brinkmann, K. & Buerkert, A. (2017). Acquisition and automated rectification of high-resolution RGB and near-IR aerial photographs to estimate plant biomass and surface topography in arid agro-ecosystems. *Experimental Agriculture*, 53 (1), 144-157. <https://doi.org/10.1017/S0014479716000089>
- Siart, C., Bubenzer, O. & Eitel, B. (2009). Combining digital elevation data (SRTM/ASTER), high resolution satellite imagery (Quickbird) and GIS for geomorphological mapping: A multi-component case study on Mediterranean karst in Central Crete. *Geomorphology*, 112 (1-2), 106-121. <https://doi.org/10.1016/j.geomorph.2009.05.010>
- Stroppiana, D., Migliazzi, M., Chiarabini, V., Crema, A., Musanti, M., Franchino, C. & Villa, P. (2015). Rice yield estimation using multispectral data from UAV: A preliminary experiment in northern Italy. In *2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)* (pp. 4664-4667). IEEE. <https://doi.org/10.1109/IGARSS.2015.7326869>
- Swain, K. C., Thomson, S. J. & Jayasuriya, H. P. (2010). Adoption of an unmanned helicopter for low-altitude remote sensing to estimate yield and total biomass of a rice crop. *Transactions of the ASABE*, 53 (1), 21-27. <https://doi.org/10.13031/2013.29493>
- Tugi, A., Suri, M. A., Zainon, O., Yusoff, A. R. M., Rahman, M. Z. A., Sari, N. A. & Darwin, N. (2015). Oil palm tree growth monitoring for smallholders by using unmanned aerial vehicle. *Jurnal Teknologi*, 77 (26). <https://doi.org/10.11113/jt.v77.6855>
- Viljanen, N., Honkavaara, E., Näsi, R., Hakala, T., Niemeläinen, O. & Kaivosoja, J. (2018). A novel machine learning method for estimating biomass of grass swards using a photogrammetric canopy height model, images and vegetation indices captured by a drone. *Agriculture*, 8 (5), 70. <https://doi.org/10.3390/agriculture8050070>
- Waite, R. B. (1994). The application of visual estimation procedures for monitoring pasture yield and composition in exclosures and. *Tropical Grasslands*, 28, 38-42.
- Westoby, M. J., Brasington, J., Glasser, N. F., Hambrey, M. J. & Reynolds, J. M. (2012). 'Structure-from-Motion' photogrammetry: A low-cost, effective tool for geoscience applications. *Geomorphology*, 179, 300-314. <https://doi.org/10.1016/j.geomorph.2012.08.021>
- Wijesingha, J., Astor, T., Schulze-Brüninghoff, D. & Wachendorf, M. (2020). Mapping invasive Lupinus polyphyllus Lindl. in semi-natural grasslands using object-based image analysis of UAV-borne images. *PFG-Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, 88 (5), 391-406. <https://doi.org/10.1007/s41064-020-00121-0>
- Wiratmoko, D., Jatmiko, R. H., Yusuf, M. A., Farrasati, R. & Prasetyo, A. E. (2020, June). Using visible spectral-index as alternative methods for identifying levels of Ganoderma Boninese infection. In *IOP Conference Series: Earth and Environmental Science*, vol. 500, no. 1, p. 012067. <https://doi.org/10.1088/1755-1315/500/1/012067>
- Xia, M., Li, W., Fu, H., Yu, L., Dong, R. & Zheng, J. (2019, May). Fast and robust detection of oil palm trees using high-resolution remote sensing images. *Automatic Target*

Recognition XXIX (vol. 10988, p. 109880C). International Society for Optics and Photonics. <https://doi.org/10.1117/12.2518352>

Yuan, L., Zhang, J., Shi, Y., Nie, C., Wei, L. & Wang, J. (2014). Damage mapping of powdery mildew in winter wheat with high-resolution satellite image. *Remote Sensing*, 6 (5), 3611-3623. <https://doi.org/10.3390/rs6053611>

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

Zheng, J., Fu, H., Li, W., Wu, W., Yu, L., Yuan, S., ... & Kanniah, K. D. (2021). Growing status observation for oil palm trees using Unmanned Aerial Vehicle (UAV) images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 173, 95-121. <https://doi.org/10.1016/j.isprsjprs.2021.01.008>

Zhu, W., Sun, Z., Peng, J., Huang, Y., Li, J., Zhang, J., Yang, B. & Liao, X. (2019). Estimating maize above-ground biomass using 3D point clouds of multi-source unmanned aerial vehicle data at multi-spatial scales. *Remote Sensing*, 11 (22), 2678. <https://doi.org/10.3390/rs11222678>