



Teledetección

para una Agricultura Sostenible en la era del Big Data

EDITORES

Luis Ángel Ruiz Fernández
Javier Estornell Cremades

María González de Audicana Amenábar
Jesús Álvarez Mozos

upna

Universidad Pública de Navarra
Nafarroako Unibertsitate Publikoa

Evaluación de la consistencia de los datos obtenidos desde UAV por el sensor Sequoia para su aplicación en agricultura

Estela Pérez-Cardiel⁽¹⁾, Juan de la Riva⁽¹⁾, Marcos Rodrigues⁽¹⁾, Darío Domingo^(1,2), M^a Auxiliadora Casterad⁽³⁾

⁽¹⁾ Grupo GEOFOREST-IUCA, Dpto. de Geografía y Ordenación del Territorio Universidad de Zaragoza, C/ Pedro Cerbuna 12, 50009 Zaragoza, España. epcardiel@unizar.es, delariva@unizar.es, rmarcos@unizar.es.

⁽²⁾ EiFAB-iuFOR, Universidad de Valladolid, Campus Duques de Soria, 42004 Soria, España. dario.domingo@uva.es

⁽³⁾ Dpto. de Sistemas Agrícolas, Forestales y Medio Ambiente, Centro de Investigación y Tecnología Agroalimentaria de Aragón, Avda. Montañana 930, 50059 Zaragoza, España. acasterad@cita-aragon.es

Resumen: Durante los últimos años, el uso de vehículos aéreos no tripulados (*Unmanned Aerial Vehicles*, UAV) se ha convertido en una potente herramienta para el monitoreo de los cultivos. Existen sensores multispectrales compactos que se pueden integrar en drones ligeros con costes asequibles y que se están utilizando en la agricultura de precisión. Sin embargo, la calidad radiométrica de dichos sensores se ha explorado relativamente poco. Por ello, el objetivo de este trabajo es evaluar si la reflectividad a nivel superficial y los índices de vegetación obtenidos mediante el sensor Sequoia a bordo de un UAV son lo suficientemente consistentes para proporcionar información útil para las aplicaciones en agricultura. En este trabajo se comparan los registros de espectrorradiometría de campo con los valores de reflectividad adquiridos con Sequoia a bordo de UAV en parcelas de regadío de maíz y girasol entre los meses de junio y agosto de 2019. Los resultados indican que los valores de reflectividad del visible y los índices NDVI, GNDVI, NDRre y OSAVI presentan buen nivel de consistencia. En cambio, esto no es así para el borde del rojo, el infrarrojo cercano y el índice CIre. La diferencia observada se relaciona con falta de consistencia de las bandas del borde del rojo e infrarrojo cercano, en las que Sequoia, respectivamente, subestima y sobreestima la medición. No obstante, cuando estas bandas se combinan en índices que incorporan otras del visible este desajuste se diluye y los resultados son más consistentes.

Palabras clave: radiometría de campo, Parrot Sequoia, UAV, reflectividad, índices de vegetación.

Evaluation of the consistency of data obtained from Sequoia UAV-borne sensor for its application in agriculture

Abstract: During the last years, the use of Unmanned Aerial Vehicles (UAV) has become a powerful tool for crop monitoring. Small-sized multispectral sensors that are integrated into lightweight and affordable drones are being increasingly used in precision agriculture. However, their radiometric accuracy has not yet been fully explored. The aim of this study is to evaluate whether the surface level reflectance and vegetation indices NDVI, GNDVI, CIre, NDRre and OSAVI obtained by the Sequoia sensor on board of a UAV are sufficiently robust for agricultural applications. For this purpose, field spectrometry records are compared with reflectance values acquired with the Sequoia sensor on board UAVs in irrigated corn and sunflower plots between June and August 2019. The results indicate that the reflectance in the visible region and the NDVI, GNDVI, NDRre and OSAVI indices show a good level of consistency. However, this is not the case in the red-edge, the near infrared and the CIre index. The observed difference is related to inconsistencies in the red-edge and near-infrared bands, where Sequoia, respectively, underestimates and overestimates. But when these bands are combined with indices incorporating visible bands this mismatch is diluted and the results are more consistent.

Keywords: field spectrometry, Parrot Sequoia, UAV, reflectance, vegetation indices.

1. INTRODUCCIÓN

Los vehículos aéreos no tripulados (*Unmanned Aerial Vehicles*, UAV) se han convertido en una potente herramienta para el monitoreo de los cultivos. Por ejemplo, para el seguimiento fenológico (Agüera et al., 2015), la detección de enfermedades (Castrignanò et al., 2020), las estimaciones de rendimiento y la detección temprana de la presencia de malas hierbas (Peña et al., 2014). De esta forma, el agricultor puede optimizar el uso de insumos –fertilizantes, riegos y/o agroquímicos– ajustándolos a las necesidades del cultivo y en las zonas donde sean necesarios.

El conjunto de técnicas basadas en el análisis de imágenes obtenidas mediante sensores multispectrales a bordo de UAV, si bien prometedoras, son aún limitadas y complejas. Por ejemplo, el movimiento y estabilidad de la cámara alojada en el UAV hace que el procesamiento de las imágenes obtenidas sea complicado (Tsouros et al., 2019), requiriendo realizar la calibración radiométrica, la corrección geométrica y el mosaico de imágenes. No obstante, los sensores han mejorado en términos de rendimiento y precisión; un ejemplo es Parrot Sequoia (Sequoia), diseñado fundamentalmente para aplicaciones en agricultura

de precisión, siendo uno de los más empleados debido a su bajo peso y su fácil integración con los UAV más utilizados en el mercado, así como por las opciones de software que lo acompañan. Este sensor multiespectral proporciona mediciones de reflectividad absoluta sin necesidad de calibración radiométrica, pues dispone de un sensor de luz solar que captura la irradiancia y corrige los cambios en la iluminación durante el vuelo. Además, integra un módulo GPS que aumenta significativamente la precisión de los datos (Fawcett et al., 2020).

En este contexto, el objetivo del trabajo es evaluar si la reflectividad a nivel superficial y los índices espectrales derivados desde el sensor Sequoia a bordo de un UAV son lo suficientemente consistentes para proporcionar información útil para su aplicación en agricultura.

2. MATERIAL Y MÉTODOS

2.1. Zona de estudio

El área de estudio se encuentra en la Zona Regable de La Violada (Almudévar, Huesca). El estudio se realizó en parcelas comerciales, 3 de maíz y 2 de girasol de ciclo corto, regadas por aspersión y tamaño entre 2 y 10 ha.

2.2. Obtención de los datos de espectrorradiometría de campo

La evaluación de Sequoia se realizó mediante radiometría de campo, utilizando el espectro-radiómetro *Analytical Spectral Device* (ASD) FieldSpec®4. Dicho instrumento registra en la región entre el visible y el infrarrojo cercano (350-1000 nm) y en dos regiones del infrarrojo medio de onda corta (1001-1800 y 1801-2500 nm).

Se realizaron 5 salidas de campo entre el 28 de junio y el 2 de agosto de 2019. Las medidas se tomaron desde la siembra del cultivo hasta el estadio V7 en maíz y R1 en girasol. Se utilizó una pértiga que permitió medir de forma constante a 165 cm del suelo, ajustando el campo de visión al diámetro que se quería registrar, aproximadamente 73 cm, que es la distancia entre hileras de cultivo. Se tomaron diez medidas sobre la línea de cultivo y otras diez perpendiculares a ésta a un ritmo de aproximadamente de 0,75 m/seg, alternado una medida sobre la línea y otra entre líneas del cultivo; además, se realizaron tres mediciones puntuales sobre el cultivo. Para cada uno de los transectos y mediciones puntuales se registró su posición utilizando un sistema de posicionamiento Leica VIVA®GS15 CS10.

Los datos se procesaron con el software ViewSpec™Pro. Se crearon las medidas en reflectividad absoluta y, con el paquete de R *hsdar* (Lehnert et al., 2019), se generó la información hiperespectral. Con ENVI 4.7 se calculó la Respuesta Espectral Relativa de Sequoia para simular su registro multiespectral a partir de los datos hiperespectrales de ASD.

2.3. Obtención de imágenes con sensor Sequoia por medio de UAV

Las imágenes se obtuvieron utilizando un UAV de ala fija SenseFly eBee Classic equipado con el sensor multiespectral Parrot Sequoia que registra la señal en cuatro

bandas: verde (550 nm, R_{550}), rojo (660 nm, R_{660}), borde del rojo (735 nm, R_{735}) e infrarrojo cercano (790 nm, R_{790}). El seguimiento de los cultivos se realizó durante 5 semanas y los vuelos fueron simultáneos a la espectrorradiometría de campo, entre las 11 y las 14 horas UTC; la planificación de vuelos inicial sirvió para toda la campaña. Las imágenes fueron procesadas en el software Pix4D, calibradas radiométricamente utilizando el objetivo de calibración que proporciona Parrot Sequoia y calibradas geométricamente con los puntos de control colocados en los márgenes de las parcelas utilizando el sistema de posicionamiento Leica ya indicado.

2.4. Índices de vegetación

Los índices espectrales elegidos para la evaluación se presentan en la Tabla 1. Los índices se seleccionaron teniendo en cuenta el rango espectral de Sequoia, combinando las distintas bandas, en algún caso se modificó levemente el rango espectral utilizado.

Tabla 1. Índices espectrales utilizados. R_{nm} refiere a la reflectividad en nanómetros.

Índice	Formulación
NDVI	$NDVI = (R_{790} - R_{660}) / (R_{790} + R_{660})$
GNDVI	$GNDVI = (R_{790} - R_{550}) / (R_{790} + R_{550})$
Clre	$Clre = (R_{790} / R_{735}) - 1$
NDRre	$NDRre = (R_{735} - R_{660}) / (R_{735} + R_{660})$
OSAVI	$OSAVI = [(1 + 0,16)(R_{790} - R_{660})] / (R_{790} - R_{660} + 0,16)$

2.5. Análisis estadístico

La comparación entre la reflectividad y los índices espectrales medidos con Sequoia y los simulados con ASD para las longitudes de onda de Sequoia se abordó mediante dos aproximaciones complementarias.

En primer lugar, se analizó la semejanza entre medidas ASD y Sequoia mediante regresión lineal simple. Para cada longitud de onda e índice de vegetación se calculó la pendiente de la recta de regresión y la intersección con el eje de ordenadas. Se obtuvo además el coeficiente de determinación (R^2) y el error cuadrático medio normalizado (RMSEn). Estas medidas permiten interpretar las diferencias en términos de sesgo (pendiente < 1 indica sobreestimación del sensor Sequoia y viceversa) y grado de ajuste lineal relacionado con la posible desviación entre medidas en un determinado rango de reflectividad (ej. $R^2 = 1$, ajuste lineal perfecto).

Además, se aplicó la prueba no paramétrica de comparación de rangos Mann-Whitney-Wilcoxon para determinar si existen (H_1) o no diferencias (H_0) significativas entre los dos sensores. Valores de probabilidad inferiores a 0,05 permiten rechazar H_0 , aceptando la hipótesis alternativa.

3. RESULTADOS Y DISCUSIÓN

El análisis comparativo revela diferencias en longitudes de onda cercanas al infrarrojo, pero que no afectan de manera determinante a los índices de vegetación salvo en el caso de Clre y, en menor medida, el NDRre. Estas diferencias en el infrarrojo parece que aumentan con la

respuesta espectral, pasando de subestimar a sobreestimar a partir de una reflectividad de 0,3 y 0,4 en el borde del rojo e infrarrojo cercano, respectivamente.

3.1. Evaluación de los datos de reflectividad

Las longitudes de onda del visible (verde y rojo) muestran una relación lineal muy alta con una pendiente cercana a 1 (Tabla 2). En el caso de las longitudes de onda de borde del rojo e infrarrojo cercano la relación es alta, aunque menor que en el visible; el sesgo es positivo y con unas pendientes más alejadas de la situación ideal 1, lo que sugiere una mayor diferencia entre los datos simulados de ASD y Sequoia. Como se puede ver en la Figura 1, las bandas del borde del rojo y del infrarrojo cercano son las que peor se ajustan a la línea 1.1. Este resultado concuerda con los obtenidos por Fawcett et al. (2020), a pesar de que toman datos en una sola fecha, y con Stow et al. (2019) donde las longitudes de onda del visible son más precisas que las longitudes de onda del infrarrojo cercano y del borde del rojo, siendo esta última la que menor precisión obtiene. Todas las longitudes de onda muestran un RMSEn menor del 10%, el visible manifiesta un mayor acuerdo con los datos de espectrorradiometría; en cambio, la relación ofrece peores resultados para el borde de rojo y el infrarrojo cercano.

Tabla 2. Estadísticos obtenidos del modelo de regresión lineal para cada una de las longitudes de onda entre los datos de Sequoia y los simulados para este sensor con ASD ($n=82$).

Banda	Intersección	Pendiente	R ²	RMSEn (%)
R ₅₅₀	0,027	0,86	0,94*	7,0
R ₆₆₀	0,024	0,93	0,97*	9,4
R ₇₃₅	0,075	0,69	0,67*	7,1
R ₇₉₀	0,135	0,70	0,80*	6,3

*valores significativos ($p>0,05$)




Figura 1. Diagrama de dispersión por bandas espectrales (R₅₅₀ verde, R₆₆₀ rojo, R₇₃₅ borde del rojo y R₇₉₀ infrarrojo cercano) entre Sequoia y su simulación con ASD ($n=82$).

Las diferencias observadas pueden deberse a la incertidumbre de la función de la respuesta espectral y el

remuestreo espectral del sensor Sequoia. Tal y como señala Fawcett et al. (2020), la función de la respuesta espectral (SRF) aproximada del sensor Sequoia para la banda del borde del rojo derivado de la información del fabricante puede ser insuficiente. En el contexto de la espectrorradiometría los errores observados son destacables, sobre todo en la región del borde del rojo, por lo que todavía se pueden realizar mejoras.

En la Figura 2 se muestran los diagramas de cajas y el test de Wilcoxon. En las longitudes de onda del visible no existen diferencias estadísticamente significativas ($p>0,05$) entre la reflectividad medida con ASD y con Sequoia. En cambio, para las longitudes de onda de borde del rojo e infrarrojo cercano sí existen diferencias estadísticamente significativas entre ambos sensores.

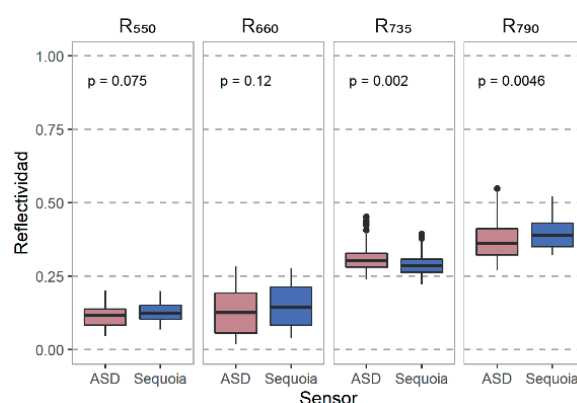


Figura 2. Diagrama de caja de los valores de reflectividad en cada banda espectral para Sequoia y su simulación con ASD y resultados del test de Wilcoxon ($n=82$).

3.2. Evaluación de los índices de vegetación

Los estadísticos obtenidos del modelo de regresión lineal entre índices de vegetación obtenidos con ASD y Sequoia (Tabla 3) indican una relación casi perfecta en casi todos los casos, a excepción del índice CIre, donde la pendiente es elevada 1,59. Esto indica que existe una diferenciación holgada entre los datos medidos con Sequoia y los simulados con ASD para las bandas de Sequoia. Los gráficos de dispersión (Figura 3) sugieren que en los índices NDVI, GNDVI Y OSAVI tienden a sobreestimar hasta el rango espectral de 0,5 aproximadamente y a partir de ahí comienzan a subestimar, en ambos casos muy levemente. En los índices CIre y NDRre las diferencias aumentan a medida que lo hace el vigor vegetal, aunque en sentidos diferentes: el primero tiende a sobreestimar y el segundo a subestimar.

Tabla 3. Estadísticos obtenidos del modelo de regresión lineal para cada índice entre los datos de Sequoia y los simulados para este sensor con ASD ($n=82$).

Banda	Intersección	Pendiente	R ²	RMSEn (%)
NDVI	0,061	0,84	0,98*	6,4
GNDVI	0,099	0,80	0,97*	4,2
CIre	0,057	1,59	0,93*	25,7
NDRre	-0,002	0,84	0,97*	8,8
OSAVI	0,058	0,85	0,97*	7,0

* valores significativos ($p>0,05$)

Para los índices en los que se utiliza la combinación de las bandas borde del rojo o infrarrojo con una banda del visible los resultados mejoran considerablemente, alcanzando valores de R^2 superiores a 0,95, con pendientes cercanas a 1 y RMSEn menores del 9%, a excepción del CIre donde el RMSEn supera el 25%.

Los diagramas de cajas (Figura 4) y la significación del test de Wilcoxon indican que sí hay diferencias significativas al nivel de confianza del 95% en el índice CIre. El índice NDRre también presenta diferencias significativas, pero el valor de significación es muy ajustado. Para el resto de índices no existen diferencias estadísticamente significativas.

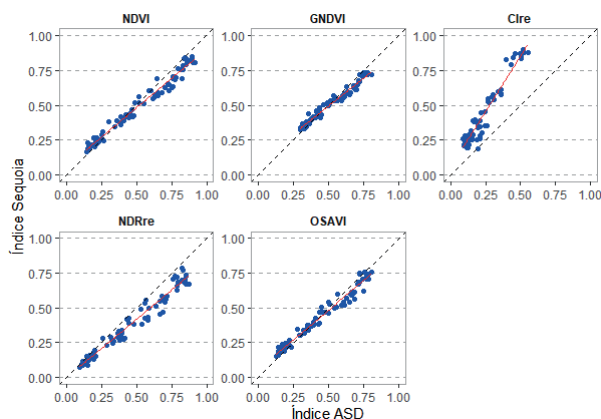


Figura 3. Diagrama de dispersión de cada índice entre los calculados con Sequoia y los derivados de la simulación de este con ASD ($n=82$).

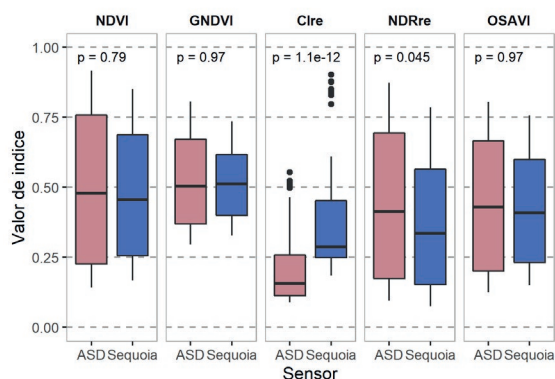


Figura 4. Diagrama de caja de los valores de los índices de vegetación para para Sequoia y su simulación con ASD y resultados del test de Wilcoxon ($n=82$).

4. CONCLUSIONES

En este trabajo se evalúa la consistencia de los datos de reflectividad –y los índices de vegetación derivados– registrados por el sensor Sequoia a bordo de un UAV mediante los datos simulados utilizando el sensor ASD.

Los valores de reflectividad en las regiones del visible (verde y rojo) y los índices NDVI, GNDVI, NDRre y OSAVI presentan buena consistencia con coeficientes de determinación por encima 0,94, intersecciones próximas a 0, pendientes cercanas a 1 y RMSEn menores del 10%.

Las diferencias más relevantes se encuentran en las bandas del borde del rojo y el infrarrojo, así como en el índice CIre; la razón está en la falta de precisión y consistencia de estas bandas. Por el contrario, para el resto de los índices de vegetación que combinan una de estas bandas (borde del rojo, infrarrojo) con otras del visible la consistencia es muy alta. Así, la introducción de una banda del visible para formar un índice de vegetación ofrece buen nivel de consistencia, aunque se utilice una banda menos precisa como puede ser el borde del rojo o el infrarrojo cercano. Consecuentemente, se debe seguir trabajando en mejorar la precisión de estas bandas espectrales para el sensor Sequoia.

5. AGRADECIMIENTOS

La primera autora es beneficiaria de un contrato pre-doctoral MECD (FPU15/04783). Este trabajo ha sido financiado por el Gobierno de Aragón (Geoforest S51_20R), FEDER “Construyendo Europa desde Aragón”. Además, consta con financiación europea-NextGenerationEU a través de una ayuda Margarita Salas a Darío Domingo (MS-240621). Los autores agradecen su colaboración a la Comunidad de Regantes de Almudévar y a los propietarios de las parcelas.

6. BIBLIOGRAFÍA

Agüera, F., Carvajal, F., Pérez, M., Orgaz, F. 2015. Multi-Temporal Imaging Using an Unmanned Aerial Vehicle for Monitoring a Sunflower Crop. *Biosystems Engineering*, 132, 19-27.

Castrignanò, A., Belmonte, A., Antelmi, I., Quarto, R., Quarto, F., Shaddad, S., Sion, V., Muolo, M.R., Ranieri, N.A., Gadaleta, G., Bartocetti, E., Riefole, C., Ruggieri, S., Nigro, F. 2020. Semi-Automatic Method for Early Detection of *Xylella fastidiosa* in Olive Trees Using UAV Multispectral Imagery and Geostatistical-Discriminant Analysis. *Remote Sensing*, 13(1), 14.

Fawcett, D., Panigada, C., Tagliabue, G., Boschetti, M., Celesti, M., Evdokimov, A., Biriukova, K., Colombo, R., Miglietta, F., Rascher, U., Anderson, K. 2020. Multi-Scale Evaluation of Drone-Based Multispectral Surface Reflectance and Vegetation Indices in Operational Conditions. *Remote Sensing*, 12(3), 514.

Lehnert, L.W., Meyer, H., Obermeier, W.A., Silva, B., Regeling, B., Thies, B., Bendix, J. 2019. Hyperspectral Data Analysis in R: The hdsar Package. *Journal of Statistical Software*, 89(12), 1-23.

Peña, J.M., Torres-Sánchez, J., Serrano-Pérez, A., López-Granados, F. 2014. Detección de malas hierbas en girasol en fase temprana mediante imágenes tomadas con un vehículo aéreo no tripulado (UAV). *Revista de Teledetección*, 42, 39-48.

Stow, D., Nichol, C.J., Wade, T., Assmann, J.J., Simpson, G., Helfter, C. 2019. Illumination geometry and flying height influence surface reflectance and NDVI derived from multispectral UAS imagery. *Drones*, 3(3), 55.

Tsouros, D.C., Bibi, S., Sarigiannidis, P.G. 2019. A Review on UAV-Based Applications for Precision Agriculture. *Information*, 10(11), 349.