

García-Guerra, J.; Burchard-Levine, V.; Borra-Serrano, I.; Dorado, J.; de Castro, A.; Peña, J. Optimización del momento de vuelo UAV y selección de predictores para estimar el vigor vegetativo (peso de poda) en viñedos

Optimización del momento de vuelo UAV y selección de predictores para estimar el vigor vegetativo (peso de poda) en viñedos

García-Guerra, Jose ¹ Burchard-Levine, Vicente ² Borra-Serrano, Irene ¹ Dorado, José ¹ de Castro, Ana ³ Peña, José Manuel ¹

¹ Tech4AGRO. Instituto de Ciencias Agrarias (ICA). Consejo Superior de Investigaciones Científicas (CSIC)

² Laboratorio De Espectro-Radiometría Y Teledetección Ambiental (SpecLab), Consejo Superior de Investigaciones Científicas (CSIC)

³ Instituto de Investigación y Tecnología Agraria y Alimentaria (INIA-CSIC)

ORCID: García-Guerra 0000-0003-2822-093X Burchard-Levine 0000-0003-0222-8706 Borra-Serrano 0000-0003-3444-3099 Dorado 0000-0002-2268-2562 de Castro 0000-0002-6699-2204 Peña 0000-0003-4592-3792

Correspondencia: jose.g.guerra@csic.es vicente.burchard@cchs.csic.es irene.borra@ica.csic.es jose.dorado@csic.es ana.decastro@csic.es jmpena@ica.csic.es

RESUMEN

El peso de poda (pruning weight, PW) es un indicador integrado del vigor vegetativo de la vid y una variable clave en viticultura de precisión por su relación con el equilibrio vegetativo-productivo y la delimitación de zonas de manejo. La teledetección con UAV permite estimar PW de forma no destructiva a escala intraparcela, pero persisten interrogantes sobre: (i) la ventana fenológica óptima de adquisición, (ii) la configuración de predictores que mejor equilibre precisión y parsimonia y (iii) la robustez de los modelos bajo transferencia entre viñedos con distinto cultivar y manejo. Evaluamos cuatro campañas (2019–2020 y 2022–2023) con siete fechas de vuelo en dos viñedos mediterráneos contrastantes. A partir de imágenes RGB y multiespectrales se derivaron métricas estructurales del dosel (área, altura y volumen) e índices espectrales. Se aplicó un flujo de regresión lineal múltiple con selección anidada y validación externa repetida, seguido de un análisis LOSO. El desempeño para PW mostró un patrón fenológico consistente, con máximos en fases tardías (envero–reblandecimiento de la baya). Las métricas estructurales, en particular el volumen del dosel, dominaron las especificaciones finales y alcanzaron R^2 de hasta 0.73 en validación externa dentro de cada viñedo. Bajo transferencia estricta, PW mantuvo R^2 moderados (0.59–0.71), aunque con diferencias en error relativo. En conjunto, los resultados apoyan vuelos en fases tardías y el uso de un predictor estructural mínimo (volumen del dosel) derivado de RGB como estrategia parsimoniosa para estimar PW.

Palabras clave: UAV, viticultura de precisión, fenología, volumen del dosel, fotogrametría SfM

Fecha de recepción: 19 febrero 2026 · Fecha de aceptación: 19 febrero 2026

Optimización del momento de vuelo UAV y selección de predictores para estimar el vigor vegetativo (peso de poda) en viñedos


García-Guerra, Jose ⁽¹⁾, Burchard-Levine, Vicente ⁽²⁾, Borra-Serrano, Irene ⁽¹⁾, Dorado, José ⁽¹⁾, de Castro, Ana ⁽³⁾, Peña, José Manuel ⁽¹⁾

⁽¹⁾ Tech4AGRO. Instituto de Ciencias Agrarias (ICA). Consejo Superior de Investigaciones Científicas (CSIC).


 0000-0003-2822-093X, jose.g.guerra@csic.es ;  0000-0003-3444-3099, irene.borra@ica.csic.es

 0000-0002-2268-2562, jose.dorado@csic.es ;  0000-0003-4592-3792, jmpena@ica.csic.es

⁽²⁾ Laboratorio De Espectro-Radiometría Y Teledetección Ambiental (SpecLab), Consejo Superior de Investigaciones Científicas (CSIC)

 0000-0003-0222-8706, vicente.burchard@cchs.csic.es

⁽³⁾ Instituto de Investigación y Tecnología Agraria y Alimentaria (INIA-CSIC).

 0000-0002-6699-2204, ana.decastro@csic.es

Resumen: El peso de poda (pruning weight, PW) es un indicador integrado del vigor vegetativo de la vid y una variable clave en viticultura de precisión por su relación con el equilibrio vegetativo-productivo y la delimitación de zonas de manejo. La teledetección con UAV permite estimar PW de forma no destructiva a escala intraparcela, pero persisten interrogantes sobre: (i) la ventana fenológica óptima de adquisición, (ii) la configuración de predictores que mejor equilibre precisión y parsimonia y (iii) la robustez de los modelos bajo transferencia entre viñedos con distinto cultivar y manejo. Evaluamos cuatro campañas (2019–2020 y 2022–2023) con siete fechas de vuelo en dos viñedos mediterráneos contrastantes. A partir de imágenes RGB y multiespectrales se derivaron métricas estructurales del dosel (área, altura y volumen) e índices espectrales. Se aplicó un flujo de regresión lineal múltiple con selección anidada y validación externa repetida, seguido de un análisis LOSO. El desempeño para PW mostró un patrón fenológico consistente, con máximos en fases tardías (envero–reblandecimiento de la baya). Las métricas estructurales, en particular el volumen del dosel, dominaron las especificaciones finales y alcanzaron R^2 de hasta 0.73 en validación externa dentro de cada viñedo. Bajo transferencia estricta, PW mantuvo R^2 moderados (0.59–0.71), aunque con diferencias en error relativo. En conjunto, los resultados apoyan vuelos en fases tardías y el uso de un predictor estructural mínimo (volumen del dosel) derivado de RGB como estrategia parsimoniosa para estimar PW.

Palabras clave: UAV, viticultura de precisión, fenología, volumen del dosel, fotogrametría SfM

Optimising UAV flight timing and predictor selection for estimating vegetative vigour (pruning weight) in vineyards

Abstract: Pruning weight (PW) is an integrated indicator of grapevine vegetative vigour and a key variable in precision viticulture due to its relationship with vegetative-productive balance and vigour-based management zoning. UAV-based remote sensing enables non-destructive PW estimation at intra-block scale; however, uncertainties remain regarding: (i) the optimal phenological acquisition window, (ii) the predictor configuration that best balances accuracy and parsimony, and (iii) model robustness under cross-vineyard transfer across different cultivars and management systems. We evaluated four seasons (2019–2020 and 2022–2023) with seven flight dates in two contrasting Mediterranean vineyards. Structural canopy metrics (area, height, and volume) and spectral indices were derived from RGB and multispectral imagery. A nested multiple linear regression workflow with repeated external validation was applied, followed by strict leave-one-site-out (LOSO) analysis. PW prediction showed a consistent phenological pattern, with highest performance at late stages (véraison–berry softening). Structural metrics, particularly canopy volume, dominated the final model specifications and achieved R^2 values of up to 0.73 under external validation within each vineyard. Under strict transfer, PW retained moderate R^2 (0.59–0.71), albeit with differences in relative error. Overall, the results support late-season flights and the use of a minimal structural predictor (canopy volume) derived from RGB as a

parsimonious strategy for PW estimation.

Keywords: UAV, precision viticulture, phenology, canopy volume, SfM photogrammetry

1. INTRODUCCIÓN

El vigor vegetativo de la vid condiciona el equilibrio crecimiento–producción y, con ello, el rendimiento, la calidad y las necesidades de manejo. El peso de poda en reposo invernal (*pruning weight*, PW) es el indicador de referencia del vigor, al integrar la biomasa anual producida y reflejar el balance vegetativo–reproductivo; no obstante, su medición manual es laboriosa y difícil de escalar, lo que ha motivado su estimación espacial mediante teledetección (Dobrowski *et al.*, 2003). En viñedos en hileras, la mezcla suelo–dosel y la resolución espacial pueden limitar la sensibilidad de sensores de menor resolución (p. ej., satelitales) (Matese *et al.*, 2015). En este contexto, los vehículos aéreos no tripulados (UAV) proporcionan imágenes centimétricas y productos tridimensionales derivados de fotogrametría (Structure-from-Motion, SfM), ofreciendo una vía no destructiva para estimar PW a escala intraparcela (Matese & Di Gennaro, 2021). En trabajos previos, PW se ha estimado mediante índices espectrales (p. ej., NDVI sobre píxeles de dosel) y/o métricas estructurales obtenidas de productos 3D (p. ej., volumen de dosel) (García-Fernández *et al.*, 2021; Marques *et al.* 2025; Matese & Di Gennaro, 2021). Sin embargo, en términos operativos sigue siendo necesario definir cuándo adquirir los datos a lo largo del ciclo fenológico y qué configuración de sensores/predictores es suficiente (RGB, multiespectral o mixta). Además, la mayoría de estudios que estiman PW se realizan en un único viñedo o campaña, sin cuantificar su robustez bajo transferencia a contextos agronómicos distintos. Aquí abordamos estas lagunas mediante una evaluación multi-año y multi-sitio en dos viñedos con distinto cultivar y manejo, y con siete vuelos UAV desde floración hasta cosecha usando sensores RGB y multiespectral, con el objetivo de: (i) identificar el momento óptimo de vuelo UAV para estimar PW, (ii) comparar el desempeño de modelos basados en predictores RGB, multiespectrales y mixtos, y (iii) evaluar la transferibilidad del modelo bajo cambio de dominio entre viñedos con distinto cultivar y manejo.

2. MATERIAL Y MÉTODOS

El estudio se realizó en la finca experimental “El Socorro” (Colmenar de Oreja, Madrid; 40°07'58"N, 3°22'33"W; 755 m s.n.m.), con clima mediterráneo continental semiárido (T media anual 13,7 °C; P media anual 421 mm). Se estudiaron dos viñedos experimentales (Parcela A, Parcela B), ambos conducidos en cordón Royat bilateral y con riego por goteo, con ensayos organizados mediante un diseño en bloques completos aleatorizado, pero con distinto cultivar y periodo de estudio. La Parcela A (Tempranillo; 0.67 ha) corresponde a un ensayo de manejo del suelo establecido en 2008 (6 tratamientos, 4 bloques; 24 unidades experimentales). La Parcela B (Petit Verdot; 0.5 ha) corresponde a un ensayo de riego establecido en 2021 (3 tratamientos, 3 bloques; 9 unidades experimentales). En ambas parcelas se fijaron tres puntos de muestreo por unidad experimental (Parcela A, n = 72; Parcela B, n = 27). Cada punto abarcó

un conjunto fijo de cepas consecutivas (cuatro en la Parcela A y tres en la Parcela B). El peso de poda (PW) se midió durante el reposo invernal, recolectando en cada punto los sarmientos retirados y pesándolos en campo con una báscula calibrada. En cada fecha de vuelo se registró la fenología en campo a nivel de punto de muestreo mediante la escala BBCH (Lorenz *et al.*, 1995). La localización de los puntos de muestreo se georreferenció mediante GNSS diferencial para asegurar la correspondencia espacial con las variables derivadas de UAV a lo largo de todas las fechas de vuelo y años.

En cada parcela se realizaron siete vuelos por año durante dos años consecutivos (Parcela A: 2019–2020; Parcela B: 2022–2023), a intervalos aproximados de dos semanas, desde el final de la floración de la vid hasta la vendimia. Las imágenes se adquirieron con UAV multirrotor equipados con sensor RGB (Sony ILCE-6300L en la Parcela A y DJI Zenmuse P1 en la Parcela B) y sensor multiespectral Parrot Sequoia+ en ambos casos. Los vuelos se realizaron a alturas comprendidas entre 15 y 40 m, con solapes frontales y laterales $\geq 70\%$. El procesado SfM se llevó a cabo con Agisoft PhotoScan (Parcela A) y OpenDroneMap (Parcela B).

La segmentación del dosel se realizó mediante análisis de imagen basado en objetos (OBIA) en eCognition Developer, siguiendo el protocolo descrito por de Castro *et al.* (2018). Para cada fecha de vuelo se generó un modelo de altura del dosel (CHM) como diferencia entre el DSM y el DTM ($CHM = DSM - DTM$), y se delimitaron objetos de dosel mediante reglas para separar el dosel de la vid del fondo. A partir de dichos objetos se extrajeron tres métricas estructurales por fecha de vuelo, agregadas a escala de punto de muestreo: área (CA), altura (CH) y volumen del dosel (CV), como proxy tridimensional del desarrollo estructural del dosel (Tabla 1). A partir de los ortomosaicos multiespectrales se calcularon cuatro índices espectrales (GNDVI, GRVI, NDVI, NDRE), cuyas definiciones se recogen en la Tabla 1. Los índices se calcularon a nivel de píxel y se restringieron a los objetos del dosel segmentados mediante OBIA (Sección 2.4) para minimizar la mezcla dosel–fondo; posteriormente, para cada punto de muestreo y fecha de vuelo, se agregaron como el valor medio dentro del objeto de dosel correspondiente.

El análisis se centró en la estimación de PW a partir de predictores derivados de UAV. La modelización se realizó mediante regresión lineal múltiple, seleccionada por su parsimonia, interpretabilidad y estabilidad bajo tamaños muestrales moderados. Se compararon tres configuraciones de predictores: modelos basados en sensor RGB, utilizando métricas estructurales derivadas de SfM (CA, CH y CV); modelos basados en sensor multiespectral, utilizando índices espectrales; y modelos mixtos, combinando predictores estructurales y espectrales. La optimización del momento de vuelo se abordó evaluando el desempeño predictivo en cada fecha disponible y seleccionando, dentro de cada

configuración, especificaciones parsimoniosas, evitando combinaciones redundantes de predictores altamente colineales. El desempeño se estimó mediante validación externa repetida (50 repeticiones; 75/25 entrenamiento-

test), con divisiones estratificadas por año dentro de cada viñedo para asegurar que ambos años estuvieran representados en entrenamiento y test en cada repetición.

Tabla 1. Predictores derivados de UAV empleados en el análisis

Tipo	Sensor	Predictor	Definición / Fórmula
Estructural	RGB	CA	Área proyectada horizontal del objeto del dosel (m ²)
Estructural	RGB	CH	Media del CHM dentro del objeto (m)
Estructural	RGB	CV	Integración del CHM sobre el área proyectada del dosel ($\sum_{i=1}^N \text{CHM}_i \cdot A_{\text{pixel}} \cdot (m^3)$)
Espectral	Multiespectral	GNDVI	$(\text{NIR} - \text{G}) / (\text{NIR} + \text{G})$
Espectral	Multiespectral	GRVI	$(\text{G} - \text{R}) / (\text{G} + \text{R})$
Espectral	Multiespectral	NDRE	$(\text{NIR} - \text{RE}) / (\text{NIR} + \text{RE})$
Espectral	Multiespectral	NDVI	$(\text{NIR} - \text{RED}) / (\text{NIR} + \text{RED})$

El rendimiento se cuantificó mediante el coeficiente de determinación (R²) y el error cuadrático medio relativo (rRMSE), expresado como porcentaje respecto a la media observada. Con el fin de evaluar la generalización entre parcelas bajo un criterio operativo único, se definió una configuración común (fecha de vuelo y conjunto de predictores) seleccionada por su desempeño equilibrado en parcelas. Para cada candidato, el rendimiento se resumió mediante la mediana de R² y rRMSE en el conjunto de repeticiones dentro de cada parcela, y la configuración común se escogió maximizando el desempeño combinado entre parcelas (promedio no ponderado de las medianas de R² y rRMSE), priorizando configuraciones parsimoniosas cuando el desempeño fue similar. La capacidad de generalización entre parcelas se evaluó mediante un esquema leave-one-site-out (LOSO), entrenando el modelo íntegramente en una parcela y evaluándolo sin recalibración en la otra, utilizando en ambos casos la configuración común previamente definida. Este procedimiento permitió cuantificar la robustez del modelo frente a cambios de contexto (cultivar, manejo y año de adquisición). Todos los análisis se realizaron en R (R Core Team, 2024).

3. RESULTADOS

El desempeño predictivo del PW varió con el estado fenológico en ambas parcelas (Fig. 1), alcanzando un máximo en la fecha de vuelo 6 (BBCH 8, maduración). Este patrón fue consistente entre parcelas. En esa fecha, los modelos basados en métricas estructurales derivadas de SfM (STR) alcanzaron los valores más altos de R² en validación externa en ambas parcelas (Fig. 1). Los modelos basados únicamente en índices espectrales (SPC) mostraron un rendimiento extremadamente bajo en ambas parcelas, y los modelos mixtos (STR_SPC) no mejoraron de forma consistente respecto a STR (Fig. 1). Bajo el criterio operativo común se seleccionó la fecha de vuelo 6 y, en esa fecha, una especificación univariable basada en el volumen de dosel (CV). La Figura 2 muestra el desempeño de este modelo (CV; fecha 6) en validación externa repetida (50 repeticiones; 75/25) con mayor ajuste en la Parcela A (R² = 0.70; rRMSE = 22.8%) que en la Parcela B (R² = 0.53; rRMSE = 46.0%). En la

transferencia estricta LOSO, R² fue 0.59 (A→B) y 0.71 (B→A), con rRMSE elevados y asimétricos (94.8% y 56.4%, respectivamente; Tabla 2). La regresión de calibración Observado ~ Predicho mostró interceptos distintos de 0 y pendientes cercanas a 1 en ambas direcciones (A→B: $\alpha = 0.096$, $\beta = 1.052$; B→A: $\alpha = -0.091$, $\beta = 0.950$).

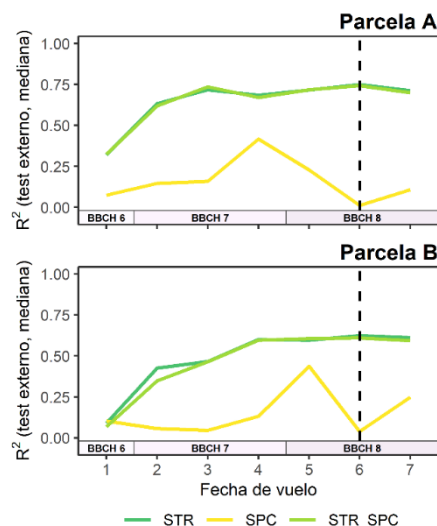


Figura 1. Desempeño (R² en test externo; mediana de 50 repeticiones) de modelos para estimar PW a lo largo de siete fechas de vuelo en dos parcelas experimentales (A y B), comparando predictores estructurales (STR), espectrales (SPC) y combinados (STR_SPC). Las bandas indican el estado fenológico de la vid según la escala BBCH (6: floración; 7: desarrollo del fruto; 8: maduración) y la línea discontinua la fecha de vuelo seleccionada como configuración operativa común.

4. DISCUSIÓN

Los resultados muestran una dependencia fenológica marcada en la estimación de PW mediante UAV, con el máximo desempeño en BBCH 8 (fecha 6). Este patrón es coherente con el carácter acumulativo del peso de poda. A medida que avanza el ciclo vegetativo, las métricas estructurales capturan un dosel más desarrollado y

próximo a su máximo desarrollo, con una progresiva estabilización del crecimiento vegetativo y, en consecuencia, más alineado con el vigor acumulado que integra el PW.

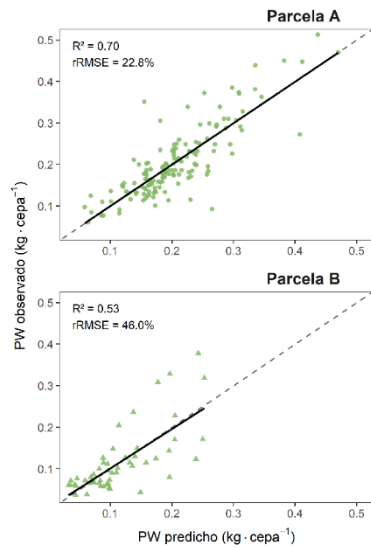


Figura 2. Relación entre PW observado y predicho ($\text{kg} \cdot \text{cepa}^{-1}$) en la fecha de vuelo 6 en las dos parcelas analizadas. Cada punto representa un punto de muestreo; la línea discontinua indica 1:1 y la continua el ajuste lineal. Se muestran R^2 y $r\text{RMSE}$ (%) calculados a partir de las predicciones medias del modelo ganador basado en CV (fecha 6).

Tabla 2. Transferibilidad estricta (LOSO) para PW, con α (intercepto) y β (pendiente) obtenidos de la regresión de calibración Observado ~ Predicho en el conjunto de validación

Train → Test	R^2	$r\text{RMSE}$ (%)	α	β
A → B	0.59	94.8	0.096	1.052
B → A	0.71	56.4	-0.091	0.950

La comparación entre familias de predictores indica un dominio claro de la información estructural: en la fecha óptima, los modelos espectrales mostraron un rendimiento inferior y su combinación con predictores estructurales no produjo mejoras consistentes. En línea con García-Fernández *et al.* (2021) y Marques *et al.* (2025), el volumen del dosel (CV) emerge como un descriptor parsimonioso e informativo para estimar PW a escala intraviñedo; sin embargo, a diferencia de estos trabajos, nuestro diseño multitemporal permite identificar explícitamente la ventana fenológica óptima y evaluar su estabilidad bajo transferencia estricta entre viñedos, pese al uso de distintos sensores RGB y flujos SfM, que podrían introducir variabilidad en métricas estructurales como el CHM o el volumen de dosel. Bajo transferencia estricta (LOSO), R^2 se mantuvo en rangos moderados-altos, mientras que los $r\text{RMSE}$ fueron elevados y distintos entre direcciones, compatibles con sesgos de calibración entre viñedos que limitan la portabilidad sin recalibración, especialmente para estimaciones absolutas de PW. En particular, la relación Observado ~ Predicho mostró pendientes próximas a 1, pero interceptos desplazados ($\alpha \approx \pm 0.09$), lo que indica un desajuste dominado por diferencias de nivel. En

consecuencia, la transferencia podría ser suficiente para zonificación relativa del vigor, mientras que la estimación cuantitativa absoluta de PW requeriría un ajuste de recalibración.

5. AGRADECIMIENTOS

Esta investigación fue financiada por los proyectos PID2023-150108OB-C31 y PID2023-150108OB-C32 del MCIU/AEI (<https://doi.org/10.13039/501100011033>) y el FSE+, así como por el proyecto ECOdigital (ref. MMT2 4-ICA-01) del programa MOMENTUM del CSIC y NextGenerationEU, a través del Plan de Recuperación, Transformación y Resiliencia (PRTR).

6. REFERENCIAS

- De Castro, A. I., Jiménez-Brenes, F. M., Torres-Sánchez, J., Peña, J. M., Borra-Serrano, I., & López-Granados, F. (2018). 3-D Characterization of Vineyards Using a Novel UAV Imagery-Based OBIA Procedure for Precision Viticulture Applications. *Remote Sensing*, 10(4), 584. <https://doi.org/10.3390/rs10040584>
- Dobrowski, S. Z., Ustin, S. L., & Wolpert, J. A. (2003). Grapevine dormant pruning weight prediction using remotely sensed data. *Australian Journal of Grape and Wine Research*, 9(3), 177-182. <https://doi.org/10.1111/j.1755-0238.2003.tb00267.x>
- García-Fernández, M., Sanz-Ablanedo, E., Pereira-Obaya, D., & Rodríguez-Pérez, J. R. (2021). Vineyard Pruning Weight Prediction Using 3D Point Clouds Generated from UAV Imagery and Structure from Motion *Photogrammetry. Agronomy*, 11(12), Article 12. <https://doi.org/10.3390/agronomy11122489>
- Lorenz, D. H., Eichhorn, K. W., Bleiholder, H., Klose, R., Meier, U., & Weber, E. (1995). Growth Stages of the Grapevine: Phenological growth stages of the grapevine (*Vitis vinifera* L. ssp. *vinifera*)—Codes and descriptions according to the extended BBCH scale†. *Australian Journal of Grape and Wine Research*, 1(2), 100-103. <https://doi.org/10.1111/j.1755-0238.1995.tb00085.x>
- Marques, P., Ferreira, L., Adão, T., Sousa, J. J., Morais, R., Peres, E., & Pádua, L. (2025). Integrating UAV Multi-Temporal Imagery and Machine Learning to Assess Biophysical Parameters of Douro Grapevines. *Remote Sensing*, 17(23), 3915. <https://doi.org/10.3390/rs17233915>
- Matese, A., & Di Gennaro, S. F. (2021). Beyond the traditional NDVI index as a key factor to mainstream the use of UAV in precision viticulture. *Scientific Reports*, 11(1), Article 1. <https://doi.org/10.1038/s41598-021-81652-3>
- Matese, A., Toscano, P., Di Gennaro, S. F., Genesio, L., Vaccari, F. P., Primicerio, J., Belli, C., Zaldej, A., Bianconi, R., & Gioli, B. (2015). Intercomparison of UAV, Aircraft and Satellite Remote Sensing Platforms for Precision Viticulture. *Remote Sensing*, 7(3), 2971-2990. <https://doi.org/10.3390/rs70302971>
- R Core Team, 2024. *R: A language and environment for statistical computing*. R Foundation for Statistical Computing. <https://www.R-project.org/>