

# Utilización de drones para la predicción de cosecha en viña

---

López-García, P.<sup>1</sup>; Martínez-Moreno, A.<sup>2</sup>; Ramírez-Cuesta, J.M. <sup>2</sup>; Buesa, I.<sup>2</sup>; Intrigliolo, D.S.<sup>2</sup>; Ortega, J.F.<sup>1</sup>; Moreno, M.A.<sup>1</sup>; Ballesteros, R.<sup>1</sup>

<sup>1</sup>Instituto de Desarrollo Regional (IDR), [UCLM](#)

<sup>2</sup>Centro de Edafología y Biología Aplicada del Segura ([CEBAS-CSIC](#))

Uno de los aspectos a mejorar en viticultura es la predicción de cosecha, necesaria para prevenir excesos de producción, muchas veces regulado por las Denominaciones de Origen o por ley, pero también por sus efectos sobre la calidad de la uva. Con el objetivo de producir cantidades de uva óptimas cada campaña, la predicción temprana de rendimiento permite ajustar la carga de racimos promoviendo la correcta maduración de la uva. Además, permite organizar las tareas de vendimia así como el requerimiento de espacio, maquinaria y personal en bodega (De La Fuente et al., 2015).

Los métodos tradicionales de predicción de cosecha, ampliamente utilizados, se basan en determinar en un número limitado de cepas los componentes del rendimiento, definidos por el número de racimos, el número de bayas por racimo y el peso de la baya (Tardaguila et al., 2012) siendo medidas puntuales que pueden no representar la realidad del conjunto de la parcela.

La implementación de las técnicas de agricultura de precisión en la viticultura ocurrió más tarde que en otros cultivos. Este retraso no fue debido a la falta de interés de los viticultores, sino a las dificultades de las características del viñedo, su organización en filas y su cubierta discontinua, que requiere imágenes de muy alta resolución para segmentar la cubierta vegetal del suelo (Matese et al., 2015). En los últimos años, la viticultura de precisión se ha centrado en la delimitación dentro de un viñedo de áreas con características homogéneas. Estas áreas son definidas a partir de información proporcionada por índices de vegetación (IVs) derivados de imágenes aéreas, y características del suelo, obtenidas con métodos no destructivos. En la captura de imágenes aéreas de muy alta resolución juegan un papel muy importante los drones. Diferentes tipos de sensores embarcados en un dron permiten la extracción de información útil, haciendo posible la delimitación de áreas de gestión dentro de un viñedo para hacer distintos manejos de riego, fertilización, aclareo de racimos, separación de las uvas en diferentes lotes según su calidad (Santesteban, 2019) y evaluación temprana de rendimiento (Di Gennaro et al., 2019).

Al igual que se puede determinar estrés hídrico con sensores multiespectrales y RGB (López-García et al., 2019), se evalúa la posibilidad de predecir cosecha con estas técnicas de teledetección de rango cercano. Con este objetivo, es necesario el uso de máquinas de aprendizaje que permite extraer información útil de los productos geomáticos de alta resolución. El objetivo de este trabajo es la predicción de cosecha en viña a partir de bandas multiespectrales derivadas de imágenes adquiridas por una cámara multiespectral embarcada en un dron, aplicando máquinas de aprendizaje.

## Materiales y métodos

El viñedo en el que se calibró la metodología se encuentra situado en el término municipal de Fuente-Álamo (Albacete), con coordenadas geográficas 38° 43' 43.3" Norte y 1° 28' 12.6" Oeste, con una altitud de 820 m y una pendiente media del 5%, de 7,5 ha de superficie, ocupando el ensayo 0,6 ha. La parcela se ubica dentro de una zona regable de la Sociedad Agraria de Transformación (SAT) Las Colleras (Figura 1).

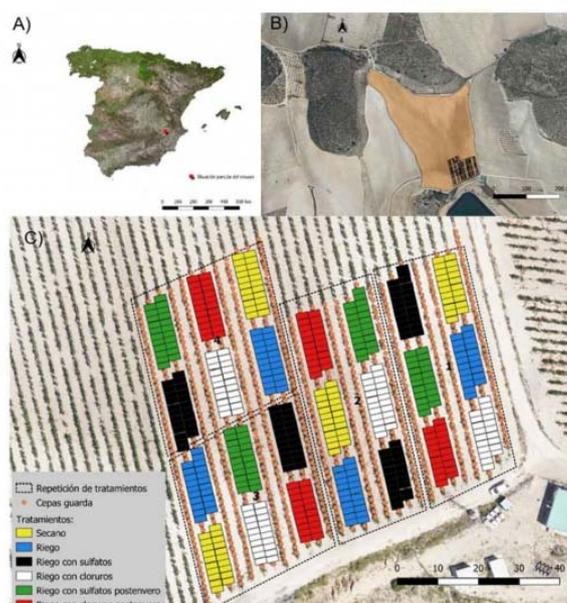


Figura 1. A) Situación de la parcela, B) vista general de la parcela y de la zona del ensayo, y C) detalle del ensayo con las cepas de cada tratamiento y repetición.

Se trata de un viñedo de la variedad Monastrell, plantado en 2007, injertado sobre SO4, con un marco de plantación de 3 m entre filas y 1,5 m entre cepas dentro de cada fila. El diseño de plantación es en espaldera orientada en dirección Norte-Sur y regada mediante goteros autocompensantes de 4 l/h espaciados a 1 m. En este viñedo se realizó un ensayo de riego (1.000 m<sup>3</sup>/ha) con aguas de diferente calidad (Figura 1C) durante la campaña de 2018. Los tratamientos de riego estudiados fueron:

1. Secano.
2. Riego con agua de “buena calidad” procedente del embalse.
3. Riego con agua de elevada concentración en sulfatos (conductividad eléctrica (CE)) de 5 dS/m).
4. Riego con agua de elevada concentración en cloruros (CE de 5 dS/m).
5. Riego con agua de elevada concentración en sulfatos (CE de 5 dS/m), iniciando el riego después del envero.
6. Riego con agua de elevada concentración en cloruros (CE de 5 dS/m), iniciando el riego después del envero.

La determinación de la producción se hizo en la vendimia, el 10 de octubre de 2018. Se muestrearon todas las cepas individualmente contando y pesando todos sus racimos, siendo el valor de la producción para cada tratamiento y repetición el promedio de la producción de las cepas muestreadas. Se realizaron cinco vuelos coincidiendo con momentos significativos del desarrollo fenológico de la viña según Baggiolini (1952) (Tabla 1). El dron utilizado fue un cuadricóptero de despegue y aterrizaje vertical, microdrones md4-1000 (Microdrones GmbH, Siegen, Alemania) con una cámara multispectral Sequoia (Parrot, Paris, Francia) de tamaño de píxel de 8 cm (Figura 2). Esta cámara mide en cuatro bandas separadas: verde (550 nm con un filtro de paso de banda (FPB) de 40 nm), rojo (660 nm con FPB de 40 nm), rojo borde (735 nm con FPB de 10 nm) e infrarrojo cercano (790 nm con FPB de 40 nm).

Fechas de vuelo	Estado fenológico
15/06/2018	Botones florales (H-I)
27/07/2018	Racimo cernido (L)
14/08/2018	Comienzo de envero (L-M)
23/08/2018	Envero (M)
19/09/2018	Maduración (N)

Tabla 1. Fechas de vuelo y estado fenológico del cultivo.

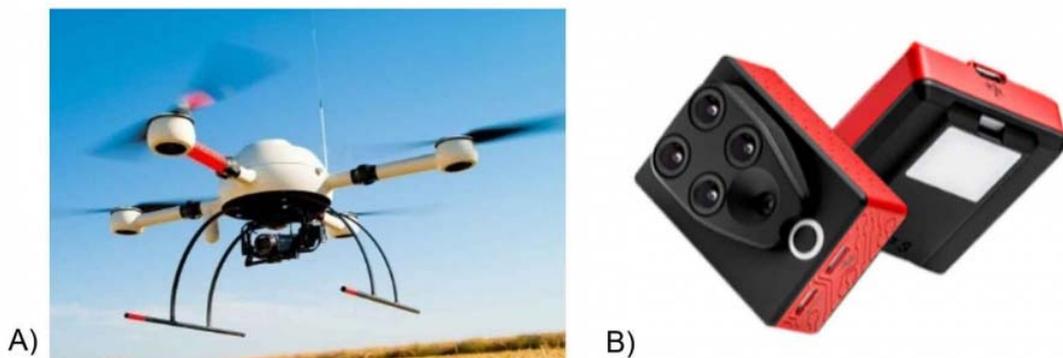


Figura 2. Dispositivos empleados en los vuelos sobre la viña: A) dron, y B) cámara multiespectral.

Las imágenes adquiridas por la cámara se trataron fotogramétricamente para obtener una ortoimagen (Figura 3A y 3B) multiespectral georreferenciada. A partir de la ortoimagen obtenida se calcularon distintos IVs en el rango multiespectral que fueron relacionados con la producción de la vid. El cálculo de estos IVs se hizo únicamente de la vegetación bien iluminada (Figura 3C), eliminando el resto de la imagen: suelo, piedras y sombra de las cepas, entre otros. Para ello se utilizó el programa MS-GEO-LAIC, una modificación del programa LAIC (Córcoles et al., 2013). El funcionamiento de este programa parte de la ortoimagen original en la que se selecciona una pequeña porción de la ortoimagen para hacer un análisis de cluster de los niveles verde, rojo, red-edge e infrarrojo cercano para distinguir entre el área verde del cultivo (con mayor reflectividad en la banda del infrarrojo cercano) y el resto de bandas.

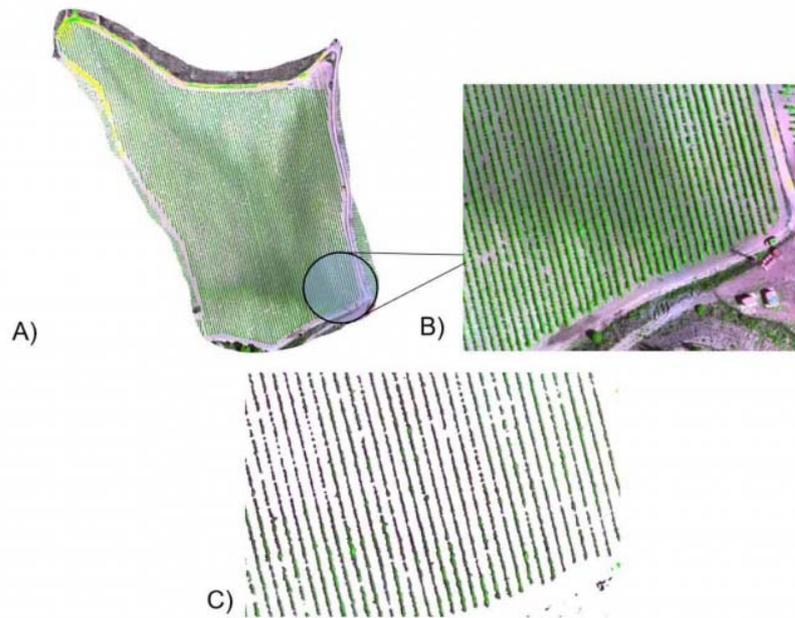


Figura 3. A) Ortoimagen en el rango multispectral, B) zoom con vegetación sin segmentar, y C) zoom con vegetación bien iluminada segmentada.

## Resultados y discusión

Los resultados de producción mostraron que el tratamiento de secano (T1) obtuvo el menor rendimiento, de 6,78 kg/cepa, y el de regadío con agua 'buena' (T2) el mayor rendimiento, de 9,61 kg/cepa (Figura 4). Respecto al rendimiento en T3, T4, T5 y T6, donde cambia el momento de inicio de riego con las diferentes aguas salinas, no se observan diferencias significativas respecto al T2, lo que indica que el mayor estrés hídrico provocado en T5 y T6 por iniciarse el riego después del envero de la uva, no se ve reflejado en la producción final.

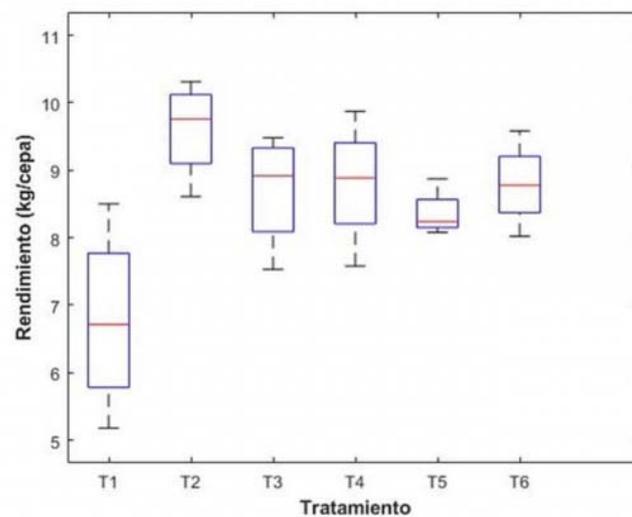


Figura 4. Rendimiento obtenido en vendimia por tratamientos.

Se desea representar la relación que existe entre la producción y varios IVs multiespectrales como primer paso para determinar métodos de predicción temprana de rendimiento basados en imágenes de dron. Para comprobar cómo de lineal es la relación entre los IVs multiespectrales y la producción para cada fecha de vuelo, se analizaron una serie de estadísticos descriptivos. Se utilizaron relaciones lineales porque se han venido utilizando tradicionalmente para establecer relaciones entre los productos obtenidos de la teledetección y distintos parámetros de la planta (Ballesteros et al., 2015).

De los resultados de los descriptivos estadísticos obtenidos para cada fecha de vuelo, no existe ningún modelo significativo, pues los coeficientes de determinación de todos los modelos y para todas las fechas no alcanzan el valor de 0,5. Si bien, en la fecha del último vuelo los coeficientes de determinación de todos los modelos son mayores que en el resto de las fechas de muestreo, superando valores de 0,4 en algunos casos (Tabla 2), conviene destacar como mejor modelo el TCARI/OSAVI con  $R^2=0,461$ ,  $RMSE=0,842$  kg/cepa y  $ER=9,896\%$ , seguido del NDVI con  $R^2=0,455$ ,  $RMSE=0,846$  kg/cepa y  $ER=9,947\%$ , si bien descartamos el TCARI/OSAVI ya que este IV considera el suelo en su cálculo, por lo que no sería significativo, pues de acuerdo a la metodología seguida se segmentó únicamente la vegetación eliminando el resto de elementos del medio.

Índices de vegetación	19/09/2018		
	R <sup>2</sup>	RMSE (Kg/cepa)	ER (%)
NDVI	<b>0.455</b>	<b>0.846</b>	<b>9.947</b>
GI	0.202	1.024	12.034
GNDVI	0.421	0.872	10.249
MCARI	0.287	0.968	11.380
MCARI 1	0.218	1.014	11.917
MCARI 2	0.359	0.918	10.788
MSAVI	0.274	0.977	11.482
MSR	0.441	0.858	10.078
MTVI3	0.218	1.014	11.917
TCARI/OSAVI	<b>0.461</b>	<b>0.842</b>	<b>9.896</b>
SRI	0.414	0.878	10.317
RDVI	0.307	0.955	11.220

Tabla 2. Estadísticos descriptivos de las relaciones lineales entre los IVs multiespectrales y la producción para el 19/09/2018.

Para resolver los problemas altamente no lineales se emplearon modelos de redes neuronales artificiales (RNA). Los resultados obtenidos con el empleo de RNAs con IVs multiespectrales como predictores, muestran ajustes robustos con  $R^2=0,813$ ,  $RMSE=0,338$  kg/cepa y  $ER=3,794\%$ . Cabe destacar la superioridad de estos modelos basados en máquinas de aprendizaje frente a los resultados obtenidos mediante la aplicación de relaciones lineales, lo que indica que estas relaciones responden a modelos altamente no lineales. Si bien, no existen modelos generalizados para todas las parcelas de viñedo, pues el funcionamiento de estas máquinas de aprendizaje se basa en la toma de datos puntuales de cada parcela para la calibración de la RNA y la extrapolación al resto de la parcela en particular.

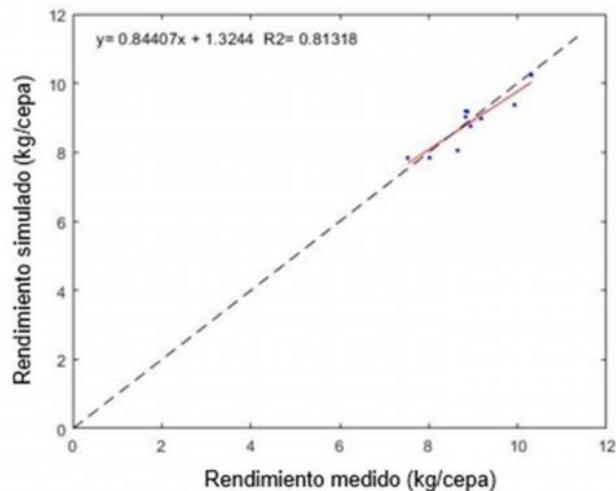


Figura 5. Línea de regresión del rendimiento medido y simulado con una RNA.

## Conclusiones

Las ortoimágenes obtenidas mediante el empleo de cámaras embarcadas en drones permite el cálculo de distintos IVs, que se relacionan con características biofísicas de las plantas, como el rendimiento en este caso. Además, la alta resolución de las ortoimágenes permite la segmentación de la vegetación, y que no se tenga en cuenta en el cálculo de los IVs otros elementos del medio como pueden ser el suelo y la sombra de las plantas, entre otros. El uso de RNAs permiten describir las relaciones altamente no lineales que se dan entre el rendimiento y los IVs calculados, con el impedimento de que no existe un modelo general, pues es necesario tomar datos puntuales de rendimiento en la parcela para la calibración de la RNA y la posterior extrapolación al resto de la parcela. De todos modos, esto podría ser positivo, ya que el agricultor tendría una predicción de cosecha personalizada para cada parcela en particular.

La utilización de los drones para obtener productos geomáticos útiles en aplicaciones agrícolas y ambientales tiene numerosas ventajas sobre el uso de satélites y de los vehículos aéreos de resolución media. Las principales ventajas son la mayor resolución espacial, temporal, al poder volar cuando sea necesario, evitar el problema de aparición de nubes, su manejo sencillo, su fácil transporte por sus reducidas dimensiones y peso. Conviene destacar que la baja altura de vuelo permite una resolución espacial del orden del centímetro, a pesar de que las cámaras empleadas no tengan una alta calidad métrica y radiométrica. Algunas de las desventajas del empleo de drones es la dificultad de volar en condiciones de viento y la autonomía, lo que obliga a planificar el vuelo considerando la duración de las baterías.

## Agradecimientos

Al Ministerio de Ciencia, Innovación y Universidades por su financiación a través de una beca FPU, y a través del Plan Nacional de I+D+i por la financiación del Proyecto PRECIRIEGO (RTC-2017-6365-2) y los Proyectos SEGRE (AGL2017-82927-C3-2-R) y NITROGRAPE (AGL2017-83738-C3-3-R). A la Consejería de Educación, Cultura y Deportes de la Junta de Comunidades de Castilla-La Mancha a través del proyecto Sistema experto colaborativo para toma de decisiones en riego de precisión en viñedo

(SBPLY/17/180501/000251). Y muy especialmente a Pedro, propietario y viticultor de la parcela, a la SAT y al resto de técnicos de campo por su implicación en el ensayo.

### **Referencias bibliográficas**

- Baggiolini, M. (1952) 'Stades repères de l'abricotier'.
- Ballesteros, R. et al. (2015) 'Characterization of *Vitis vinifera* L. Canopy Using Unmanned Aerial Vehicle-Based Remote Sensing and Photogrammetry Techniques', *American Journal of Enology and Viticulture*, 66(2), pp. 120–129. doi: 10.5344/ajev.2014.14070.
- Córcoles, J. I. et al. (2013) 'Estimation of leaf area index in onion (*Allium cepa* L.) using an unmanned aerial vehicle', *Biosystems Engineering. Academic Press*, 115(1), pp. 31–42. doi: 10.1016/J.BIOSYSTEMSENG.2013.02.002.
- Di Gennaro, S. F. et al. (2019) 'A Low-Cost and Unsupervised Image Recognition Methodology for Yield Estimation in a Vineyard', *Frontiers in Plant Science. Frontiers*, 10, p. 559. doi: 10.3389/fpls.2019.00559.
- De La Fuente, M. et al. (2015) 'Comparison of different methods of grapevine yield prediction in the time window between fruitset and veraison', *Journal International des Sciences de la Vigne et du Vin*, 49(1), pp. 27–35. doi: 10.20870/oenone.2015.49.1.96.
- López-García, P. et al. (2019) 'Utilización de drones para la cuantificación del estrés hídrico en viña', *Tierras*, 277.
- Matese, A. et al. (2015) 'Intercomparison of UAV, Aircraft and Satellite Remote Sensing Platforms for Precision Viticulture', *Remote Sensing. Multidisciplinary Digital Publishing Institute*, 7(3), pp. 2971–2990. doi: 10.3390/rs70302971.
- Santesteban, L. G. (2019) 'Precision viticulture and advanced analytics. A short review', *Food Chemistry. Elsevier*, 279, pp. 58–62. doi: 10.1016/J.FOODCHEM.2018.11.140.
- Tardaguila, J. et al. (2012) 'Mechanical yield regulation in winegrapes: comparison of early defoliation and crop thinning', *Australian Journal of Grape and Wine Research. John Wiley & Sons, Ltd (10.1111)*, 18(3), pp. 344–352. doi: 10.1111/j.1755-0238.2012.00197.x.