

Cartografía del abandono de cultivos de cítricos mediante el uso de datos altimétricos: LiDAR y fotogrametría SfM

Sergio Morell-Monzó*¹, María-T. Sebastiá-Frasquet², Javier Estornell³

¹ *Universitat Politècnica de València. EPS Gandia. C/ Paranimf, 1, 46730 Gandia, Spain.*

² *Instituto de Investigación para la Gestión Integrada de Zonas Costeras, Universitat Politècnica de València. C/ Paranimf, 1, 46730 Grau de Gandia, Spain.*

³ *Geo-Environmental Cartography and Remote Sensing Group, Universitat Politècnica de València. Camí de Vera s/n 46022 Valencia, Spain.*

Resumen: La Comunitat Valenciana (España) es el mayor productor de cítricos de Europa, sin embargo, en las últimas décadas se está produciendo un acelerado abandono de las tierras de cultivo dedicadas a la citricultura. El abandono de tierras agrícolas es un fenómeno global con relevantes implicaciones medioambientales y socio-económicas. Por este motivo es importante realizar un seguimiento de este proceso. En el caso particular de los cítricos, el pequeño tamaño de las explotaciones agrícolas, la alta fragmentación del paisaje y la baja separabilidad espectral entre las parcelas en producción y las abandonadas dificultan la detección de cultivos abandonados utilizando imágenes satelitales de resolución moderada. En este trabajo se realiza la primera aproximación a la detección de cultivos de cítricos abandonados utilizando datos altimétricos. En el estudio se utilizan dos fuentes de datos altimétricos: el LiDAR del Plan Nacional de Ortofotografía Aérea (PNOA) y los datos obtenidos mediante un sistema aéreo no tripulado aplicando procesos fotogramétricos (*Structure from Motion*). Los resultados mostraron una exactitud global del 67,9% para los datos LiDAR y un 83,6% de los datos fotogramétricos. La alta densidad de puntos de los datos fotogramétricos permitió extraer características de textura a partir de la Matriz de Co-Ocurrencia de Nivel de Gris derivadas del *Canopy Height Model*. Los resultados indican el potencial de la información altimétrica para la monitorización de los campos abandonados de cítricos, especialmente utilizando nubes de puntos de alta densidad. Investigaciones futuras deberían explorar la fusión de datos espectrales, texturales y altimétricos para el estudio de cultivos de cítricos abandonados.

Palabras clave: LiDAR, fotogrametría 3D, estado de cultivos, abandono de tierras, cítricos.

Cartography of citrus crops abandonment using altimetric data: LiDAR and SfM photogrammetry

Abstract: The Comunitat Valenciana region (Spain) is the largest citrus producer in Europe. However, it has suffered an accelerated land abandonment in recent decades. Agricultural land abandonment is a global phenomenon with environmental and socio-economic implications. The small size of the agricultural parcels, the highly fragmented landscape and the low spectral separability between productive and abandoned parcels make it difficult to

To cite this article: Morell-Monzó, S., Sebastiá-Frasquet, M.T., Estornell, J. 2022. Cartography of citrus crops abandonment using altimetric data: LiDAR and SfM photogrammetry. *Revista de Teledetección*, 59, 49-60. <https://doi.org/10.4995/raet.2021.16698>

* Corresponding author: sermomon@doctor.upv.es

detect abandoned crops using moderate resolution images. In this work, an approach is applied to monitor citrus crops using altimetric data. The study uses two sources of altimetry data: LiDAR from the National Plan for Aerial Orthophotography (PNOA) and altimetric data obtained through an unmanned aerial system applying photogrammetric processes (Structure from Motion). The results showed an overall accuracy of 67.9% for the LiDAR data and 83.6% for the photogrammetric data. The high density of points in the photogrammetric data allowed to extract texture features from the Gray Level Co-Occurrence Matrix derived from the Canopy Height Model. The results indicate the potential of altimetry information for monitoring abandoned citrus fields, especially high-density point clouds. Future research should explore the fusion of spectral, textural and altimetric data for the study of abandoned citrus crops.

Key words: LiDAR, 3D photogrammetry, crop status, land abandonment, citrus.

1. Introducción

El abandono de tierras agrícolas es un fenómeno creciente a nivel mundial con relevantes implicaciones medioambientales (ej. biodiversidad, captación de CO₂, incendios forestales, recursos hídricos, etc.) y socio-económicas (ej. producción alimentaria, sustento y paisaje) (Prishchepov, 2020). El abandono de tierras agrícolas ocurre frecuentemente en áreas montañosas y en zonas con estructuras parcelarias fragmentadas (Czesak et al., 2021). Además, según el tipo de cultivo, el contexto social y ambiental, el abandono de tierras se puede percibir como un problema o como una oportunidad (Czesak et al., 2021). Algunos de los impactos negativos que se pueden derivar del abandono de tierras están relacionados con la seguridad alimentaria, la degradación del paisaje, la proliferación de especies invasoras o la pérdida de aspectos sociales y culturales (Subedi et al., 2021). Por otra parte, pueden producirse impactos positivos como el incremento en la fijación de CO₂, la mejora de la calidad del suelo, la creación de nuevos hábitats y el aumento de la biodiversidad (Subedi et al., 2021). Sin embargo, algunos de estos impactos pueden ser tanto positivos como negativos dependiendo del contexto donde se produce el abandono de tierras (Subedi et al., 2021). Estas características hacen del abandono de tierras un fenómeno complejo que debe ser estudiado a distintas escalas (global, regional/nacional y local).

España es el mayor productor de cítricos de Europa, y la Comunitat Valenciana alberga más del 50% de la producción nacional (MAPAMA, 2020). Sin embargo, la Comunitat Valenciana es

una de las regiones donde se está produciendo un mayor abandono de tierras en las últimas décadas. Desde el año 2000 hasta el 2020 se ha producido una disminución en torno al 20% de la superficie cultivada (MAPAMA, 2020). En 2020, la superficie dedicada al cultivo de cítricos se estimaba en 159.140 ha (MAPAMA, 2020). Las causas que han propiciado el abandono de tierras son complejas, sin embargo, se podrían resumir en: a) competencia con productores extranjeros fuera de la Unión Europea, b) aparición de usos del suelo más rentables (usos urbanos), c) políticas de importación europeas desfavorables, d) ineficiencias propias del sector cítrico valenciano (Compés et al., 2019). En los próximos años se espera un aumento de las zonas abandonadas dentro y fuera de la Comunidad Valenciana debido a los cambios socio-económicos que se están produciendo en la Unión Europea (Rounsevell et al., 2006; Subedi et al., 2021).

La teledetección es una potente herramienta que nos permite observar los cambios en el uso de la tierra relacionados con el abandono de tierras agrícolas, desde un punto de vista espacial y temporal, a diferentes escalas. Los esfuerzos previos para cartografiar el abandono de tierras se han centrado en la monitorización de cultivos estacionales en grandes áreas que no requieren una resolución espacial fina. Con este fin se han utilizado series temporales MODIS y Landsat (ej. Alcantara et al., 2012; Estel et al., 2015; Löw et al., 2018; Yin et al., 2018; Grădinaru et al., 2019; Prishchepov et al., 2012; Dara et al., 2018). Las imágenes Sentinel-2 han permitido abordar el problema a una mayor resolución espacial (ej. Szostak et al., 2017), sin embargo, la monitorización de cultivos

a nivel de parcela en paisajes fragmentados sigue siendo un desafío utilizando este tipo de imágenes (Vajsová et al., 2019 y 2020; Morell-Monzó et al., 2020). Además, la monitorización de cultivos permanentes, especialmente los de hoja perenne como los cítricos, es aún más compleja debido a la baja separabilidad espectral entre las parcelas abandonadas y activas. Aunque en una parcela de cítricos abandonada generalmente se produce una pérdida de vigor en los árboles y un crecimiento de la vegetación silvestre, estas diferencias son difíciles de captar utilizando imágenes de resolución moderada. Estas circunstancias han motivado el uso de imágenes de alta resolución (sub-métricas) que permiten la extracción de texturas (Zurita-Milla et al., 2017; Neigh et al., 2018; Zhang et al., 2020) y el análisis de patrones espaciales (Gil-Yepes, et al., 2016; Recio et al., 2013). Teniendo en cuenta estos datos, Amorós-López et al. (2011) y Morell-Monzó et al. (2021) consiguieron mejorar los resultados utilizando imágenes de alta resolución para la monitorización de parcelas de cítricos. Sin embargo, hasta donde sabemos, no se ha explorado el uso de datos altimétricos para la monitorización de cultivos perennes. Sí existe una experiencia previa, los trabajos de Kolečka et al. (2015) y Czesak et al. (2021) que utilizaron datos LiDAR para cartografiar el abandono de cultivos estacionales y sucesiones forestales secundarias en zonas con paisajes altamente fragmentados.

En este trabajo se realiza una primera exploración del uso de datos altimétricos para la detección de cultivos de cítricos abandonados. El objetivo del trabajo es explorar el uso de los datos LiDAR del Plan Nacional de Ortofotografía Aérea (PNOA) y datos altimétricos utilizando un vehículo aéreo no tripulado (UAV) y generados mediante procesos fotogramétricos *Structure from Motion* (SfM) para cartografiar el estado (en producción, abandonado, no en producción) de parcelas de cítricos.

Se utilizó el algoritmo *Random Forests* (Breiman, 2001) como método de clasificación. Sin embargo, el enfoque utilizado para la extracción de características fue adaptado a la naturaleza y características de cada fuente de información. Aunque existen muchos algoritmos de aprendizaje automático que han sido usados en el campo de la teledetección, *Random Forests* se ha convertido en uno de los más utilizados (Sheykhmousa et al., 2020). Esto se debe a sus características en lo que

respecta a exactitud de clasificación, facilidad de uso (por su reducido número de hiperparámetros), robustez frente al sobreajuste (por su aprendizaje no secuencial) y buena escalabilidad frente a conjuntos de datos grandes (por su baja complejidad de tiempo de entrenamiento y la capacidad de ser paralelizado (Belgiu y Drăguț 2016; Pal, 2005)). Estas características lo han convertido en uno de los algoritmos estándar para clasificaciones supervisadas en problemas de teledetección que no requieren soluciones basadas en aprendizaje profundo o modelos de ensamble más complejos. El estudio se llevó a cabo en una zona de la comarca de La Safor (Comunitat Valenciana, España), donde se está produciendo un acelerado abandono de los cultivos de cítricos.

2. Material y métodos

2.1. Área de estudio

El área de estudio se enmarca en la comarca de La Safor, una zona costera de la Comunidad Valenciana (España). En esta zona coexisten diversos usos del suelo, como el uso urbano, forestal y agrícola, en el cual se centra este estudio. El cultivo mayoritario de esta zona son los cítricos, que ocupan más del 95% de la superficie agrícola (GVA, 2020). La superficie agrícola se ubica en la llanura costera la cual se caracteriza por su relieve plano. Esta zona destaca por suelos con una alta capacidad agronómica y una alta disponibilidad de agua que han convertido a la comarca en una zona históricamente agrícola. Sin embargo, en los últimos años se han abandonado un gran porcentaje de explotaciones agrícolas. La estructura agraria se caracteriza por el pequeño tamaño de las parcelas (promedio 0,25-0,50 ha) y la alta fragmentación del paisaje. El estudio fue realizado en una zona costera entre los municipios de Gandia y Oliva. Se tomaron datos en 12 zonas que ocupan una superficie aproximada de 1300 ha (Figura 1). Se muestrearon 12 localizaciones con el objetivo de cubrir la variabilidad ambiental de la zona.

2.2. Datos

Con el objetivo de generar información útil para la detección del abandono de cultivos de cítricos y su gestión se definió una clasificación basada en tres tipos de parcelas: no productiva (NP), productiva (PR) y abandonada (AB) como se muestra en la

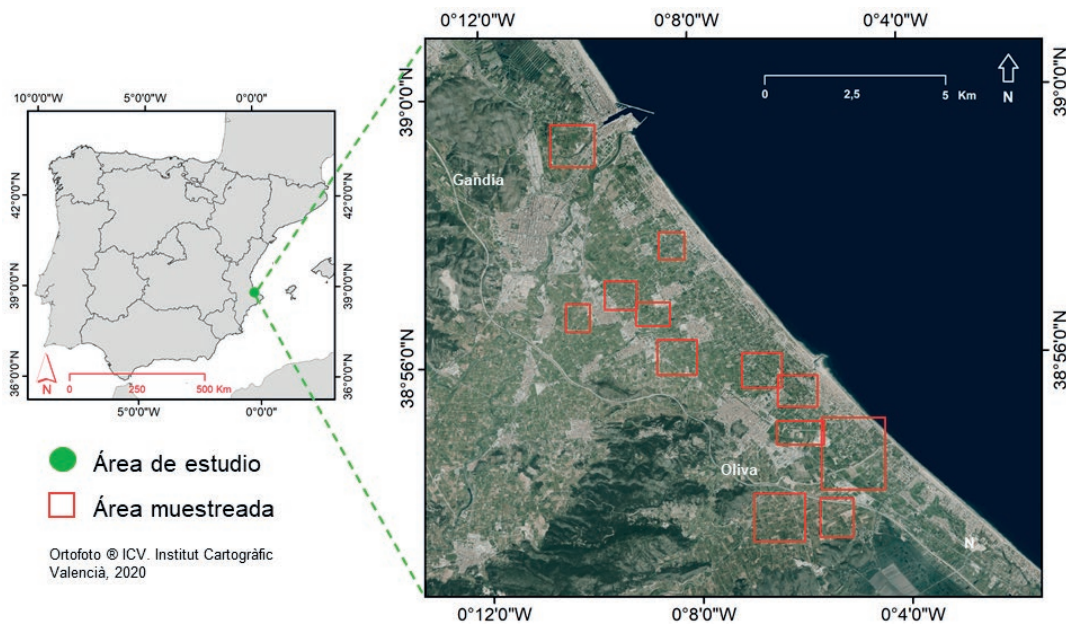


Figura 1. Área de estudio en la comarca de La Safor (Comunitat Valenciana, España).

Figura 2. La identificación de la categoría AB tiene interés para el seguimiento del abandono de los cultivos. Además, la diferenciación entre las categorías NP y PR permite realizar predicciones de producción de cítricos más precisas. Las parcelas de cítricos pueden ser identificadas a partir de la base de datos del Sistema de Información Geográfica de Parcelas Agrícolas (SIGPAC). La clasificación propuesta en este trabajo se diseñó para complementar la información de SIGPAC y ser aplicada sobre las parcelas de cítricos previamente identificadas.

Los datos verdad terreno se obtuvieron mediante campañas de campo, fotografías de drones y

fotointerpretación de ortofotos. Se clasificaron un total de 400 parcelas cítricas según la base de datos de SIGPAC; 120 de ellas fueron usadas para entrenar y validar el modelo de clasificación basado en datos LiDAR del PNOA y 280 fueron utilizadas para entrenar y validar el modelo de clasificación basado en datos altimétricos derivados de fotogrametría SfM. El conjunto de 280 parcelas fue generado mediante visitas de campo entre febrero y marzo de 2021 y revisión de fotografías tomadas por el UAV. Por otro lado, el conjunto de 120 parcelas fue generado mediante fotointerpretación sobre ortofotos de octubre de 2015. El objetivo inicial era fotointerpretar la clase para el año 2015 de las mismas parcelas



Figura 2. Clasificación utilizada: no productiva-NP (izquierda), productiva-PR (centro) y abandonada-AB (derecha).

que fueron visitadas en el campo. Sin embargo, la clasificación de las parcelas PR y AB mediante fotointerpretación no permitió conocer la clase real de todas las parcelas. Además, un conjunto significativo de parcelas había cambiado de categoría durante el periodo 2015-2021, por lo que finalmente se seleccionó un conjunto más pequeño de 120 parcelas cuya clase si se pudo asegurar mediante fotointerpretación. Los límites parcelarios se obtuvieron a partir de SIGPAC.

En relación a la nube de puntos LiDAR, se utilizaron datos del proyecto PNOA (PNOA 2015 CC BY 4.0 www.scn.es). En el marco de este proyecto se genera una cobertura LiDAR de todo el territorio español utilizando un sistema LiDAR aéreo con una frecuencia aproximada de 6 años desde el año 2009. En este estudio se utilizaron los datos de la 2ª cobertura correspondientes al año 2015. Para nuestra zona de estudio los datos LiDAR fueron tomados en octubre de 2015. Estos datos se distribuyen de forma gratuita en áreas de 2x2 km. La nube de puntos de la 2ª cobertura tiene una densidad de puntos de 0,5-4 puntos/m² y una precisión altimétrica $RMSE_z < 20$ cm. Además del valor posicional (x, y, z), los archivos incluyen los atributos de intensidad, número de retorno, cantidad de retornos, valores de clasificación, número de pasada, color RGB, tiempo GPS, ángulo y dirección de escaneo para cada punto.

La nube de puntos fotogramétrica se obtuvo a través de 12 vuelos con un UAV realizados en febrero de 2021. El vehículo no tripulado fue un senseFly eBee X que incorpora una cámara S.O.D.A. RGB 20,1MP y un sistema de posicionamiento RTK/PPK (error 3-8 cm). Los vuelos fueron realizados a una altura de 123,7 m/AED en tomas nadirales. Se tomaron un total de 5510 fotografías con un solape lateral de 60% y un solape en el sentido del vuelo de 80%. Las fotografías se procesaron utilizando la técnica SfM en Agisoft PhotoScan Professional Edition software (Agisoft LLC) version 1.2.5 build 2735. No se utilizaron puntos de control adicionales debido al sistema de posicionamiento del RTK/PPK equipado en el UAV. Se obtuvo un error de alineación <6 cm. Después se generó una nube de puntos densa (325 puntos/m²) con un total aproximado de 4723 millones de puntos ocupando un espacio de memoria de 91 Gb.

2.3. Procesamiento

La nube de puntos LiDAR con una densidad promedio 0,8 puntos/m² fue reclasificada para extraer los puntos correspondientes al suelo. Se utilizó el método *Progressive Morphological Filter* (PMF) (Zhang et al., 2003) para la identificación de los puntos correspondientes al suelo. Se probó también el método *Cloth Simulation Filter* (Zhang et al., 2016). Este método es computacionalmente más eficiente, pero proporcionó peores resultados según la interpretación visual de los resultados, por lo que se optó por el método PMF. Los puntos de suelo fueron interpolados para crear un modelo digital del terreno rasterizado con 1 m de resolución siguiendo el enfoque de k vecinos más cercanos con una ponderación de distancia inversa ($k=2$). Este método de interpolación es uno de los métodos estándar en muchas librerías de software. Después, la altura de la nube de puntos fue normalizada al suelo. Finalmente, se realizó una extracción de estadísticas descriptivas de la altura utilizando la nube de puntos y los límites parcelarios para realizar una predicción *wall-to-wall* de cada parcela. Siguiendo este enfoque basado en objetos, se extrajeron un total de 13 características de cada parcela. Las características extraídas fueron: promedio, desviación estándar, mínimo, máximo y rango de Z ; asimetría, curtosis y entropía de Z ; número de primeros retornos dividido entre el número de retornos por encima de 2 m, porcentaje de retornos sobre la Z promedio, número de primeros retornos dividido entre el número total de retornos y *Leaf Area Index* (LAD) (Bouvier et al., 2015), donde Z es altura. Las características extraídas fueron utilizadas para entrenar un modelo *Random Forests* con 200 árboles de decisión y 1/3 de las muestras como muestras *out-of-bag*. La Figura 3 muestra el flujo de trabajo para el procesamiento de los datos LiDAR.

La nube de puntos fotogramétrica con una densidad de 325 puntos/m² fue homogenizada y se redujo su densidad para reducir el tiempo de procesamiento. La homogenización se realizó a una densidad objetivo de 50 puntos/m². Después se realizó una clasificación de los puntos del suelo utilizando el mismo método aplicado para los datos LiDAR. Los puntos de suelo fueron interpolados para crear un modelo digital del terreno rasterizado con 1 m de resolución siguiendo el enfoque de k vecinos más cercanos con una ponderación de distancia

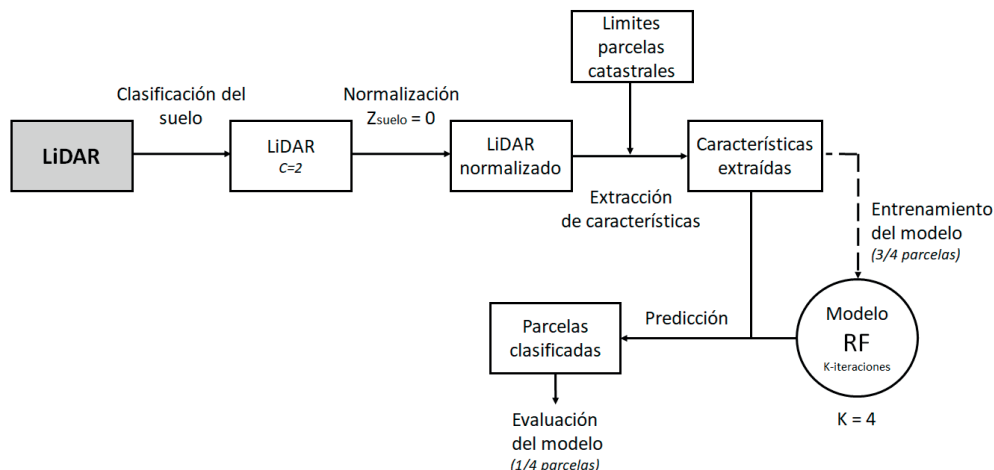


Figura 3. Flujo de trabajo para el procesamiento de los datos LiDAR.

inversa ($k=20$). Después se calculó el modelo digital de superficie utilizando el método *pit-free* (Khosravipour et al., 2014). Finalmente se calculó el *Canopy Height Model* (CHM) y 9 características a partir de la nube de puntos normalizada: promedio, desviación estándar, máximo, mínimo y rango de Z, varianza, asimetría, curtosis y entropía de Z. Adicionalmente, el CHM fue utilizado para calcular 7 características de textura basadas en la Matriz de Co-Ocurrencia de Nivel de Gris (GLCM), adaptando el enfoque propuesto en Morell-Monzó et al. (2021). Las características extraídas fueron: promedio, varianza, homogeneidad, contraste, disimilitud, entropía y segundo momento angular, que fueron calculadas a 12 tamaños de ventana distintos (3×3, 5×5, 7×7, 9×9, 11×11, 13×13, 15×15, 17×17, 19×19, 21×21, 23×23 y 25×25). Las características de textura fueron calculadas en una dirección espacial invariante, que es el promedio de las cuatro direcciones 0°, 45°, 90° y 135° a partir de una discretización del CHM a 64 niveles de gris. La discretización del CHM se realizó en intervalos uniformes entre el mínimo y el máximo. La extracción de características de textura a partir de CHM ha sido utilizada por otros autores de forma exitosa (ej. Ozdemir y Donoghue, 2013; Niemi y Vauhkonen, 2016).

Las 9 características extraídas de la nube de puntos, junto con el CHM y las 7 características de textura fueron apiladas en un fichero ráster de 1 m de resolución. Estas bandas fueron utilizadas para entrenar un modelo *Random Forests* con

200 árboles de decisión y 1/3 de las muestras como muestras *out-of-bag*. El modelo *Random Forests* permitió realizar una clasificación de los píxeles de la imagen generando una imagen segmentada semánticamente. Finalmente, los límites de las parcelas se utilizaron para mejorar la clasificación basada en píxeles utilizando el voto mayoritario de los píxeles de cada parcela. Este procedimiento crea un mapa basado en objetos donde cada objeto es una parcela (Ghorbanian et al., 2020) y mejora la precisión basada en píxeles eliminando píxeles mal clasificados, dentro de segmentos homogéneos, conocido como ruido de sal y pimienta (Wulder et al., 2018). Esta estrategia post-clasificación produjo mejoras de rendimiento en nuestros trabajos anteriores (Morell-Monzó et al., 2020; Morell-Monzó et al., 2021). La Figura 4 muestra el flujo de trabajo para el procesamiento de los datos fotogramétricos.

La lectura y procesamiento de las nubes de puntos se realizó utilizando el paquete *lidR* (Roussel y Auty, 2021). La lectura y manipulación de archivos raster y vectoriales se realizó utilizando los paquetes *raster* (Hijmans, 2021) y *rgdal* (Bivand et al., 2021) respectivamente, y la extracción de características de textura se realizó utilizando el paquete *glim* (Zvoleff, 2020) en un entorno R 3.6.1 (R Core Team, 2019).




Figura 4. Flujo de trabajo para el procesamiento de los datos fotogramétricos.

2.4. Evaluación

Se evaluó el rendimiento de clasificación para cada fuente de información utilizada (LiDAR y fotogrametría SfM). La evaluación de la precisión se realizó a través de una validación cruzada de 4 iteraciones. En cada iteración se utilizaron $\frac{3}{4}$ de las parcelas para entrenamiento y las parcelas restantes ($\frac{1}{4}$), que nunca fueron vistas por el modelo, fueron utilizadas como conjunto de test. Para la validación cruzada de los datos LiDAR, en cada iteración, se utilizaron 90 parcelas para entrenamiento y 30 para test. Para los datos derivados de fotogrametría SfM, en cada iteración, se utilizaron 210 parcelas para entrenamiento y 70 para test. Se calculó la exactitud global, índice Kappa de Cohen y métricas derivadas de la matriz de confusión (precisión y exhaustividad) utilizando el promedio de las 4 iteraciones de la validación cruzada. La exactitud global es la medida más simple y representa el número de muestras correctamente clasificadas entre el total de muestras de test. Debido a que la clasificación propuesta consta de pocas categorías, la probabilidad de acierto utilizando un modelo aleatorio es alta. Por este motivo se incluyó el índice Kappa que compara la exactitud observada con la exactitud esperada (probabilidad aleatoria). Se incluyeron también la precisión y la exhaustividad de cada clase, que corresponden a la exactitud del productor y del usuario respectivamente.

3. Resultados

Todos los modelos *Random Forests* creados convergieron antes de los 200 árboles de decisión. El hiperparámetro *mtry*, que define el número de características en cada embolsamiento, fue ajustado a 6 para el conjunto de características derivadas del LiDAR y a 5 para el conjunto de características derivadas de la nube de puntos fotogramétrica.

Los datos LiDAR obtuvieron una exactitud global de clasificación del 67,9%, con un índice Kappa de 0,52. La precisión para las parcelas NP y AB fue del 65% y del 67% respectivamente, mientras que la clase PR obtuvo una precisión del 73%. Los datos LiDAR tuvieron mayor capacidad para clasificar las parcelas PR que las parcelas NP y AB. Esto se debe a la semejanza altimétrica que hay entre las parcelas no productivas y las parcelas abandonadas con vegetación muy baja, que son frecuentes en nuestro conjunto de datos. Los valores de precisión y exhaustividad también muestran esta tendencia (Tabla 1).

Tabla 1. Rendimiento de clasificación de los datos LiDAR mediante una validación cruzada de 4 iteraciones.

LiDAR	Validación cruzada (k=4)		
	No productivo	Productivo	Abandonado
Precisión	0,6507	0,7326	0,6713
Exhaustividad	0,6750	0,7000	0,6625
Exactitud global	0,67915		
Kappa de Cohen	0,51875		

Los datos derivados de la nube de puntos fotogramétrica mostraron un rendimiento de clasificación mayor que los datos LiDAR. Se obtuvo una exactitud global máxima de 83,56%. No obstante, la exactitud global de clasificación varió dependiendo del tamaño de ventana utilizado para calcular las características de textura entre el 79,29-83,57% (Tabla 2) con un promedio de 80,89%. El refinamiento de la clasificación utilizando la votación mayoritaria dentro de cada parcela produjo una mejora del rendimiento a todos los tamaños de ventana con una mejora promedio del 1,76% (Tabla 2).

Tabla 2. Exactitud global de clasificación basada en píxeles (antes de aplicar el voto mayoritario por parcela) y basada en parcelas (después de aplicar el voto mayoritario por parcela).

GLCM kernel	Exactitud global (pixel)	Exactitud global (parcela)
3×3	0,7588	0,7929
5×5	0,7674	0,8000
7×7	0,7757	0,7929
9×9	0,7831	0,8072
11×11	0,7883	0,8286
13×13	0,7966	0,8357
15×15	0,7984	0,8143
17×17	0,8044	0,8072
19×19	0,8055	0,8072
21×21	0,8056	0,8072
23×23	0,8058	0,8072
25×25	0,8060	0,8072
<i>max:</i>	<i>0,8060</i>	<i>0,8357</i>
<i>min:</i>	<i>0,7588</i>	<i>0,7929</i>
<i>promedio:</i>	<i>0,7913</i>	<i>0,8089</i>

El mejor rendimiento se obtuvo al extraer las características de textura a un tamaño de ventana de 13×13. A este tamaño de ventana, la exactitud global de la clasificación basada en píxeles fue del 79,65% (Kappa 0,66) y el refinamiento mediante votación mayoritaria aumentó el rendimiento hasta una exactitud global de 83,57% (Kappa 0,74), con una precisión de 83,96 para la clase NP, 92,88 para la clase PR y 76,58 para la clase AB. La categoría más fácilmente detectable por esta fuente de información fue también PR. Sin embargo, las parcelas NP fueron más fácilmente detectables que las AB (Tabla 3).

Tabla 3. Rendimiento de clasificación de los datos fotogramétricos mediante una validación cruzada de 4 iteraciones.

Fotogrametría SfM	Validación cruzada (k=4)		
	No productivo	Productivo	Abandonado
Precisión	0,8396	0,9288	0,7658
Exhaustividad	0,5000	0,9658	0,8800
Exactitud global	0,8357		
Kappa de Cohen	0,7379		

A continuación, la Figura 5 muestra la predicción de los datos LiDAR para el año 2015 frente a la predicción de los datos fotogramétricos SfM para 2021. Se pueden observar diferencias entre ambas predicciones debido tanto a los cambios en los usos del suelo producidos entre 2015 y 2021 como por las diferencias de exactitud de clasificación de ambas fuentes de datos utilizadas.

4. Discusión

El estudio evaluó el uso de datos altimétricos para la detección de parcelas de cítricos abandonadas. Se evaluó el rendimiento de clasificación de tres tipos de parcelas útiles para el estudio del abandono de tierras y para la estimación de rendimientos agrícolas. Los resultados obtenidos mostraron un rendimiento de clasificación bajo para los datos LiDAR (68%), con una resolución de 0,8 puntos/m². Sin embargo, los datos altimétricos derivados de un proceso fotogramétrico SfM obtuvieron una precisión de clasificación del 83,56%. Este mejor rendimiento podría ser explicado teniendo en cuenta que, debido a la alta densidad de la nube de puntos fotogramétrica, se pudieron extraer características de textura a partir del CHM. Nuestras experiencias previas (Morell-Monzó et al., 2021) mostraron que las características de textura mejoran el rendimiento de clasificación para monitorizar parcelas de cítricos. Los datos LiDAR, con una resolución de 0,8 puntos/m², no permitieron la extracción de características de textura.

Si comparamos los resultados obtenidos con estudios anteriores, observamos las siguientes diferencias en cuanto a rendimiento. Para la detección de parcelas abandonadas de cítricos, las imágenes de alta resolución (sub-métricas) con 4 bandas espectrales (*R*, *G*, *B*, *NIR*) ofrecieron un mejor rendimiento (exactitud global: 93-95%) (Morell-Monzó et al., 2021) que ambas fuentes de información altimétrica. Sin

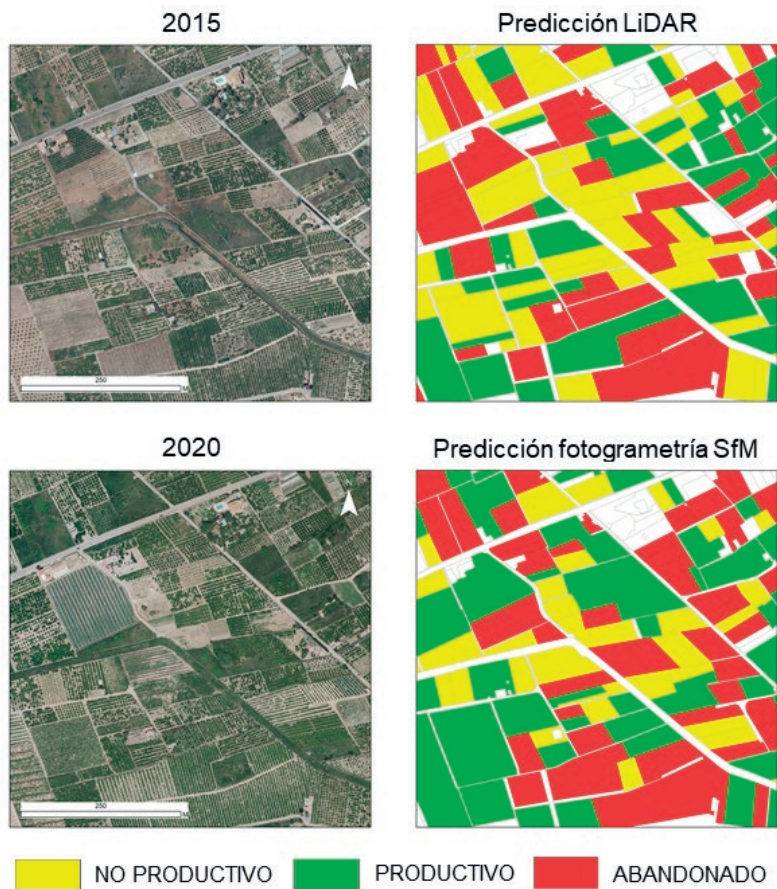


Figura 5. Detalle de predicción obtenida a partir de los datos LiDAR (2015) frente a la obtenida por los datos fotogramétricos SfM (2021).

embargo, los datos altimétricos obtenidos mediante fotogrametría mostraron un rendimiento similar a un enfoque basado en una única imagen Sentinel-2 (exactitud global: 77%) (Morell-Monzó et al., 2020). En relación con los estudios de Kolečka et al. (2015) y Czesak et al. (2021) que utilizan datos LiDAR de una resolución mayor (4-12 puntos/m²), la exactitud global para la detección del abandono de cultivos estacionales fue del 82% (Czesak et al., 2021) mientras que para la monitorización de sucesiones forestales secundarias fue del 95% (Kolečka et al., 2015). Estos mejores rendimientos pueden explicarse por la mayor densidad de puntos LiDAR utilizados en estos trabajos en comparación a los del PNOA aplicados en nuestro estudio (0,8 puntos/m²) y teniendo en cuenta que la variación que se produce en los cultivos estacionales abandonados facilita su detección frente a una cubierta de árboles frutales perennes (cítricos). Los mejores resultados

obtenidos a partir de la nube de puntos derivada por procesos fotogramétricos basados en SfM y en otros estudios en los que utilizan datos LiDAR de mayor densidad sugieren que este parámetro podría ser de interés para aportar resultados más precisos a los obtenidos con los datos LiDAR utilizados en nuestro trabajo.

5. Conclusiones

Este trabajo proporciona una de las primeras experiencias en el uso de datos altimétricos para cartografiar el abandono de tierras agrícolas de cultivos perennes. El estudio calcula el rendimiento de datos LiDAR (0,8 puntos/m²) y de datos altimétricos derivados de un proceso de fotogrametría SfM para el caso específico del abandono de cultivos de cítricos. El potencial de los datos altimétricos es especialmente notorio en el caso de las nubes

de puntos fotogramétricas *Structure from Motion* de alta densidad. Los resultados mostraron una exactitud global del 67,9% para los datos LiDAR y de un 83,6% de los datos fotogramétricos. La extracción de características de textura a partir del *Canopy Height Model* fue clave para identificar parcelas *no productivas, productivas y abandonadas*. Investigaciones futuras deberían explorar la fusión de datos espectrales, texturales y altimétricos para el estudio de parcelas de cítricos y otros cultivos perennes y analizar el rendimiento de las futuras coberturas de datos LiDAR con una mayor densidad de puntos.

Agradecimientos

Los autores agradecen los fondos recibidos para realizar este trabajo a través del proyecto de investigación “Estudio del Abandono de Tierras Utilizando Diferentes Técnicas de Teledetección” (AICO/2020/246) financiado por la Generalitat Valenciana.

Referencias

Alcantara, C., Kuemmerle, T., Prishchepov, A. V., Radeloff, V. C. 2012. Mapping abandoned agriculture with multi-temporal MODIS satellite data. *Remote Sensing of Environment*, 124, 334-347. <https://doi.org/10.1016/j.rse.2012.05.019>

Amorós-Lopez, J., Izquierdo-Verdiguier, E., Gómez-Chova, L., Muñoz-Marí, J., Rodríguez-Barreiro J. Z., Camps-Valls, G., Calpe-Maravilla, J. 2011. Land cover classification of VHR airborne images for citrus grove identification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66, 115-123. <https://doi.org/10.1016/j.isprsjprs.2010.09.008>

Belgiu, M., Drăguț L. 2016. Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24-31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>

Bivand, R., Keitt, T., Rowlingson, B. 2021. rgdal: Bindings for the ‘Geospatial’ Data Abstraction Library. R package version 1.5-23. <https://CRAN.R-project.org/package=rgdal>

Bouvier, M., Durrieu, S., Fournier, R. A., Renaud, J. 2015. Generalizing predictive models of forest inventory attributes using an area-based approach with airborne las data. *Remote Sensing of Environment*, 156, 322-334. <http://doi.org/10.1016/j.rse.2014.10.004>

Breiman, L. 2001. Random Forests. *Machine Learning*, 45, 5-32. <https://doi.org/10.1023/A:1010933404324>

Compés, R., García, J. M., Martínez, V. 2019. *La crisis citrícola en la Comunidad Valenciana y el Acuerdo de Asociación Económica con el sur de África*. Comunicación. Universitat Politècnica de València.

Czesak, B., Rózycka-Czas, R., Salata, T., Dixon-Gough, R., Hernik, J. 2021. Determining the Intangible: Detecting Land Abandonment at Local Scale. *Remote Sensing*, 13, 1166. <https://doi.org/10.3390/rs13061166>

Dara, A., Baumann, M., Kuemmerle, T., Pflugmacher, D., Rabe, A., Griffiths, P., Hölzel, N., Kamp, J., Freitag, M., Hostert, P. 2018. Mapping the timing of cropland abandonment and recultivation in northern Kazakhstan using annual Landsat time series. *Remote Sensing of Environment*, 213, 49-60. <https://doi.org/10.1016/j.rse.2018.05.005>

Estel, S., Kuemmerle, T., Alcántara, C., Levers, C., Prishchepov, A. V., Hostert, P. 2015. Mapping farmland abandonment and recultivation across Europe using MODIS NDVI time series. *Remote Sensing of Environment*, 163, 312-325. <https://doi.org/10.1016/j.rse.2015.03.028>

Generalitat Valenciana. 2020. Estadísticas agrícolas. Superficies y producción de la Comunitat Valenciana (Principales cultivos). <https://agroambient.gva.es/es/estadistiques-agricoles>

Gil-Yepes, J. L., Ruiz, L. A., Recio, J. A., Balaguer-Beser, A., Hermosilla, T. 2016. Description and validation of a new set of object-based temporal geostatistical features for land-use/land-cover change detection. *ISPRS Journal of Photogrammetry and Remote Sensing*, 121, 77-91. <https://doi.org/10.1016/j.isprsjprs.2016.08.010>

Ghorbanian, A., Kakooei, M., Amani, M., Mahdavi, S., Mohammadzadeh, A., Hasanlou, M. 2020. Improved land cover map of Iran using Sentinel imagery withing Google Earth Engine and novel automatic workflow for land cover classification using migrated training samples. *ISPRS Journal of Photogrammetry and Remote Sensing*, 167, 276-288. <https://doi.org/10.1016/j.isprsjprs.2020.07.013>

Grădinaru, S. R., Kienast, F., Psomas, A. 2019. Using multi-seasonal Landsat imagery for rapid identification of abandoned land in areas affected by urban sprawl. *Ecological Indicators*, 96(2), 79-86. <https://doi.org/10.1016/j.ecolind.2017.06.022>

Hijmans, R. H. 2021. raster: Geographic Data Analysis and Modeling. R package version 3.4-10. <https://CRAN.R-project.org/package=raster>

- Khosravipour, A., Skidmore, A. K., Isenburg, M., Wang, T., Hussin, Y. A. 2014. Generating pitfree canopy height models from airborne Lidar. *Photogrammetric Engineering & Remote Sensing*, 80(9), 863-872. <https://doi.org/10.14358/PERS.80.9.863>
- Kolecka, N., Kozak, J., Kaim, D., Dobosz, M., Ginzler, C., Psomas, A. 2015. Mapping Secondary Forest Succession on Abandoned Agricultural Land with LiDAR Point Clouds and Terrestrial Photography. *Remote Sensing*, 7(7), 8300-8322. <https://doi.org/10.3390/rs70708300>
- Löw, F., Prishchepov, F., Waldner, F., Dubovyk, O., Akramkhanov, A., Biradar, C., Lamers, J. 2018. Mapping Cropland Abandonment in the Aral Sea Basin with MODIS Time Series. *Remote Sensing*, 10(2), 159. <https://doi.org/10.3390/rs10020159>
- Ministerio de Agricultura y Pesca, Alimentación y Medio Ambiente. 2020. ESYRCE: Encuesta Sobre Superficies y Rendimientos del año 2019; Ministerio de Agricultura y Pesca, Alimentación y Medio Ambiente: Madrid, Spain, 2020. <https://www.mapa.gob.es/es/estadistica/temas/estadisticas-agrarias/agricultura/esyrce/>
- Morell-Monzó, S., Estornell, J., Sebastián-Frasquet, M.-T. 2020. Comparison of Sentinel-2 and High-Resolution Imagery for Mapping Land Abandonment in Fragmented Areas. *Remote Sensing*, 12(12), 2062. <https://doi.org/10.3390/rs12122062>
- Morell-Monzó, S., Sebastián-Frasquet, M.T., Estornell, J. 2021. Land Use Classification of VHR Images for Mapping Small-Sized Abandoned Citrus Plots by Using Spectral and Textural Information. *Remote Sensing*, 13(4), 681. <https://doi.org/10.3390/rs13040681>
- Neigh, C. S. R., Carroll, M. L., Wooten, M. R., McCarty, J. L., Powell, B. F., Husak, G. J., Enenkel, M., Hain C. R. 2018. Smallholder crop area mapped with wall-to-wall WorldView sub-meter panchromatic image texture: A test case for Tigray, Ethiopia. *Remote Sensing of Environment*, 212, 8-20. <https://doi.org/10.1016/j.rse.2018.04.025>
- Niemi, M. T., Vauhkonen, J. 2016. Extracting Canopy Surface Texture from Airborne Laser Scanning Data for the Supervised and Unsupervised Prediction of Area-Based Forest Characteristics. *Remote Sensing*, 8(7), 582. <https://doi.org/10.3390/rs8070582>
- Ozdemir, I., Donoghue D. N. M. 2013. Modelling tree size diversity from airborne laser scanning using canopy height models with image texture measures. *Forest, Ecology and Management*, 295, 28-37. <https://doi.org/10.1016/j.foreco.2012.12.044>
- Pal, M. 2005. Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, 26(1), 217-222. <https://doi.org/10.1080/01431160412331269698>
- Prishchepov, A.V. 2020. *Agricultural Land Abandonment*. Oxford Bibliographies Environmental Science. Oxford University Press., <https://doi.org/10.1093/obo/9780199363445-0129>
- Prishchepov, A.V., Radeloff, V.C., Dubinin, M., Alcantara, C. 2012. The effect of Landsat ETM/ETM image acquisition dates on the detection of agricultural land abandonment in Eastern Europe. *Remote Sensing of Environment*, 126, 195-209. <https://doi.org/10.1016/j.rse.2012.08.017>
- R Core Team. 2019. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.
- Recio, J. A., Hermosilla, T., Ruiz, L. A., Palomar, J. 2013. Automated extraction of tree and plot-based parameters in citrus orchards from aerial images. *Computer and Electronics in Agriculture*, 90, 24-34. <https://doi.org/10.1016/j.compag.2012.10.005>
- Rounsevell, M. D. A., Reginster, I., Araújo, M. B., Carter, T. R., Dendoncker, N., Ewert, F., House, J. I., Kankaanpää, S., Leemans, R., Metzger, M. J. 2006. A coherent set of future land use change scenarios for Europe. *Agriculture Ecosystems and Environment*, 114, 57-68. <https://doi.org/10.1016/j.agee.2005.11.027>
- Roussel, J. R., Auty D. 2021. Airborne LiDAR Data Manipulation and Visualization for Forestry Applications. R package version 3.1.2. <https://cran.rproject.org/package=lidR>
- Sheykhmousa, M., Mahdianpari, M., Ghanbari, H., Mohammadimanes, F., Ghamisi, P., Homayouni, S. 2020. Support Vector Machine versus Random Forest for Remote Sensing Image Classification: A Meta-Analysis and Systematic Review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 6308-6325. <https://doi.org/10.1109/JSTARS.2020.3026724>
- Subedi, Y. R., Kristiansen, P., Cacho, O. 2021. Drivers and consequences of agricultural land abandonment and its reutilisation pathways: A systematic review. *Environmental Development*, (in press). <https://doi.org/10.1016/j.envdev.2021.100681>
- Szostak, M., Hawryło, P., Piela, D. 2017. Using of Sentinel-2 images for automation of the forest succession detection. *European Journal of Remote Sensing*, 51, 142-149. <https://doi.org/10.1080/22797254.2017.1412272>

- Vajsová, B., Fasbender, D., Wirnhardt, C., Lemajic, S. 2019. *Applicability limits of Sentinel-2 data compared to higher resolution imagery for CAP checks by monitoring*, Sima, A. and Aastrand, P. editor(s), EUR 29721 EN, Publications Office of the European Union, Ispra, 2019, ISBN 978-92-76-01935-0, <https://doi.org/10.2760/26277>, JRC115564.
- Vajsová, B., Fasbender, D., Wirnhardt, C., Lemajic, S., Devos, W., 2020. Assessing Spatial Limits of Sentinel-2 Data on Arable Crops in the Context of Checks by Monitoring. *Remote Sensing*, 12(14), 2195. <https://doi.org/10.3390/rs12142195>
- Wulder, M. A., Coops, N.C., Roy, D.P., White, J.C., Hermosilla, T. 2018. Land cover 2.0. *International Journal of Remote Sensing*, 39, 4254-4284. <https://doi.org/10.1080/01431161.2018.1452075>
- Yin, H., Prishchepov, A. V., Kuemmerle, T., Bleyhl, B., Buchner, J., Radeloff, V. C. 2018. Mapping agricultural land abandonment from spatial and temporal segmentation of Landsat time series. *Remote Sensing of Environment*, 210, 12-24. <https://doi.org/10.1016/j.rse.2018.02.050>
- Zhang, K., Chen, S. C., Whitman, D., Shyu, M. L., Yan, J., Zhang, C. 2003. A progressive morphological filter for removing nonground measurements from airborne LIDAR data. *IEEE Transactions on Geoscience and Remote Sensing*, 41(4 PART I), 872-882. <http://doi.org/10.1109/TGRS.2003.810682>
- Zhang, P., Hu, S., Li, W., Zhang, C. 2020. Parcel-level mapping of crops in smallholder agricultural area: A case study of central China using single-temporal VHRS imagery. *Computer and Electronics in Agriculture*, 175, 105581. <https://doi.org/10.1016/j.compag.2020.105581>
- Zhang, W., Qi, J., Wan, P., Wang, H., Xie, D., Wang, X., Yan, G. 2016. An Easy-to-Use Airborne LiDAR Data Filtering Method Based on Cloth Simulation. *Remote Sensing*, 8(6), 501. <https://doi.org/10.3390/rs8060501>
- Zurita-Milla, R., Izquierdo-Verdiguier, E., de By, R.A. 2017. Identifying crops in smallholder farms using time series of WorldView-2 images. *9th International Workshop on the Analysis of Multitemporal Remote Sensing Images (MultiTemp)*. <https://doi.org/10.1109/Multi-Temp.2017.8035246>
- Zvoleff, A. 2020. glcm: Calculate Textures from Grey-Level Co-Occurrence Matrices (GLCMs). R package version 1.6.5. <https://CRAN.R-project.org/package=glcm>