



2022
Lleida

27 · 1
junio · juny
julio · juliol

Cataluña
Catalunya

8º CONGRESO FORESTAL ESPAÑOL

La **Ciencia forestal** y su contribución a
los **Objetivos de Desarrollo Sostenible**

8CFE

Edita: Sociedad Española de Ciencias Forestales

Cataluña | Catalunya · 27 junio | juny - 1 julio | juliol 2022

ISBN 978-84-941695-6-4

© Sociedad Española de Ciencias Forestales



Organiza

föco: visión artificial para la detección de zonas con riesgo de incendios en la interfaz urbano forestal

RODRÍGUEZ-PUERTA, F.^{1, 2}, MARTÍNEZ, R.^{2,3}, ORTEGA, C.⁴, ÁGUEDA-HERNÁNDEZ, B.^{1,2,3}, PÉREZ-RODRÍGUEZ, F.³, LIZARRALDE, I.^{2,3} y ALONSO, R.^{2,3}

¹ EiFAB Universidad de Valladolid – Campus de Soria

² Instituto Universitario de Investigación Gestión Forestal Sostenible iuFOR

³ föra forest technologies, SLL.

⁴ AEROMEDIA SLU

Resumen

föco es un gemelo digital que utiliza Inteligencia Artificial y datos remotos para detectar zonas de riesgo de incendios en la interfaz urbano-forestal. A partir de mosaicos estacionales sin nubes de datos satelitales (Sentinel-2) y de datos capturados con dron (ortofoto y datos LiDAR), se ofrece una solución tecnológica sencilla, actualizada, rápida y de amplia cobertura.

föco analiza toda la información remota existente de la siguiente manera: (i) Primero procesa el LIDAR de dron con una resolución espacial de 50cm, (ii) después realiza una segmentación basada en el modelo de altura de vegetación y en la ortofoto del dron, (iii) a continuación, calcula los estadísticos zonales de todas las variables remotas para cada segmento, (iv) después, construye la base de datos, y entrena algoritmos basados en Inteligencia Artificial al sistema, a partir de verdad terreno adquirida in situ, para finalmente (v) aplicar dichos algoritmos y crear un mapa de vegetación a nivel segmento. Una vez creados esos mapas, sobre cada segmento se aplican las normas vigentes de actuaciones en fajas contra incendios en el interfaz urbano forestal, basadas en el tipo de vegetación, su altura y su cobertura. Estas normas acostumbran a estar definidas en cada región. El resultado final se intersecta con la información catastral, de tal forma que cada propietario forestal puede recibir indicaciones de las actuaciones que debe realizar para incrementar su seguridad frente a incendios forestales.

Palabras clave

Interfaz, Sentinel-2, LiDAR, dron, Incendios.

1. Introducción

Desde la década de 1950 se ha producido un fenómeno mundial de migración del campo a la ciudad, principalmente en los países desarrollados, que ha provocado profundos cambios en el uso del suelo causados por el abandono rural (Hoggart and Paniagua 2001). Aunque el alcance y los efectos de estos cambios en los paisajes rurales varían significativamente según las regiones, en la cuenca mediterránea una de las consecuencias negativas es el aumento y la intensidad de los incendios forestales debido a la invasión de matorrales y bosques jóvenes en antiguas tierras de cultivo y pastos (Benayas et al. 2007)

Las fajas contra incendios en la Interfaz Urbano Forestal (IUF) consisten en la aplicación de cambios en las características del combustible en las zonas adyacentes a las viviendas y comunidades con el fin de reducir el riesgo de incendios forestales y crear zonas seguras para la lucha contra el fuego (Radeloff et al. 2005; Rigolot et al. 2022). Normalmente, se recomienda reducir la carga de combustible superficial a través de cortas con el objetivo de reducir la cobertura arbórea y de podas para aumentar la altura de la base de la copa (Ascoli et al. 2018).

La teledetección ha sido ampliamente utilizada para estimar estas variables de combustible de la superficie y del dosel (González-Olabarria et al. 2012; González-Ferreiro et al. 2014). La combinación de la información LiDAR con las imágenes multispectrales proporciona una poderosa herramienta para clasificar bosques con cobertura completa (Zhu et al. 2017). Sin embargo, la cobertura temporal y espacial con sensores aerotransportados está limitada por el coste de adquisición, lo que dificulta el análisis de la dinámica del combustible, haciendo que el análisis se centre en extensiones geográficas pequeñas. En este caso, los datos de los satélites ópticos constituyen una fuente alternativa rentable, ya que pueden ofrecer una cobertura espacial completa y una resolución temporal adecuada para actualizar los mapas de combustible.

De la amplia gama de algoritmos de Aprendizaje Automático utilizados para encontrar las reglas de clasificación de objetos en las ciencias forestales, el algoritmo *Random Forest* (RF) ha mostrado altos índices de precisión. No obstante, los algoritmos de *Support Vector Machine*, tanto *Lineales* como *Radiales* (SVML, SVMR) y las *Redes Neuronales Artificiales* (RNA) son cada vez más tenidos en cuenta en este ámbito (Nitze et al. 2012; Valbuena et al. 2016; Vega Isuhuaylas et al. 2018). Todos estos algoritmos han sido ampliamente utilizados en estudios forestales (Linderman et al. 2004; Charalabos and Keramitsoglou 2012; Doktor et al. 2014; Burai et al. 2015).

2. Objetivos

Partiendo de la hipótesis inicial de que los vehículos aéreos no tripulados podrían utilizarse para identificar las zonas de actuación en los cortafuegos y las zonas de Interfaz Urbano Forestal, el objetivo general de este trabajo es probar el rendimiento de los datos combinados de teledetección pasiva y activa para predecir los tipos de vegetación mediante algoritmos de aprendizaje automático. Para ello se han hecho competir los cuatro principales algoritmos de *Machine Learning* (RF, SVML, SVMR y ANN) sobre una clasificación basada en objetos.

3. Metodología

El área de estudio se situó en Porto do Son (Galicia). Este municipio engloba un conjunto de localidades costeras y pueblos dispersos del interior (**Figura 1**). El área de interés correspondía a 370 ha. En la **figura 2** se muestra una visión general de todos los materiales y métodos utilizados.

Los datos del UAV-LiDAR se obtuvieron en julio de 2019 a través de un sistema LiDAR integrado en un dron DJI M600 Pro y un sensor LiDAR Velodyne Ultra Puck capaz de capturar 600.000 pulsos de doble retorno por segundo, con un alcance máximo del láser de 220 m. El sistema integraba también un receptor GNSS de doble frecuencia L1/L2 para generar trayectorias cinemáticas de posprocesamiento (PPK). La altura de vuelo fue de 55 m sobre el suelo a una velocidad de 4 m/s y a una distancia horizontal aproximada entre las líneas de vuelo adyacentes de 15 m (solapamiento del 90%), produciendo una nube de puntos LiDAR de muy alta densidad (140 puntos·m⁻²).

El flujo de trabajo de procesamiento LiDAR tuvo dos etapas. En primer lugar, se utilizó el entorno *LASTools* (software rapidlasso) para preprocesar los datos brutos en cuatro tareas: i) se generaron un total de 586 *tiles* de 200x200m utilizando *lastile*; ii) se depuraron estos *tiles* para eliminar el ruido y los datos duplicados utilizando *lasduplicate* y *lasnoise*; iii) se clasificó el suelo usando el comando *lasground_new*; y iv) se utilizó *lasclassify* para discriminar entre edificios y vegetación. La segunda etapa se ejecutó a través del software *easyLaz*® (föra forest technologies), una herramienta propia basada en el software *FUSION/ LDV* (McGaughey 2012). Se generó un modelo digital del terreno (MDT), un modelo digital de superficie (MDS) y un modelo de altura de la vegetación (MDAV) con una resolución espacial de 50cm. Se calcularon las métricas de la nube de

puntos con una resolución de 1m, y por último, se contabilizó el porcentaje de retornos en cada capa de 1 metro de altura.

Como fuente de datos multiespectral, se utilizaron las imágenes del programa ESA-Copernicus del satélite Sentinel-2 (con una resolución de 10 m y 20 m). Se usaron imágenes libres de nubes de los meses de febrero, mayo, agosto y noviembre de 2017, 2018 y 2019 para caracterizar la diferente fenología. Se sintetizó su información a través de cuatro de los principales índices; Índice de Vegetación de Diferencia Normalizada (NDVI), Índice de Vegetación de Diferencia Normalizada Verde (GNDVI), Índice de Vegetación Ajustado al Suelo (SAVI) e Índice de Vegetación Mejorado (EVI) (Kyratzis et al. 2017).

Se utilizó un enfoque de clasificación basado en objetos a partir de la segmentación de la imagen, creando imágenes-objeto que representan entidades significativas (por ejemplo, tejados) mediante la agrupación de píxeles adyacentes con características similares (Cleve et al. 2008). Para definir la segmentación de objetos utilizamos el paquete de software *eCognition* (Trimble Geospatial Imaging) (Blaschke et al. 2014). El proceso de segmentación se basó en parametrizar la escala, la forma, el criterio espectral de homogeneidad y la relación de compacidad.

Para clasificar el tipo de vegetación se llevó a cabo una clasificación no supervisada basada en técnicas de *Machine Learning*. Como paso previo se llevó a cabo una selección de variables a través del comando VSURF (Genuer et al. 2015). Se entrenaron los diferentes algoritmos y para poderlos comparar entre ellos (RF, SVM, SVML, SVMR y ANN), se utilizó el paquete *caret* del software R utilizando los métodos *rf*, *svmLinear*, *svmRadial* y *nnet* (Max 2008). Finalmente, para limitar el problema de sobreajuste, se redujo la muestra mediante la técnica de validación cruzada utilizando 10 juegos con tres réplicas cada uno.

Finalmente, una vez clasificada la vegetación y conociendo las distintas métricas de cada objeto/segmento, se aplicaron las normas vigentes en Galicia (España) sobre mantenimiento de zonas de interfaz urbano-forestal (Ley 7/2012, de 28 de junio, de montes de Galicia, <https://www.boe.es/eli/es-ga/l/2012/06/28/7>). Estas normas se basan en el hecho de que el bosque típico gallego estaba formado principalmente por especies como el roble (*Quercus robur* L.), el castaño (*Castanea sativa* Mill.) y el pino marítimo (*Pinus pinaster* Ait.), pero estas formaciones se han visto muy reducidas a lo largo de los siglos en favor de los pastos, las tierras agrícolas y los matorrales. Así, en estas normas se definen cinco clases de verdad vegetación: Clase 1: Sin vegetación; Clase 2: Cultivos; Clase 3: Arbustos y hierbas; Clase 41: Árboles permitidos (roble, castaño...), y Clase 42: Árboles prohibidos (eucalipto, pino marítimo y acacias). Para poder entrenar los algoritmos se tomó verdad terreno en diferentes objetos, sumando un total de 434 segmentos distribuidos por todas las clases (Clase 1: 86 segmentos; Clase 2: 77 segmentos; Clase 3: 71 segmentos; Clase 41: 82 segmentos; y Clase 42: 118 segmentos). La **figura 3** muestra el esquema de las reglas relativas a la clase de verdad del terreno, la altura de la vegetación, la fracción de cabida cubierta y el tratamiento a aplicar.

4. Resultados

En lo que respecta a la segmentación con *eCognition*, se utilizó el método de segmentación multiescala basado en el enfoque de evolución de redes fractales (FNEA), teniendo en cuenta las características espectrales y la forma de la unidad de segmentación. En este caso, uno de los parámetros más importantes es el de la escala. Se utilizaron tres parámetros de escala (5, 10 y 15) para caracterizar las diferentes zonas de vegetación. La **figura 4** muestra gráficamente los resultados de la segmentación obtenida. El mejor resultado se obtuvo con un parámetro de escala de 15. Estos segmentos fueron suficientemente grandes para integrar la información de los índices de Sentinel-2 (10x10 m).

En cuanto a la clasificación, a partir de los resultados de la validación cruzada, la mayoría de los modelos alcanzaron una precisión media cercana a 0,90 (**Tabla 1**), excepto el algoritmo ANN. RF se confirmó como el método más preciso, mientras que ANN presentó el valor de precisión más bajo. SVMR y SVML obtuvieron valores de precisión intermedios de 0,8716 y 0,8674 respectivamente. Al mismo tiempo, los valores Kappa no variaron respecto a los valores de precisión obtenidos. En la validación cruzada (**Tabla 2**), los peores resultados se obtuvieron en la identificación de las especies prohibidas. La distribución del área final obtenida tras la generalización del modelo entrenado a toda el área de interés se resume en la **Tabla 3**.

Los resultados de la clasificación son espacialmente explícitos, permitiendo no sólo planificar antes de cualquier exploración de campo cuántos de los recursos alcanzables desplegar, sino también dónde hacerlo (**Figura 5**), lo que a su vez haría factible la aplicación de procedimientos de optimización (Chen et al. 2020).

5. Discusión

La clasificación por aprendizaje automático es una herramienta adecuada para realizar clasificaciones de usos del suelo y para la planificación las actuaciones sobre el interfaz urbano-forestal. Nuestro trabajo demuestra que, aunque todos los algoritmos evaluados son muy precisos, *RF* es el que mejor resultados nos ha proporcionado. Más del 90% de los segmentos clasificados (clases 1, 2, 3, 41 y 42) obtienen resultados correctos, a pesar del tamaño relativamente pequeño de la muestra de la verdad sobre el terreno con la que se ha entrenado el modelo. La precisión de estos algoritmos ha sido evaluada anteriormente en varios estudios y, en particular, para el análisis de la vegetación, algunos de ellos lograron resultados relevantes utilizando UAVs combinados con otros datos de teledetección (Maxwell et al. 2018; Pham et al. 2019; Prado Osco et al. 2019). Por ejemplo, (R. Valbuena et al. 2016) encontró que el mejor algoritmo de aprendizaje automático para determinar las etapas de desarrollo del bosque mediterráneo son la *RF* y la *ANN*, y (Vega Isuhuaylas et al. 2018) tuvo éxito con la *SVM* y la *RF* en la clasificación de los bosques de montaña. También se utilizaron algoritmos como *RF* para identificar especies en un entorno tropical con datos multitemporales e hiperespectrales adquiridos con una plataforma UAV (Miyoshi et al. 2020). Otro estudio investigó el uso integrado de datos LiDAR e hiperespectrales con los algoritmos mencionados para clasificar especies arbóreas en un bosque mixto de coníferas y frondosas en Maine, EE.UU (Marrs and Ni-Meister 2019). Los niveles de precisión obtenidos en las clasificaciones del presente estudio son consistentes con los alcanzados en todos estos estudios anteriores. Aunque las diferencias entre los errores de precisión pueden no parecer significativas a primera vista, tales diferencias son de crucial importancia cuando se trabaja a gran escala, y los errores pueden ser mayores cuando se clasifican áreas más grandes con más tipos de objetos. Por lo tanto, el rendimiento de los distintos algoritmos debe probarse en cada análisis de clasificación, ya que su comportamiento puede cambiar en gran medida en función de las características, el tamaño y la variedad de los tipos de objetos incluidos en el área de estudio. Finalmente, todas estas investigaciones demuestran el potencial y la eficacia de la inteligencia artificial para tratar este tipo de datos

Las implicaciones prácticas del uso de las técnicas de clasificación para la ordenación del territorio a gran escala, y en particular para los costosos y largos procesos que suele conllevar la gestión de los combustibles, saltan a la vista al examinar las cifras de la **tabla 3**. Casi la mitad de la zona de interés estudiada aquí se clasifica como zona de "no actuación", lo que implica unas consecuencias económicas claras respecto a la inspección visual del terreno. Además, estos datos permiten calibrar adecuadamente los recursos humanos y de maquinaria necesarios para realizar la cantidad de fajas auxiliares de la forma más eficiente. Además, como la clasificación obtenida es espacialmente explícita, permite planificar cuántos recursos hay que desplegar antes de realizar

cualquier exploración de campo, y, lo que es igualmente importante, dónde hay que hacerlo (**Figura 5**). Esta continuidad espacial permite, a su vez, la aplicación de procedimientos de optimización (Chen et al. 2020). En este sentido, el uso de MDT y MDS de muy alta resolución, derivados de los datos UAV-LiDAR, permite identificar áreas con pendientes pronunciadas y vallas de piedra u otros obstáculos para la maquinaria, lo que es crucial para una solución óptima de distribución de recursos.

6. Conclusiones

La utilización de drones para identificar las áreas susceptibles de fajas cortafuegos en zonas de interfaz proporciona mayor precisión al combinar dicha información con los datos de teledetección pasiva y activa. Esto permite predecir los tipos de vegetación y las actuaciones a realizar a través de algoritmos de aprendizaje automático.

En este estudio, hemos demostrado que los vehículos aéreos no tripulados son herramientas adecuadas para proporcionar datos precisos y operativos para identificar las áreas de actuación en zonas de interfaz urbano-forestal. Cuando los unimos con otros datos procedentes de sensores remotos a gran escala, obtenemos mejores resultados. En nuestro caso, al unirlos con datos del satélite Sentinel-2, y utilizando algoritmos de RF, obtuvimos una precisión, al clasificar los usos del suelo, cercana a 0,9. La predicción precisa del tipo de vegetación permite identificar las actuaciones a realizar y definir adecuadamente los recursos humanos y la maquinaria necesaria para llevar a cabo las labores de reducción del combustible en el interfaz urbano-forestal. Nuestros resultados apoyan el papel esencial de los UAVs en la planificación y gestión del combustible forestal y, por tanto, en la prevención de los incendios forestales y la reducción de los daños en las infraestructuras humanas.

7. Agradecimientos

Los datos del dron fueron proporcionados por AEROMEDIA UAV, S.L. Las ortofotos y los datos LIDAR de baja resolución fueron proporcionados por el CNIG-PNOA. Las imágenes de Sentinel fueron suministradas por la ESA (Agencia Espacial Europea).

8. Bibliografía

ASCOLI D, RUSSO L, GIANNINO F, SIETTOS C, MOREIRA F. 2018. Firebreak and Fuelbreak. https://doi.org/10.1007/978-3-319-51727-8_70-1

BENAYAS J, MARTINS A, NICOLAU J, SCHULZ J. 2007. Abandonment of agricultural land: An overview of drivers and consequences. *CAB Reviews Perspectives in Agriculture Veterinary Science Nutrition and Natural Resources*. 2. <https://doi.org/10.1079/PAVSNNR20072057>

BLASCHKE T, HAY GJ, KELLY M, LANG S, HOFMANN P, ADDINK E, QUEIROZ FEITOSA R, VAN DER MEER F, VAN DER WERFF H, VAN COILLIE F, TIEDE D. 2014. Geographic Object-Based Image Analysis – Towards a new paradigm. *ISPRS Journal of Photogrammetry and Remote Sensing*. 87:180–191. <https://doi.org/10.1016/j.isprsjprs.2013.09.014>

BURAI P, DEÁK B, VALKÓ O, TOMOR T. 2015. Classification of Herbaceous Vegetation Using Airborne Hyperspectral Imagery. *Remote Sensing*. 7(2). <https://doi.org/10.3390/rs70202046>

CHARALABOS K, KERAMITSOGLU I. 2012. Land Use/Cover Mapping With Emphasis to Burnt Area Delineation Using Co-Orbital ALI and Landsat TM Imagery. *International Journal of Applied Earth Observation and Geoinformation*. 18:344–355. <https://doi.org/10.1016/j.jag.2012.02.004>

CHEN C, GAN J, ZHANG Z, QIU R. 2020. Multi-objective and multi-period optimization of regional timber supply network with uncertainty. *Canadian Journal of Forest Research*. 50:203–214. <https://doi.org/10.1139/cjfr-2018-0551>

CLEVE C, KELLY M, KEARNS FR, MORITZ M. 2008. Classification of the wildland–urban interface: A comparison of pixel- and object-based classifications using high-resolution aerial photography. *Computers, Environment and Urban Systems*. 32(4):317–326. <https://doi.org/10.1016/j.compenvurbsys.2007.10.001>

DOKTOR D, LAUSCH A, SPENGLER D, THURNER M. 2014. Extraction of Plant Physiological Status from Hyperspectral Signatures Using Machine Learning Methods. *Remote Sensing*. 6(12). <https://doi.org/10.3390/rs61212247>

GENUER R, POGGI J-M, TULEAU-MALOT C. 2015. VSURF: An R package for variable selection using random forests. *The R Journal*. 7. <https://doi.org/10.32614/RJ-2015-018>

GONZÁLEZ-FERREIRO E, DIÉGUEZ-ARANDA U, CRECENTE-CAMPO F, BARREIRO-FERNÁNDEZ L, MIRANDA D, CASTEDO-DORADO F. 2014. Modelling canopy fuel variables for *Pinus radiata* D. Don in NW Spain with low-density LiDAR data. *International journal of wildland fire*. 23(3):350–362.

GONZÁLEZ-OLABARRIA J-R, RODRÍGUEZ F, FERNÁNDEZ-LANDA A, MOLA-YUDEGO B. 2012. Mapping fire risk in the Model Forest of Urbión (Spain) based on airborne LiDAR measurements. *Forest Ecology and Management*. 282:149–156. <https://doi.org/10.1016/j.foreco.2012.06.056>

HOGGART K, PANIAGUA A. 2001. The Restructuring of Rural Spain? *Journal of Rural Studies*. 17:63–80. [https://doi.org/10.1016/S0743-0167\(00\)00037-1](https://doi.org/10.1016/S0743-0167(00)00037-1)

KYRATZIS AC, SKARLATOS DP, MENEXES GC, VAMVAKOUSIS VF, KATSIOTIS A. 2017. Assessment of Vegetation Indices Derived by UAV Imagery for Durum Wheat Phenotyping under a Water Limited and Heat Stressed Mediterranean Environment. *Frontiers in Plant Science*. 8:1114. <https://doi.org/10.3389/fpls.2017.01114>

LINDERMAN M, LIU J, QI J, AN L, OUYANG Z, YANG J, TAN Y. 2004. Using artificial neural networks to map the spatial distribution of understorey bamboo from remote sensing data. *International Journal of Remote Sensing*. 25(9):1685–1700. <https://doi.org/10.1080/01431160310001598971>

MARRS J, NI-MEISTER W. 2019. Machine Learning Techniques for Tree Species Classification Using Co-Registered LiDAR and Hyperspectral Data. *Remote Sensing*. 11(7). <https://doi.org/10.3390/rs11070819>

MAX K. 2008. Building Predictive Models in R Using the caret Package. *Journal of Statistical Software*. 28. <https://doi.org/10.18637/jss.v028.i05>

MAXWELL AE, WARNER TA, FANG F. 2018. Implementation of machine-learning classification in remote sensing: an applied review. *International Journal of Remote Sensing* 39(9):2784–2817. <https://doi.org/10.1080/01431161.2018.1433343>

MCGAUGHEY RJ. 2012. FUSION/LDV: Software for LiDAR data analysis and visualization, Version 3.01. US Department of Agriculture, Forest Service, Pacific Northwest Research Station, University of Washington: Seattle, WA, USA.

MIYOSHI GT, ARRUDA MD, OSCO LP, MARCATO JUNIOR J, GONÇALVES DN, IMAI NN, TOMMASELLI AM, HONKAVAARA E, GONÇALVES WN. 2020. A Novel Deep Learning Method to Identify Single Tree Species in UAV-Based Hyperspectral Images. *Remote Sensing*. 12(8). <https://doi.org/10.3390/rs12081294>

NITZE I, SCHULTHESS U, ASCHE H. 2012. Comparison of machine learning algorithms random forest, artificial neural network and support vector machine to maximum likelihood for supervised crop type classification. *Proceedings of the 4th GEOBIA*, May 7-9, 2012 - Rio de Janeiro - Brazil. p.035.

PHAM TD, YOKOYA N, BUI DT, YOSHINO K, FRIESS DA. 2019. Remote Sensing Approaches for Monitoring Mangrove Species, Structure, and Biomass: Opportunities and Challenges. *Remote Sensing*. 11(3). <https://doi.org/10.3390/rs11030230>

PRADO OSCO L, MARQUES RAMOS AP, ROBERTO PEREIRA D, AKEMI SAITO MORIYA É, NOBUHIRO IMAI N, TAKASHI MATSUBARA E, ESTRABIS N, DE SOUZA M, MARCATO JUNIOR J, GONÇALVES WN, ET AL. 2019. Predicting Canopy Nitrogen Content in Citrus-Trees Using Random Forest Algorithm Associated to Spectral Vegetation Indices from UAV-Imagery. *Remote Sensing*. 11(24). <https://doi.org/10.3390/rs11242925>

RADELOFF VC, HAMMER RB, STEWART SI, FRIED JS, HOLCOMB SS, MCKEEFRY JF. 2005. THE WILDLAND–URBAN INTERFACE IN THE UNITED STATES. *Ecological Applications*. 15(3):799–805. <https://doi.org/10.1890/04-1413>

RIGOLOT E, CASTELLI L, COHEN M, COSTA M, DUCHÉ Y. 2022. Recommendations for fuel-break design and fuel management at the Wildland Urban Interface: an empirical approach in South Eastern France.

VALBUENA RUBÉN, MALTAMO M, PACKALEN P. 2016. Classification of multilayered forest development classes from low-density national airborne lidar datasets. *Forestry*. 89(4):392–401. <https://doi.org/10.1093/forestry/cpw010>

VALBUENA R., MALTAMO M, PACKALEN P. 2016. Classification of forest development stages from national low-density lidar datasets: a comparison of machine learning methods. *Revista de Teledetección [Internet]. Special issue: Active Remote Sensing in Forest Applications*. <https://doi.org/10.4995/raet.2016.4029>

VEGA ISUHUAYLAS LA, HIRATA Y, VENTURA SANTOS LC, SERRUDO TOROBEO N. 2018. Natural Forest Mapping in the Andes (Peru): A Comparison of the Performance of Machine-Learning Algorithms. *Remote Sensing*. 10(5). <https://doi.org/10.3390/rs10050782>

ZHU XX, TUIA D, MOU L, XIA G-S, ZHANG L, XU F, FRAUNDORFER F. 2017. Deep learning in remote sensing: a review. *IEEE Geosci Remote Sens Mag.* 5(4):8–36. <https://doi.org/10.1109/MGRS.2017.2762307>

TABLAS Y FIGURAS

Tabla 1. Precisión, desviación estándar de ésta, valor Kappa y desviación estándar del valor Kappa resultantes de cada modelo.

	PRECISIÓN	DESV.STD	KAPPA	DESV.STD
ANN	0.7646	0.0690	0.7023	0.0873
SVML	0.8674	0.0420	0.8330	0.0527
SVMR	0.8716	0.0624	0.8386	0.0784
RF	0.8809	0.0473	0.8499	0.0593

Tabla 2. Matriz de confusión (observado: filas; predicho: columnas) para los análisis de entrenamiento y validación cruzada en el modelo final de Random Forest para la clasificación del uso del suelo (Clase 1: Sin vegetación; Clase 2: Cultivos; Clase 3: Arbustos y pastos; Clase 41: Arbolado permitido; Clase 42: Árboles prohibidos).

	ENTRENAMIENTO						VALIDACIÓN CRUZADA					
	1	2	3	41	42	error	1	2	3	41	42	error
1	64	1	0	0	0	0,0154	21	0	0	0	0	0,0000
2	2	53	5	0	0	0,1167	0	14	3	0	0	0,1765
3	0	6	47	3	2	0,1897	0	1	11	1	0	0,1538
41	2	0	3	58	5	0,1471	0	0	0	13	1	0,0714
42	0	0	2	8	84	0,1064	0	0	2	5	17	0,2917

Tabla 3. Distribución de la superficie final obtenida tras la generalización del modelo entrenado a toda la zona de interés (izquierda: clasificación de los tipos de vegetación; derecha: clasificación de los tipos de tratamientos siguiendo el esquema de la Figura 3)

VEGETACIÓN			TRATAMIENTOS		
CLASE	SUPERFICIE (m ²)	%	Class	Area (m ²)	%
1	47.231,2	1,6	Sin Tratamiento	1.366.241,7	46,4
2	655.821,9	22,3	Desbroce	532.688,9	18,1
3	1.193.765,7	40,6	Clara	51.458,7	1,7
41	376.776,5	12,8	Clara y Poda	324.770,2	11,0
42	669.613,5	22,8	Corta	668.049,3	22,7

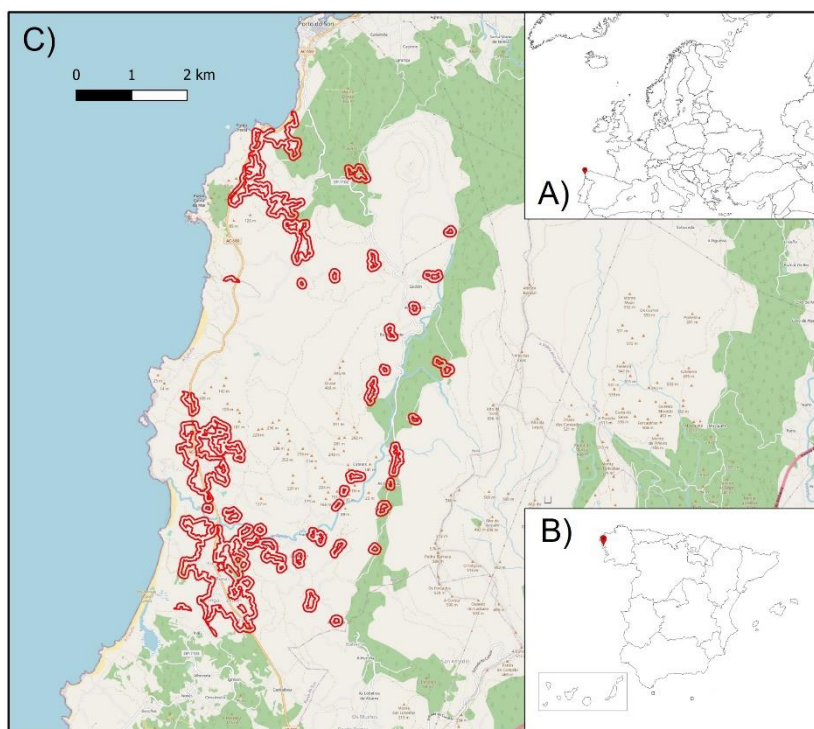


Figura 1. Localización general de la zona de estudio: (a) localización en referencia a Europa, (b) localización en referencia a España, y (c) detalle de la zona volada con UAV (polígonos rojos).

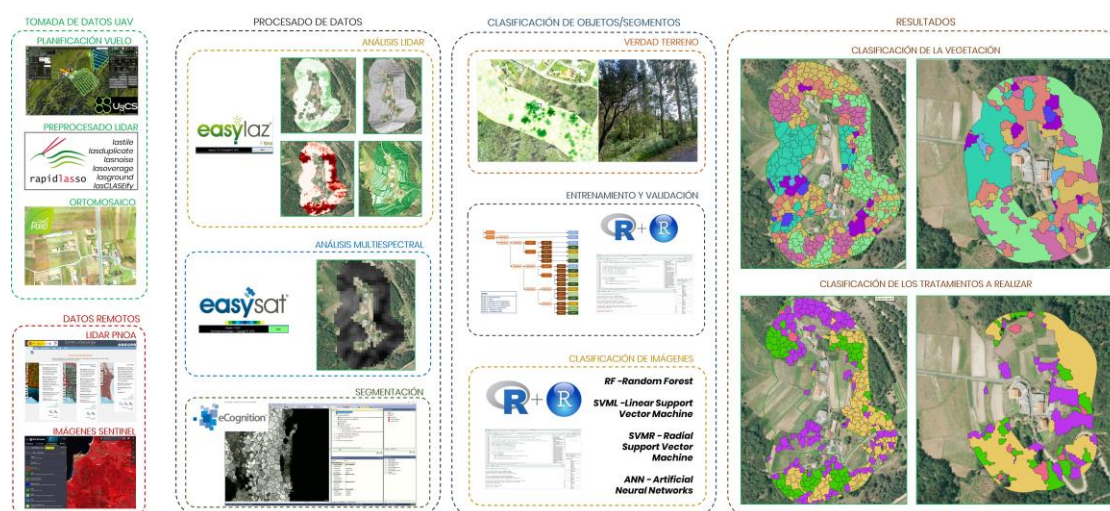


Figura 2. Esquema general que representa todos los materiales y métodos utilizados en esta investigación (RS, Teledetección; ALS, Escáner Láser Aerotransportado; PNOA, Programa Nacional de Ortofotografía Aérea del Gobierno Español).

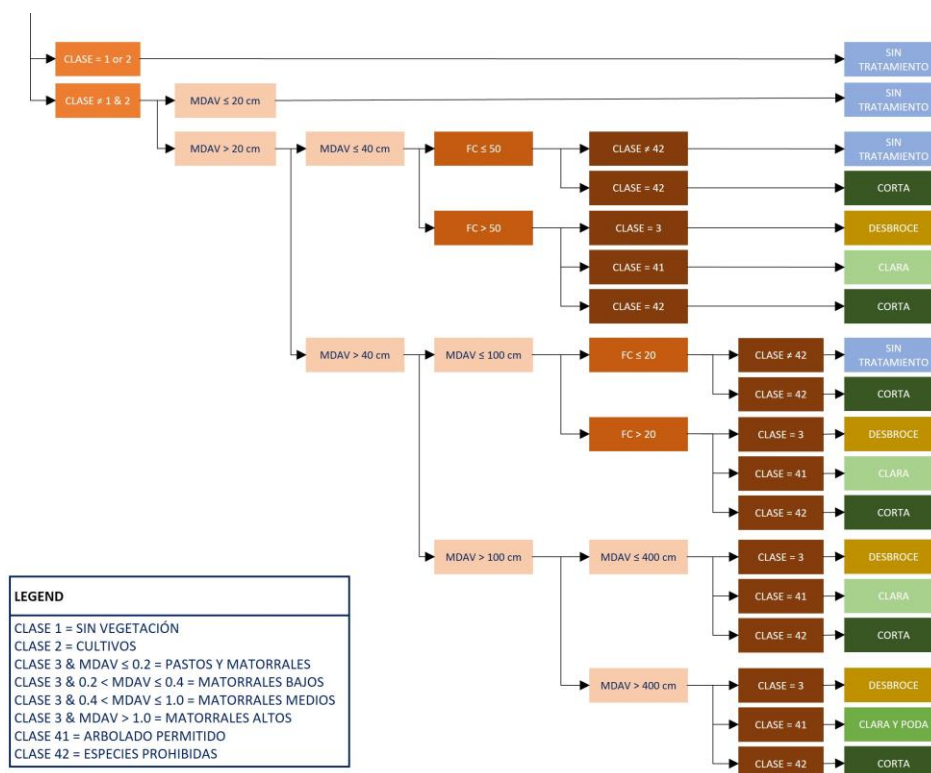


Figura 3. Esquema de las reglas de planificación de los cortafuegos a partir de la clasificación del uso del suelo y de las métricas de la vegetación (MDAV, modelo de altura del dosel; FC, Fracción de Cobertura Cubierta).

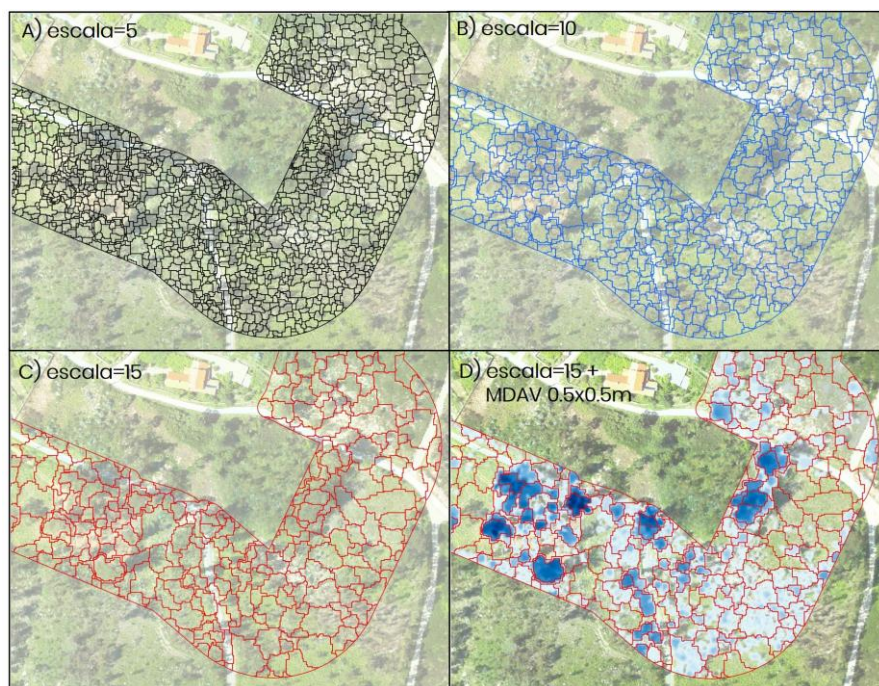


Figura 4. Detalle de una de las zonas de estudio con los segmentos superpuestos sobre el ortomosaico: (a) objetos pequeños (escala=5); (b) objetos medianos (escala=10); (c) objetos grandes (escala=15); (d) segmentación finalmente seleccionada (escala =15) superpuesta con el MDAV (50 cm de resolución).




Figura 5. Detalle de una de las zonas de estudio con la clasificación final de los tipos de actividades (aclareo: azul; aclareo y poda: marrón; corta: rojo; desbroce: cian; sin actuación: amarillo).