



2025 | **16-20**
GIJÓN | **JUNIO**

9º CONGRESO FORESTAL ESPAÑOL

9CFE-1542

Actas del Noveno Congreso Forestal Español
Edita: **Sociedad Española de Ciencias Forestales. 2025.**
ISBN: **978-84-941695-7-1**

Organiza





Mapa de modelos de combustible utilizando Sentinel-2 y LiDAR aéreo en Galicia

SOLARES CANAL, A. (1,2), ALONSO, L. (1,2), RINCÓN, T. (1), PICOS, J. (1),
MOLINA TERRÉN D.M. (3), BECERRA, C. (1), y ARMESTO J. (1,2)

(1) Escola de Enxeñaría Forestal, Universidade de Vigo.

(2) Grupo Xestión Segura e sostible de Recursos Minerais (XESSMin), CINTECX, Universidade de Vigo.

(3) departamento de Ciència i Enginyeria Frestal i Agrícola, Universitat de Lleida.

Resumen

Contar con mapas de modelos de combustible a escala de paisaje es esencial para la gestión de la prevención de incendios forestales. En paisajes dinámicos y con altas tasas de crecimiento de biomasa, como es la costa atlántica gallega, es necesario actualizar regularmente estos mapas. Este trabajo presenta una metodología para este fin basada en imágenes Sentinel-2 y LiDAR aéreo. Primeramente se realiza un proceso que permite relacionar las situaciones de combustibles presentes en el área de estudio con los modelos de combustibles Rothermel, mediante el uso de la foto-guía de combustibles forestales de Galicia y el software Visual-Fuego. Posteriormente se procede a cartografiar los diferentes modelos de Rothermel seleccionados para cada situación utilizando la teledetección. Las imágenes Sentinel-2 permiten diferenciar entre los distintos tipos de vegetación (matorral, arbolado, vegetación en áreas rocosas y prados o cultivos) y el LiDAR permite distinguir diferentes estructuras dentro de un mismo tipo de vegetación (matorral mayor o menor de 1 m o arbolado con continuidad vertical y sin continuidad vertical). Este flujo de trabajo permite obtener mapas de combustible de alta resolución a escala paisaje periódicamente actualizables.

Palabras clave

Incendios, modelos de combustible, teledetección, Sentinel-2, LiDAR.

1. Introducción

Contar con mapas de modelos de combustibles precisos y actualizados es esencial para la gestión de los incendios forestales. El grado de actualización es especialmente relevante en zonas donde la vegetación tiene una alta tasa de cambio. Un ejemplo de ello es Galicia. Galicia cuenta con rápidas tasas de crecimiento de la vegetación que llevan a la rápida acumulación de altas cargas de combustibles (ARELLANO et al., 2017). Así mismo el régimen de incendios y la alta tasa de aprovechamientos de la región hace que la cobertura forestal se vea frecuentemente modificada. De hecho, el 22,51% de la superficie total quemada en España entre 2006 y 2015 fue en esta comunidad (MAPA, 2019). Esta tendencia se ha mantenido en los años posteriores (LÓPEZ-RODRÍGUEZ et al., 2021; XUNTA DE GALICIA, 2022) con varios incendios forestales de gran envergadura (RODRIGUES et al., 2023; XUNTA DE GALICIA, 2022). La alta tasa de aprovechamiento se refleja en que el 50% del volumen anual cortado en España se corta en Galicia (MTERD, 2022).

Tradicionalmente, la identificación del modelo de combustible se ha realizado a través de estudios de campo (ANDERSON, 1982; ARROYO et al., 2008). Sin embargo, la actualización periódica a gran escala de mapas de modelos de combustibles no es ni técnica ni económicamente factible. En las últimas décadas, se han desarrollado nuevas tecnologías de teledetección que están proporcionando datos útiles para los para la caracterización y mapeo de combustibles (WALLACE et al., 2022; GALE et al., 2021). Los datos multiespectrales y ópticos pueden ser útiles para



obtener información geográfica sobre diferentes tipos de vegetación en diferentes lugares y ecosistemas (ERINJERY, et al. 2018; ZENG et al., 2020). Así como los datos SAR (Radar de Apertura Sintética) y los datos LiDAR (Light Detection And Ranging) ayudan a conocer la estructura de la vegetación. Si bien el potencial de los datos SAR aún no se ha evaluado completamente, las capacidades de los datos LiDAR para estudiar la estructura de los bosques están altamente desarrolladas (MORAN et al., 2018; WIGGINS et al., 2019; TELLO et al., 2018). GALE et al. (2021) publicaron recientemente una revisión sobre el uso de teledetección para la creación de mapas de modelos de combustibles. Destacaron la existencia de dos enfoques principales: la utilización de datos de teledetección para la caracterización de diferentes variables de los combustibles (ej. la carga) y la utilización de datos de teledetección en la identificación automatizada de modelos de combustible predefinidos. De los estudios analizados, solo el 30% utiliza este último enfoque (GALE et al. 2021). Algunos ejemplos son DOMINGO et al. (2020) y HUESCA et al. (2019) que utilizaron datos de teledetección para identificar, a nivel de píxel, los modelos Prometheus en zonas Mediterráneas. Otro ejemplo es el estudio de MARINO et al. (2016) que desarrolló un mapa de modelos de combustible para las Islas Canarias. Utilizaron datos de ALS e imágenes de Landsat para crear un mapa de Modelo de Combustible de las Islas Canarias (CIFM). FERRER PALOMINO y RODRÍGUEZ y SILVA (2021), utilizaron datos LiDAR para caracterizar, identificar y mapear modelos de combustible según los modelos de combustible UCO40 en Andalucía. Una consideración importante que se deduce de la revisión de GALE et al. (2021), así como de los ejemplos presentados, es que la mayoría de los estudios que utilizan la teledetección para el mapeo de combustibles se centran en mapear zonas mediterráneas. Sin embargo, este tipo de mapas son necesarios también en otras regiones (CARDIL et al., 2021). Por ejemplo, en zonas de vegetación atlántica como Galicia.

En Galicia se han realizado diversos esfuerzos para identificar y caracterizar los modelos de combustible más comunes; la más destacada es la foto-guía de combustibles publicada por Lourizán CIF (foto-guía en adelante) (ARELLANO et al., 2017). Otros investigadores han caracterizado algunas variables del combustible a través de la teledetección; algunos ejemplos son ALONSO-REGO et al. (2021), ALONSO-REGO et al. (2020), FIDALGO-GONZÁLEZ et al. (2019) y ARELLANO-PÉREZ et al. (2018). Sin embargo, estas metodologías no dan como resultado un mapa con la distribución de los modelos de combustible. En este estudio, describimos una metodología basada en datos de teledetección para la obtención de un mapa de modelo de combustible para un área cubierta de vegetación atlántica en Galicia (noroeste de España).

2. Objetivos

En este estudio, se pretende describir una metodología basada en imágenes Sentinel-2 y datos LiDAR para la obtención de un mapa de modelo de combustible actualizado en Galicia.

3. Metodología

3.1. Área de estudio

Para este proyecto se seleccionó un área piloto situado en la costa Atlántica gallega (ver Figura 1). Las principales especies arbóreas presentes en el área de estudio son *Pinus pinaster*, *Pinus radiata*, *Eucalyptus globulus* y *Quercus robur*, junto con especies de bosque de ribera (*Alnus glutinosa*, L., *Fraxinus excelsior*L., y *Salix*spp. L. entre otros) (MITECO, 2011). Las zonas de matorral de la zona de estudio están principalmente compuestas por *Ulex europaeus*L. y *Erica*spp. L.



Figura 1. Área de estudio.

3.2. Materiales

En este estudio se utilizó una serie temporal de imágenes del satélite Sentinel-2 del año 2019. Las imágenes utilizadas tenían el nivel de corrección 2A. Se utilizaron un total de 12 imágenes, una imagen por mes. Para cada mes se seleccionó la imagen con menor nubosidad, con la consideración de que ninguna imagen debía tener una nubosidad superior al 50%. Las imágenes se descargaron del Centro de Acceso Abierto de Copernicus (<https://scihub.copernicus.eu/>).

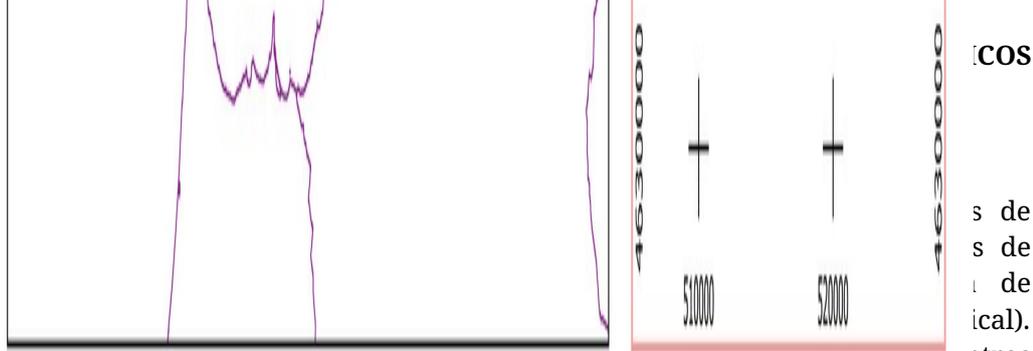
Así mismo se utilizaron datos LiDAR aéreo. Los datos LiDAR fueron adquiridos en noviembre de 2019. Las nubes de puntos tienen una resolución espacial media de 7,2 puntos/m².

Además, se utilizó la fotografía de combustibles de Galicia (Arellano et al. 2017). Esta presenta un conjunto de situaciones reales de combustible de Galicia e indicadores del comportamiento del fuego asociada a las mismas. Para cada situación de combustible se presenta: información sobre las especies dominantes, las alturas medias de la vegetación, las cargas de combustible, fotografías representativas y una estimación del comportamiento del fuego.

3.3. Metodología

El primer paso consistió en realizar un mapa de cobertura del suelo a partir de las imágenes Sentinel-2. La leyenda objetivo de mapa fue la siguiente: Eucalipto, Coníferas, Frondosas, Cultivos y pastos, Matorrales, Áreas rocosas, Antrópico y Agua. El mapa se realizó siguiendo la metodología descrita en ALONSO et al. (2019). Esta metodología consiste en la clasificación supervisada de cada una de las imágenes mensuales descargadas. Para ello se utilizó el algoritmo “random forest” (BREIMAN, 2001). Para obtener la clasificación final del año 2019 estas clasificaciones mensuales fueron agregadas en una sola. El criterio de agregación consistió en seleccionar para cada píxel la clase más común de entre las clasificaciones obtenidas para ese mismo píxel cada uno de los meses.

El siguiente paso consistió en realizar la caracterización estructural de la vegetación mediante el procesamiento de los datos LiDAR para. Todos el procesamiento LiDAR se realizó utilizando el paquete “lidR” del software R (ROUSSEL & AUTY, 2021). El primer paso consistió en normalizar las nubes de puntos. A continuación, a partir de las nubes normalizadas, se obtuvo un modelo de altura de copas (CHM) que permitirá posteriormente conocer la altura de la vegetación. Finalmente, para conocer la estructura vertical de la vegetación se obtuvo una serie de métricas en una malla raster de resolución espacial 5 m. Las métricas obtenidas fueron: el máximo, la media, la desviación estándar, la asimetría, la curtosis, la entropía, el porcentaje de retornos por encima de la media, el porcentaje de retornos por encima de 2 m, percentiles y el porcentaje acumulado de retornos en diferentes capas (según WOODS et al. 2008). Estas estadísticas fueron utilizadas para calcular que zonas arboladas presentan continuidad vertical y cuales no. Para ello se realizó una clasificación “random forest”. La verdad terreno de esta clasificación se obtuvo mediante la inspección de la nube de puntos. Para facilitar esta inspección las nubes de puntos fueron divididas en secciones horizontales de grosor 2 m. Cada sección horizontal fue transformada a una capa raster de 5 m en la que cada píxel contiene el número de puntos contenidos en el prisma definido por el contorno del píxel y los valores de altura máximo y mínimo de cada sección. Esto se obtuvo utilizando la herramienta “lasgrid” del software LAStools (ISENBURG, 2021).



s de
s de
l de
ical).
etros
tible
uego
cada
UCO,
ción
bles

LiDAR obtenidas fue posible clasificar cada uno de los modelos. En ambos procesos se aplicó el principio de precaución: se adoptó el criterio que representaba el peor de los casos, en términos de comportamiento frente al fuego. La Tabla 1 presenta las relaciones establecidas. Resaltar que, como se ha explicado anteriormente, el mapa de cobertura del suelo se obtiene asignando a cada píxel la clase más común obtenida a lo largo del año 2019. Sin embargo, los datos LiDAR fueron capturados en noviembre de 2019. Esto puede llevar que áreas cortadas a final de año puedan estar clasificadas como arboladas, pero no tener altura de arbolado en los datos LiDAR.

Tabla 1. Relaciones entre situaciones de combustible fotoguía de combustibles de Galicia (Arellano, 2017), modelos Rothermel y variables de teledetección.

Situación fotoguía	Modelo Rothermel	Sentinel-2	LiDAR
-	1	Zonas rocosas	-
Pl-01, Pl-02, Pa-01, Pa-04	2	Cultivos y pastos	-
Ea-05, Es-01, Pt-05, Pt-06, Pt-07, Ue-05, Ue-08, Ue-10, Ub-02, Ub-04, Cs-01, Cs-03	4	Matorral	CHM > 1 m
Eu-01, Eu-05, Eu-06, Pt-01, Ue-01, Ue-02, Ub-03	5	Matorral	CHM < 1 m
PpMB-02, PpL-04, PpL-09, EgL-08, QrL-04	7	Eucalipto o Coníferas o Fronosas	Continuidad vertical
PpF-03, PpF-05, PpF-06, EgL-05, EgL-06, EgF-03, EgF-05, QrF-02, QrF-04, BaL-01	10	Eucalipto o Coníferas o Fronosas	Discontinuidad vertical
-	12	Eucalipto o Coníferas o Fronosas	CHM < 1 m

Para verificar los mapas obtenidos se verificaron los mapas de usos del suelo y el mapa de continuidad y discontinuidad vertical. El mapa de coberturas fue validado mediante un muestreo sistemático estratificado con 50 puntos por clase. La verdad terreno fue obtenida mediante fotointerpretación de las imágenes PNOA. El mapa de continuidad y discontinuidad se verificó mediante la distribución de un total de 1484 puntos distribuidos aleatoriamente. La verdad terreno se obtuvo mediante la interpretación de la nube de puntos en cada uno de esos píxeles. Para ayudar a la interpretación se construyeron capas raster de porcentaje de puntos a diferentes alturas. En concreto 7. A continuación, se construyó una matriz de confusión para cada mapa y se calcularon las métricas de precisión. Las métricas de precisión calculadas fueron: la precisión global (OA), la precisión del productor (PA), la precisión del usuario (UA) .Para cada métrica se calcularon sus intervalos de



confianza siguiendo las indicaciones de Oloffson et al. (2014).

4. Resultados

El mapa de cobertura del suelo obtenido se presenta en la Figura 2. Este mapa tiene una precisión global del 90% y precisiones de usuario y de productor entre 70 y 100%. Estos se presentan en la Tabla 2.





Figura 2. Mapa de coberturas obtenido para la zona de estudio a partir de imágenes Sentinel-2.

Tabla 2. Matriz de confusión mapa de coberturas. Euc: Eucalipto, Con: Coníferas, Fro: Frondosas, Cul: Cultivos o prados, Mat: Matorral, Roc: Zonas rocosas, Ant: Antrópico, Agu: Agua.

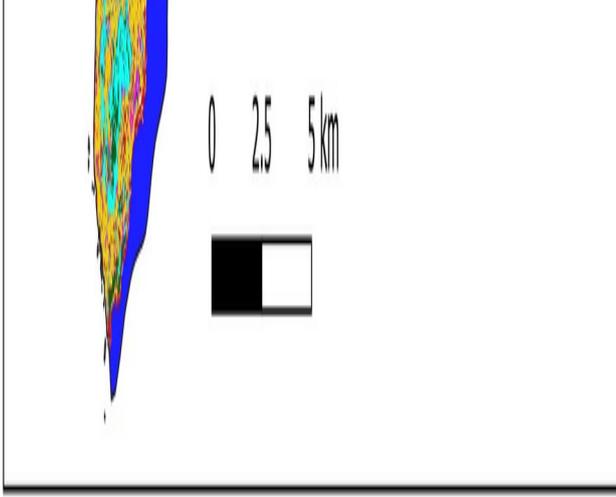
Verdad terreno	
Clasificación	

En la Tabla 2 se presenta la matriz de confusión de la clasificación “random forest” que permitió diferenciar entre zonas arboladas con y sin continuidad vertical. Se obtuvo una Precisión Total del 98 %.

Tabla 2. Matriz de confusión de zonas arboladas con y sin continuidad vertical. VT: Verdad Terreno, C: Clasificación. PP: Precisión Productor, PU: Precisión Usuario, PT: Precisión Total.

VT/ C	Continuo	Discontinuo	TOTAL	PU(%)	
Continuo	750	17	767	98 ± 1	
Discontinuo	717	717		100 ± 0,0	
TOTAL	750	734	1484	PT (%)	
PP (%)	100 ± 0,0	98 ± 2,73 10 ⁻³		PT (%)	98 ± 0,6

En la Figura 3 se muestra el mapa de modelos de combustibles final obtenido. Además, en la Tabla 3 se muestra como estos combustibles se distribuyen en el territorio en términos de superficie. Dado que un alto porcentaje del área está cubierta por tierras agrícolas, el modelo de combustible 2 es uno de los modelos



COS

s de
ayor
is de
a ser
tible
le 7.
e, se
reas



Figura 3. Mapa de modelos de combustible.

Tabla 3. Distribución de los diferentes modelos de combustible en el área de estudio.

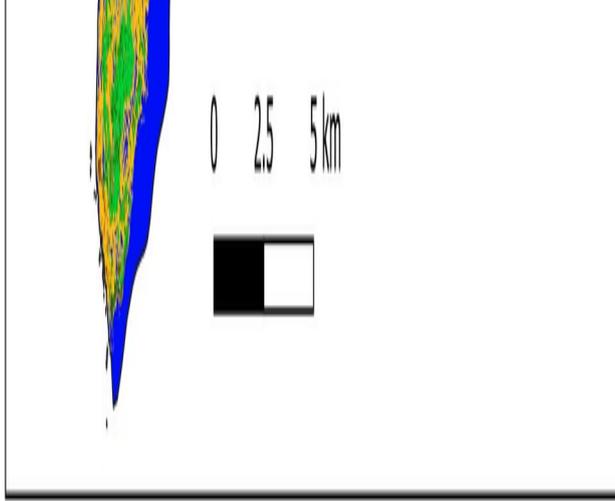
Modelo de combustible	Superficie (ha)	Porcentaje (%)
Modelo 1	3525	12
Modelo 2	9241	30
Modelo 4	2819	9
Modelo 5	1140	4
Modelo 7	7179	24
Modelo 10	4322	14
Modelo 12	432	1

5. Discusión

La metodología descrita utiliza datos de teledetección para obtener un mapa actualizado del modelo de combustible para una zona caracterizada por un clima atlántico. El mapa es compatible con la mayoría de los programas de simulación del comportamiento del fuego, esenciales en la gestión de incendios, ya que la mayoría de estos utilizan la ecuación de tasa de propagación de Rothermel (SIMONS et al., 2013).

La metodología descrita incluye la asociación sistemática de los modelos de combustible de Rothermel a las situaciones de combustible presentes en el área de estudio. Esta no es una tarea sencilla ya que los modelos de Rothermel se describieron para una región climática con tipos de vegetación y estructuras muy diferentes. Esta asociación podría conducir a una forma estandarizada de mapear los modelos de combustible en esta área. La automatización de este proceso lo hace más objetivo y menos dependiente del criterio de cada técnico individual. Este tipo de adaptaciones no son necesarias cuando se dispone de la clasificación del modelo de combustible para la zona de estudio, como fue el caso de MARINO et al. (2016) para las Islas Canarias y en FERRER PALOMINO y RODRÍGUEZ Y SILVA (2021) para Andalucía. Se están realizando diversos esfuerzos para establecer modelos de combustible adaptados a las situaciones de combustible en Galicia (ARELLANO et al. 2017; VEGA et al. 2024). Hasta que estos se completen la opción presentada en este trabajo puede ser de alta relevancia. Esto no quita que podría ser interesante el mapeado de otros modelos como los desarrollados en Portugal (FERNANDES et al., 2009; FERNANDES y LOUREIRO 2022; SÁ et al. 2023) ya que hacen agrupaciones de especies que podrían ayudar a describir mejor las condiciones de la vegetación del área de estudio y su comportamiento frente a los incendios forestales. De hecho, la clasificación de la cobertura del suelo del área de estudio separa tres clases de arbolado que pueden presentar un comportamiento ligeramente diferente frente a los incendios forestales (ARELLANO et al., 2017). Esta distinción podría garantizar que, en el caso de que en el futuro se elaboren diferentes ecuaciones de propagación del fuego para cada clase de arbolado, se pueda obtener el máximo beneficio potencial de las capacidades de teledetección.

La metodología propuesta es similar al enfoque adoptado por MARINO et al. (2016). El estudio de MARINO et al. (2016) también utiliza un mapa de la cubierta terrestre



truir
ible.
gran
) La
ntos
lado
n en
e las
Para
ático
a).

Si bien es cierto que esta metodología se presenta como una metodología para obtener mapas actualizados de modelos de combustible, su dependencia de los datos LiDAR podría significar que su capacidad de actualización se vea comprometida. Por lo tanto, entre una actualización de datos LiDAR y la siguiente, puede ser necesario actualizar el mapa del modelo de combustible utilizando imágenes satelitales de acceso abierto, como hicieron, por ejemplo, DECASTRO et al. (2022). Una metodología que puede resultar valiosa para esta tarea es la metodología desarrollada por ALONSO et al. (2021) para la detección de perturbaciones forestales en Galicia. Sin embargo, esta metodología sería insuficiente para detectar cambios entre modelos que difieren únicamente en la estructura vertical de la vegetación (es decir, no puede diferenciar entre el modelo 7 y el modelo 10), ya que para ello se necesita contar con datos LiDAR. Contar con mapas de modelos de combustible actualizados es de suma importancia, y sería recomendable aumentar la frecuencia con la que se actualizan los datos de ALS de acceso abierto en España (actualmente se actualiza cada 7 a 11 años (MTMAU, 2023)).

6. Conclusiones

Este estudio permitió la creación de un mapa actualizado del modelo de combustible para un paisaje atlántico utilizando la teledetección. El mapa de combustible obtenido está adaptado a los modelos de combustible de Rothermel y, por lo tanto, puede ser utilizado operativamente con diversos software de simulación de incendios. Además, se basó específicamente en los tipos de combustible presentes en el área de estudio y podría servir de base para futuros modelos de combustible diseñados explícitamente para este entorno. La disponibilidad de este mapa permitirá a las partes interesadas de esta región hacer un cambio hacia mejores acciones de supresión y gestión de combustible. Esto se debe a mapas de combustible con mayor grado de detalle y más actualizados para su uso con software de simulación de comportamiento del fuego.

7. Agradecimientos

Este trabajo forma parte del proyecto “PALEOINTERFAZ: Elemento estratégico en la prevención de incendios forestales. Desarrollo de metodologías de análisis 3D y multiespectral para la gestión integrada” de la convocatoria RETOS 2019 del Ministerio de Ciencias Innovación y Universidades (PID2019-111581RB-I00), del proyecto INTERREG firepocstep+: 0139_FIREPOCTEP_MAS_6_E y del proyecto USE4FOREST_ INTERREG SUDOE. Además, para su realización Laura Alonso contó con la financiación del Programa Postdoctoral de la Xunta de Galicia (ED481B_059) y del Ministerio de Ciencia Innovación y Universidades (FPU19/02054).

8. Bibliografía



ALONSO, L.; J. PICOS; J. ARMESTO; 2021. Forest land cover mapping at a regional scale using multi-temporal Sentinel-2 imagery and RF models. *Remote Sensing*, 13 (12): 2237.

ALONSO-REGO, C.; ARELLANO-PÉREZ, S.; CABO, C.; ORDOÑEZ, C.; ÁLVAREZ-GONZÁLEZ, J.G.; DÍAZ-VARELA, R.A.; RUIZ-GONZÁLEZ, A.D.; 2020. Estimating Fuel Loads and Structural Characteristics of Shrub Communities by Using Terrestrial Laser Scanning. *Remote Sensing*, 12 (22): 3704.

ALONSO-REGO, C.; ARELLANO-PÉREZ, S.; GUERRA-HERNÁNDEZ, J.; MOLINA-VALERO, J.A.; MARTÍNEZ-CALVO, A.; PÉREZ-CRUZADO, C.; CASTEDO-DORADO, F.; GONZÁLEZ-FERREIRO, E.; ÁLVAREZ-GONZÁLEZ, J.G.; RUIZ-GONZÁLEZ, A.D.; 2021. Estimating stand and fire-related surface and canopy fuel variables in pine stands using low-density airborne and single-scan terrestrial laser scanning data. *Remote Sensing*, 13 (24): 5170.

ANDERSON, H.E., 1982. Aids to determining fuel models for estimating fire behavior. Gen. Tech. Rep. INT-GTR-122. Ogden, Utah: U.S. Department of Agriculture, Forest Service, Intermountain Forest and Range Experiment Station.

ARELLANO, S.; VEGA, J.A.; RUIZ, A.D.; ARELLANO, A.; ÁLVAREZ, J.G.; VEGA, J.D.; PÉREZ, E.; 2017. Foto-Guía De Combustibles Forestales De Galicia y Comportamiento Del Fuego Asociado. Santiago de Compostela, Spain: Andavira Editora, S. L.

ARELLANO-PÉREZ, S.; CASTEDO-DORADO, F.; LÓPEZ-SANCHEZ, C.A.; GONZÁLEZ-FERREIRO, E.; YANG, Z.; DÍAZ-VARELA, R.A.; ÁLVAREZ-GONZÁLEZ, J.G.; VEGA, J.A.; RUIZ-GONZALEZ A.D.; 2018. Potential of Sentinel-2A data to model surface and canopy fuel characteristics in relation to crown fire hazard. *Remote Sensing*, 10 (10): 1645.

ARROYO, L.A.; PASCUAL, C.; MANZANERA, J.A., 2008. Fire models and methods to map fuel types: The role of remote sensing. *Forest Ecology and Management* 256 (6): 1239–1252.

BREIMAN, L.; 2001. Random Forests. *Machine Learning* 45, 5–32.

CARDIL, A.; MONEDERO, S.; SCHAG, G.; DE-MIGUEL, S.; TAPIA, M.; STOOFF, C.R.; SILVA, C.A.; MOHAN, M.; CARDIL, A.; RAMIREZ, J.; 2021. Fire behavior modeling for operational decision-making. *Current Opinion in Environmental Science & Health* 23:100291.

DECASTRO, A.L.; JULIANO, T.W.; KOSOVIĆ, B.; EBRAHIMIAN, H.; BALCH, J.K.; 2022. A computationally efficient method for updating fuel inputs for wildfire behavior models using sentinel imagery and Random Forest classification. *Remote Sensing* 14 (6): 1447.

DOMINGO, D.; DE LA RIVA, J.; LAMELAS, M.; GARCÍA-MARTÍN, A.; IBARRA, P.; ECHEVERRÍA, M.; HOFFRÉN R.; 2020. Fuel type classification using airborne laser scanning and Sentinel 2 data in mediterranean forest affected by wildfires. *Remote Sensing* 12 (21): 3660.

ERINJERY, J.J.; SINGH, M.; KENT, R.; 2018. Mapping and assessment of vegetation types in the tropical rainforests of the Western Ghats using multispectral Sentinel-2 and SAR Sentinel-1 satellite imagery. *Remote Sensing of Environment*. 345–354.

FERNANDES, P.; LOUREIRO, C.; 2022. Modelos de combustível florestal para Portugal – Documento de referencia, versão de 2021.



FERNANDES, P.; GONÇALVES, H.; LOUREIRO, C.; FERNANDES, M.; COSTA, T.; CRUZ, M.; BOTELHO, H.; 2009. Modelos de combustible florestal para Portugal. In: 6º Congr. Florest. Nac. Soc. Port. Ciências Florestais; SPCF Lisboa, Portugal.

FERRER PALOMINO, A.; RODRÍGUEZ Y SILVA, F.; 2021. Fuel Modelling Characterisation Using Low-Density Lidar in the Mediterranean: An Application to a Natural Protected Area. *Forests* 12 (8): 1011.

FIDALGO-GONZÁLEZ, L.A.; ARELLANO-PÉREZ, S.; ÁLVAREZ-GONZÁLEZ, J-G; CASTEDO-DORADO, F.; RUIZ-GONZÁLEZ, A.D.; GONZÁLEZ-FERREIRO E.; 2019. Estimación de la distribución vertical de combustibles finos del dosel de copas en masas de *Pinus sylvestris* empleando datos LiDAR de baja densidad. *Revista De Teledetección* 53: 1–16.

GALE, M.G.; CARY, G.Y.; VAN ALBERT, I.J.M.; YEBRA M.; 2021. Forest fire fuel through the lens of remote sensing: Review of approaches, challenges and future directions in the remote sensing of biotic determinants of fire behaviour. *Remote Sensing of Environment* 255: 112282.

HUESCA, M.; RIAÑO, D.; USTIN S.L.; 2019. Spectral mapping methods applied to LiDAR data: Application to fuel type mapping. *International Journal of Applied Earth Observation and Geoinformation* 74: 159–168.

ISENBURG, M. 2021. LAStools- efficient LiDAR processing software (academic). <http://rapidlasso.com/LAStools>.

LABIF-UCO, Laboratorio de Defensa contra Incendios Forestales y Manejo del Fuego de la Universidad de Córdoba. 2019. Visual-Fuego software.

LÓPEZ-RODRÍGUEZ, G.; RODRÍGUEZ-VICENTE, V; MAREY-PÉREZ, M.F.; 2021. Study of Forest Productivity in the Occurrence of Forest Fires in Galicia (Spain). *Sustainability* 13 (15): 8472.

MARINO, E.; RANZ, P.; TOMÉ, J.L.; NORIEGA, M.A.; ESTEBAN, J.; MADRIGAL, J.; 2016. Generation of high-resolution fuel model maps from discrete airborne laser scanner and Landsat-8 Oli: A low-cost and highly updated methodology for large areas. *Remote Sensing of Environment* 187: 267–280.

MAPA; 2019. Los incendios forestales en España: decenio 2006–2015.

MITECO; 2011. Mapa Forestal de España (MFE) de máxima actualidad.

MTMAU; 2023. Plan Nacional de Ortofotografía Aérea (PNOA).

MTERD; 2022. Anuario de Estadística Forestal 2020.

MORAN, C.J.; ROWELL, E.M.; SEIELSTAD, C.A.; 2018. A data-driven framework to identify and compare forest structure classes using LiDAR. *Remote Sensing of Environment* 211: 154–166.

OLOFSSON, P.; FOODY, G.M.; HEROLD, M.; STEHMAN, S.V.; WOODCOCK, C.E.; WULDER, M.A.; 2014. Good practices for estimating area and assessing accuracy of land change. *Remote Sensing of Environment*, 148, 42-57. <https://doi.org/10.1016/j.rse.2014.02.015>

RODRIGUES, M.; CUNILL CAMPRUBÍ, À.; BALAGUER-ROMANO, R.; COCO MEGÍA, C.J.; CASTAÑARES, F.; RUFFAULT, J.; FERNANDES, P.M.; RESCO DE DIOS V.; 2023. Drivers and implications of the extreme 2022 wildfire season in Southwest Europe. *Science of The Total Environment* 859: 160320.

ROUSSEL, J.R.; AUTY, D.; COOPS, N.C.; TOMPALSKI, P.; GOODBODY, T.R.H.;



SÁNCHEZ MEADOR, A.; BOURDON, J.F.; DE BOISSIEU, F.; ACHIM, A.; 2020. LidR: An R package for analysis of Airborne Laser Scanning (ALS) data. *Remote Sensing of Environment* 251: 112061.

SÁ, A.C.L.; BENALI, A.; APARICIO, A.B.; BRUNI, C.; MOTA, C., PEREIRA J.M.C.; FERNANDES, P.M.; 2023.A method to produce flexible and customized fuel models dataset. *MethodsX*, 10, 102218.

SIMONS, N.E.; 2013.Improving decision making during wildland fire events. Thesis: University of California, Santa Barbara.

TELLO, M.; CAZCARRA-BES V.; PARDINI, M; PAPATHANASSIOU. K.; 2018. Forest structure characterization from SAR tomography at L-Band. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 11 (10): 3402–3414.

VEGA, J.A.; ÁLVAREZ-GONZÁLEZ, J.G.; ARELLANO-PÉREZ, S.; FERNÁNDEZ, C.; CUIÑAS, P.; JIMÉNEZ, E.; FERNÁNDEZ-ALONSO, J.M.; FONTÚRBEL, T.; ALONSO-REGO, C.; RUIZ-GONZÁLEZ, A.D.; 2024.Developing customized fuel models for shrub and bracken communities in Galicia (NW Spain), *Journal of Environmental Management*, 351, 119831.

WALLACE, L.; HILLMAN; S. HALLY; B. TANEJA, R.; WHITE, A.; MCGLADE. J.; 2022. Terrestrial Laser Scanning: An operational tool for fuel hazard mapping? *Fire* 5 (4): 85.

WIGGINS, H.L.; NELSON, C.R.; LARSON, A.J.; SAFFORD. H.D.; 2019. Using LiDAR to develop high-resolution reference models of forest structure and spatial pattern. *Forest Ecology and Management* 434: 318–330.

WOODS, M.; LIM, K.; TREITZ. P.; 2008. Predicting forest stand variables from LiDAR data in the Great Lakes – St. Lawrence Forest of Ontario.*The Forestry Chronicle* 84 (6): 827–839.

XUNTA DE GALICIA,CONSELLERÍA DO MEDIO. RURAL, DIRECCIÓN XERAL, AND DE DEFENSA DO MONTE; 2022. PLADIGA: Plan de Prevención e Defensa Contra os Incendios Forestais de Galicia. España: Santiago de Compostela.

ZENG, L.; WARDLOW, B.D.; XIANG, D.; HU, S.;LI.D; 2020. A review of vegetation phenological metrics extraction using time-series, multispectral satellite data.*Remote Sensing of Environment* 237.