



**2025** | **16-20**  
**GIJÓN** | **JUNIO**

**9º CONGRESO FORESTAL ESPAÑOL**

**9CFE-1278**

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

Organiza





## Servidor de combustibles a nivel paneuropeo: un portal de geo-datos para el apoyo y evaluación en incendios forestales

KUTCHARTT, E. (1,2), GONZÁLEZ-OLABARRIA, J.R. (1,3), AQUILUÉ, N. (1,3), GARCIA-GONZALO, J. (1,3), TRASOBARES, A. (1), BOTEQUIM, B. (4,5), HAUGLIN, M. (6), PALAIOLOGOU, P. (7), VASSILEV, V. (8), CARDIL, A. (1,9), NAVARRETE, M.A. (9), ORAZIO, C. (10), PIROTTI, F. (2,11)

(1) Centro de Ciencia y Tecnología Forestal de Cataluña (CTFC). Carretera de Sant Llorenç de Morunys, Km 2, 25280 Solsona, España

(2) Department of Land, Environment, Agriculture and Forestry (TESAF), University of Padova. Via dell'Università 16, 35020 Legnaro (PD), Italia

(3) Joint Research Unit CTFC – AGROTECNIO. Carretera de Sant Llorenç de Morunys, Km 2, 25280 Solsona, España

(4) CoLAB ForestWISE – Collaborative Laboratory for Integrated Forest & Fire Management. Quinta de Prados 5001-801 Vila Real, Portugal

(5) Forest Research Centre, School of Agriculture (ISA), University of Lisbon. Tapada de Ajuda 1349-017 Lisboa, Portugal

(6) Division of Forest and Forest Resources, Norwegian Institute of Bioeconomy Research (NIBIO). Postboks 115, NO-131 Ås, Noruega

(7) Department of Forestry and Natural Environment Management, Agricultural University of Athens (AUA), Karpenisi 36100, Grecia

(8) Space Research and Technology Institute, Bulgarian Academy of Sciences, str. "Acad. Georgy Bonchey" bl. 1, 113 Sofia, Bulgaria

(9) Technosylva. Parque Tecnológico de León, 24009 León, España

(10) Institut Européen de la Forêt Cultivée (IEFC), 69 Route d'Arcachon, 33610 Cestas, Francia

(11) Interdepartmental Research Center of Geomatics (CIRGEO), University of Padova. Via dell'Università 16, 35020 Legnaro (PD), Italia

### Resumen

Dentro de las variables más importantes para modelar el comportamiento de un incendio forestal, se encuentran las variables topográficas y las características vegetacionales. En esta última, se identifican atributos en el dosel de copas, como la cobertura (%) y altura (m), y más específicamente los combustibles de copas, siendo la altura base del dosel - ABD (m) y la densidad aparente del dosel - DAD (kg/m<sup>3</sup>), atributos fundamentales para entender el comportamiento del fuego a nivel superior (entre copas). Para completar la simulación de un incendio, también se requiere considerar el tipo de combustible superficial. Por lo tanto, en este trabajo, se reportan un mapa de biomasa a escala paneuropea, las dos variables de combustibles de copas y la variable del combustible superficial mediante productos y datos satelitales, inteligencia artificial, y ecuaciones alométricas específicas para las 16 especies forestales de mayor representatividad en Europa. La escala de trabajo fue a nivel paneuropeo, en donde las nueve capas disponibles (más las 2 capas de incertidumbre referente a los combustibles de copas) se



presentaron en un formato ráster y fueron co-registradas en el mismo sistema de coordenadas (WGS84) y a una resolución espacial aproximada de 100 m para el año 2020. Las capas ráster fueron distribuidas mediante una aplicación de *Google Earth Engine* (GEE) y el programa R, pudiéndose visualizar y descargar la información a distintos niveles administrativos mediante un servidor de combustibles paneuropeo (<https://www.cirgeo.unipd.it/fire-res/app/>). Los errores reportados en ABD y DAD fueron de 3,9 m y 0,099 kg/m<sup>3</sup>, respectivamente, según el error cuadrático medio, utilizando datos de campo como parte de una validación independiente, que combinó información LiDAR con mediciones de campo en países provenientes de distintas latitudes (Portugal, Italia, Grecia, y Noruega). En síntesis, la información proporcionada cuenta con un grado de precisión razonable para la mitigación, como consecuencia de los análisis proporcionados a partir de las simulaciones de incendios forestales a escala paneuropea. Esta información sobre combustibles, toma especial interés para países que actualmente no cuentan con información para ejecutar este tipo de simulaciones.

### Palabras clave

Datos satelitales, inteligencia artificial, ecuaciones alométricas, Web-GIS, simulación de incendios, toma de decisiones, prevención de incendios

## 1. Introducción

En Europa, los incendios forestales han afectado una superficie de 837.212 ha, lo que corresponde a una total de 7.854 incendios forestales durante el año 2022, cifras que solo incluyen a los países pertenecientes a la EU-27 (EUROPEAN COMMISSION, 2024), ya que incluyendo países non EU y del norte de África y medio oriente, esta cifra sobrepasa los 14 millones de hectáreas afectadas, traducidas en más de 13 mil incendios forestales solo para un mismo año. Los incendios forestales están fuertemente influenciados por tres variables biofísicas como las condiciones climáticas, vegetacionales, y topográficas (MEIGS et al., 2020). Dentro de estas variables, información referente a la caracterización de la vegetación es fundamental para entender el comportamiento de un incendio, lo que permite mitigar potenciales daños mediante el apoyo en la toma de decisiones en su gestión y prevención (RYAN, 2002; MATTHEWS et al., 2012; LABENSKI et al., 2023). En la actualidad, se cuenta con un amplio rango de información satelital, tanto de sensores pasivos (datos ópticos como Sentinel-2 y Landsat 8) como activos (información SAR o GEDI) (HEISIG et al., 2022), que pueden ser un soporte en la prevención de estos incendios. Dicha información satelital, que caracteriza los principales factores en los incendios, debe ser incorporada como fuentes de datos a programas que puedan simular el comportamiento de un incendio. Entre tales factores destacan características topográficas, como elevación, pendiente, y exposición; la estructura y distribución vegetacional, como la altura base del dosel (ABD; m), la densidad aparente del dosel (DAD; kg/m<sup>3</sup>) y combustibles superficiales mediante distintos tipos de codificaciones. Específicamente, esta información permite predecir variables como la tasa de dispersión (m/s), longitud de llama (m), probabilidad de queda (%), intensidad de la línea de fuego (kW/m), entre otras variables que permiten detectar las áreas de mayor riesgo, y, por lo tanto, ejecutar medidas de mitigación (HALL & BURKE, 2006; MUTLU et al., 2008; KUCUK & SEVINC, 2023; KUDLACKOVA et al., 2024). En la actualidad, existen diversos programas que permiten simular el comportamiento de un incendio, como aquellos desarrollados por el Servicio Forestal de los Estados Unidos FARSITE



(FINNEY, 2004), FlamMap (FINNEY, 2006) y FSim (FINNEY et al., 2011), y también el programa Prometheus en Canadá (TYMSTRA et al., 2010), el Wildfire Analyst en España (MONEDERO et al., 2019), o el Cell2Fire en Chile (PAIS et al., 2021).

Sin embargo, para proveer de información fiable y de diversas características a estos programas de simulación, es muy necesario contar con servidores que puedan disponer de datos de manera interactiva, para que la información pueda ser visualizada y descargada de manera fácil y rápida. Por ejemplo, ROLLINS (2009) desarrolló el LANDFIRE, que entrega información espacial sobre el combustible forestal y los regímenes de incendios para los Estados Unidos en píxeles de 30 m de resolución (<http://www.landfire.gov>). Por otra parte, KRŠNIK et al. (2020) han implementado un servidor de datos para Cataluña a una resolución espacial de 20 m. Estos datos, que combinan información topográfica y vegetacional, permiten evaluar los riesgos del combustible y del comportamiento del fuego bajo diferentes escenarios meteorológicos para toda Cataluña. En Europa, existe información disponible a escala paneuropea tanto a nivel topográfico, como vegetacional. Información en relación con la elevación, pendiente, y exposición se encuentra disponible a nivel global (TADONO et al., 2016), que, a través de un modelo superficial del terreno, es posible derivar las variables ya mencionadas. Por otra parte, información referente a los atributos de dosel de copas como cobertura (%) y altura (m), se encuentran disponibles a través de HANSEN et al. (2013) y LANG et al. (2023), respectivamente. Además, las variables de combustibles de copas también se encuentran disponibles para toda Europa y actualizadas para el año 2020 (ARAGONESES et al., 2024; KUTCHARTT et al., 2024b). Por último, los combustibles superficiales se encuentran disponibles tanto a nivel global (PETTINARI & CHUVIECO, 2016), como a escala paneuropea (ARAGONESES et al., 2023), este último se encuentra disponible a una resolución espacial de 1 km. No obstante, toda la información descrita anteriormente carece de un servidor que permita organizar los datos ráster de manera interactiva y armonizada para todos los países en Europa. Un servidor paneuropeo, como única fuente de datos para correr simulaciones, toma una gran relevancia para países que aún no cuentan con dicha información, hasta que tal información pueda ser mejorada mediante datos locales, como actualmente sucede en zonas de Portugal o España, en que los modelos de combustibles han sido generados a partir de datos LiDAR y trabajo de campo a una alta resolución.

## 2. Objetivos

La presente comunicación tiene como objetivo generar y entregar un conjunto de datos coherentes en formato ráster que permitan caracterizar el peligro y el comportamiento de incendios forestales a escala paneuropea mediante un servidor interactivo. Específicamente, el trabajo tiene como propósito i) presentar mapas de biomasa aérea (BA; Mg/ha), combustibles de copas (ABD; m y DAD; kg/m<sup>3</sup>) y combustibles superficiales a escala paneuropea; ii) armonizar los datos en un mismo sistema de coordenadas y a una misma resolución espacial (100 m), que permita correr simulaciones de incendios forestales para todos los países con información estándar; iii) proveer métricas de incertidumbres para los combustibles de copas mediante el error medio cuadrático y el error porcentual medio absoluto; y iv) distribuir los datos ráster entre distintos niveles de NUTS (Nomenclatura de las Unidades Territoriales Estadísticas) mediante una plataforma Web-GIS, lo que organiza la información ráster desde países hasta provincias (desde el NUTS 0 al NUTS 3), optimizando su tiempo de descarga según la necesidad del usuario, en caso que no se requiera descargar todo el sistema

paneuropeo.

### 3. Metodología

El área de estudio abarcó todo el continente paneuropeo, incluyendo a países que no forman parte de la EU-27, como Suiza o el Reino Unido, lo que se traduce en un área aproximada de 4,9 millones de km<sup>2</sup>. Para toda el área de estudio, se produjeron los mapas de biomasa aérea, combustibles de copas, y combustibles superficiales, este último según la metodología y codificación propuesta por SCOTT & BURGAN (2005), mientras que las capas relacionadas con la topografía (elevación, pendiente y exposición), y con los atributos de dosel de copas, como altura y cobertura se obtuvieron de trabajos previos (detallados en la sección 3.1), que disponen de conjuntos de datos a nivel global y de forma actualizada.

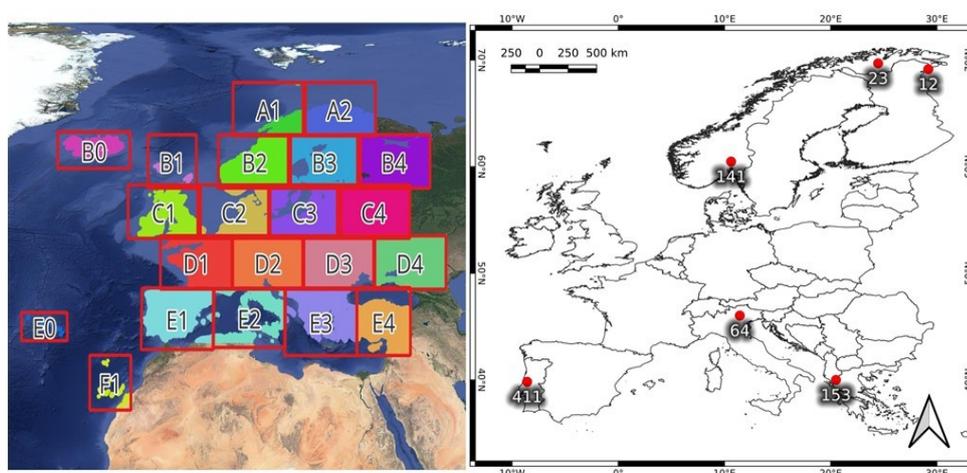


Figura 1. Área de estudio que abarca todo el territorio paneuropeo, incluyendo las 21 cuadrículas utilizadas para el entrenamiento, predicción y actualización al año 2020 de la de biomasa aérea total (izquierda; PIROTTI et al., 2023), y las áreas de validación para las variables de combustibles de copas (derecha; KUTCHARTT et al., 2024a).

#### 3.1 Coberturas obtenidas mediante trabajos previos

La información topográfica, como las variables de elevación (m), pendiente (°) y exposición (°), son fundamentales para poder predecir el comportamiento de un incendio forestal, dicha información fue derivada a partir de un modelo digital de superficie global (ALOS World 3D), que originalmente estaba a una resolución espacial de 30 m (1 arcsec), mediante el instrumento de teledetección pancromática. Esta información ha sido proporcionada por la Agencia de Exploración Aeroespacial de Japón (TADONO et al., 2016) mediante el ALOS PRISM. Las tres variables fueron remuestreadas a una resolución espacial de 100 m, para armonizar los datos con las posteriores capas de vegetación producidas por los autores.

Misma situación se reporta con las variables de altura (m) y cobertura de dosel (%). En el caso de la altura de dosel, esta variable fue proporcionada por LANG et al. (2023) a una resolución espacial de 10 m, dicha información se obtuvo mediante modelos de Deep Learning, combinado con datos de GEDI (Global Ecosystem



Dynamics Investigation) y Sentinel-2. Aunque últimamente se han reportado trabajos que han llegado a una resolución espacial de 1 m (TOLAN et al., 2024), debido a que las capas han sido remuestreadas a una resolución espacial menor (100 m), esta información no fue considerada en el presente trabajo. Los datos de cobertura de dosel fueron proporcionados por HANSEN et al. (2013) mediante datos satelitales a una resolución de 30 m, incluyendo actualizaciones sobre las pérdidas de cobertura por perturbaciones (deforestación, incendios forestales, daños por viento, etc.). Al igual que con las variables topográficas, los píxeles fueron remuestreados desde su tamaño original a los 100 m propuestos en el sistema paneuropeo.

### 3.2 Mapa de biomasa mediante datos satelitales e inteligencia artificial

La primera capa generada fue un mapa de biomasa aérea (Mg/ha) mediante 49 covariables independientes, obtenidas a través de diferentes sensores y productos derivados de la teledetección. Las covariables utilizadas fueron bioclimáticas (19), mapas de cobertura del uso del suelo, altura y cobertura del dosel, composición de índices de vegetación (EVI y NDVI) obtenidos mediante Sentinel-2, datos SAR mediante Sentinel-1 y ALOS-2, un mapa vegetacional de especies forestales y un modelo digital de elevación mediante el ALOS World 3D (PIROTTI et al., 2023). Las fuentes originales de resolución espacial variaron entre 10 m (altura del dosel) y 1 km (datos bioclimáticos), por lo que la información fue remuestreada a una resolución espacial de 100 m, para luego ser utilizada en el entrenamiento de algoritmos de machine learning mediante un muestreo estratificado a partir de un mapa de biomasa existente de 2018 (SANTORO & CARTUS, 2021). Se utilizó el programa R mediante su librería H2O (LEDELL et al., 2022). Para la predicción de la biomasa total área, se corrieron 13 modelos, en los que se seleccionaron aproximadamente 200.000 áreas de muestreo para su entrenamiento, utilizando la misma cantidad para su validación. Por ello, el mapa de biomasa previo fue de suma importancia, ya que este fue utilizado para la predicción y actualización de un nuevo mapa de biomasa para el año 2020. Debido a la gran variabilidad de las zonas bioclimáticas en Europa, desde vegetación esclerófila de baja altura y poca cobertura en zonas mediterráneas hasta bosques boreales en países escandinavos, los modelos fueron estratificados dividiendo Europa a través de 21 cuadrículas (ver Figura 1). De esta manera se limitó la varianza de las diferentes variables utilizadas, creando modelos más específicos a través de áreas más homogéneas, y extrayendo las métricas de error, como el error cuadrático medio (ECM) o el error absoluto medio (EAM), individualizando las métricas de error para cada cuadrícula.

### 3.3 Mapa de combustibles de copas

Los combustibles de copas están referidos a la altura base del dosel (ABD) que es la distancia vertical desde el suelo hasta el inicio de la copa en metros, y a la densidad aparente del dosel (DAD) que es la fracción entre la biomasa foliar (ramillas finas y hojas) y el volumen del dosel en kg/m<sup>3</sup> (KUTCHARTT et al., 2024b). Para la obtención de ambas variables, fueron combinados datos satelitales con ecuaciones alométricas específicas para las 16 especies forestales más representativas en Europa. La primera variable a resolver fue la ABD, utilizando la información de la altura del dosel proporcionada por LANG et al. (2023), como también los datos generados por BONANNELLA et al. (2022), que entregaban información sobre la probabilidad de la presencia de una de las 16 especies forestales, entregando una variabilidad espacial necesaria para su estimación. Por lo tanto, teniendo el valor



de un píxel como la altura total y sabiendo la presencia de la especie dominante, se crearon ecuaciones alométricas con más de 85.000 árboles inventariados entre países provenientes de distintas latitudes. En función de su altura, se buscó predecir la ABD a través de modelos lineales utilizando algoritmos de regresión robusta de mínimos cuadrados recortados, lo que buscaba limitar el impacto de algunos valores atípicos y otras desviaciones del modelo de regresión lineal. Debido a la incerteza de la especie dominante por píxel, no se seleccionó una sola especie por píxel, sino que se ponderaron según su probabilidad de presencia entre las especies más importantes. A continuación, se presentan las ecuaciones que se ajustaron y utilizaron para la predicción de la ABD:

$$ABD = f(AD, sp, \varepsilon) \quad (1)$$

$$\hat{\beta} \text{ (LTS)} = \operatorname{argmin}_{\beta \in R^p} \sum_{i=1}^n r_{[i]}^2(\beta) \quad (2)$$

Donde, en la ecuación 1, AD = altura del dosel, sp = conjunto de datos ráster que representa la probabilidad de las especies arbóreas y

$$r_{[i]}^2(\beta) = \frac{\varepsilon}{y_i - \beta^T X_i}$$

Para determinar la variable DAD el proceso fue más complejo, ya que se debió estimar la biomasa foliar del dosel. Por lo tanto, mediante la diferencia entre la altura total y la ABD se determinó el volumen del dosel, y a través de las ecuaciones alométricas a nivel de componente arbóreo que fueron obtenidas de FORRESTER et al. (2017), quienes armonizaron ecuaciones para toda Europa, se pudo obtener la masa seca. Es decir, a partir de la biomasa total y la biomasa foliar obtenida mediante estimaciones alométricas, se obtuvo el porcentaje de biomasa foliar, siendo esto clave para su estimación. Es importante mencionar, que las funciones para estimar la biomasa a nivel de componentes fueron en función del DAP (cm). Sin embargo, la información disponible a partir del satélite era solo la altura y no sus respectivos diámetros, por lo tanto, se crearon ecuaciones alométricas a la inversa, en donde el DAP (cm) fue predicho en función de la altura reportado por el píxel. A continuación, se presentan las ecuaciones de manera simplificada y paso por paso de cómo se determinó la variable DAD:



$$DAD = BA_{\text{foliar}} / VD \quad (3a)$$

$$BA_{\text{foliar}} = f(DAP, BA_{\text{total}}, sp, \epsilon) \quad (3b)$$

$$VD = AD - ABD \quad (3c)$$

$$DAP = f(AD, sp, \epsilon) \quad (3d)$$

Donde, el  $BA_{\text{foliar}}$  = la biomasa aérea foliar fina entre ramillas y hojas (Mg/ha) que proviene de la biomasa aérea total ( $BA_{\text{total}}$ ),  $VD$  = volumen del dosel ( $m^3$ ),  $AD$  = altura del dosel (m),  $DAP$  = diámetro a la altura del pecho a 1,3 m (cm),  $sp$  = presencia de la especie forestal y  $\epsilon$  = error del modelo utilizado. Más detalles sobre las fórmulas se pueden encontrar en KUTCHARTT et al. (2024b).

A continuación, se muestra el flujo de trabajo completo, destacando cada uno de los sensores y productos de teledetección utilizados (parte superior de la Figura 2) con su resolución espacial original (KUTCHARTT et al., 2024b), en combinación con la inteligencia artificial (algoritmos de *machine learning*) para la estimación de la biomasa aérea total, y con las ecuaciones alométricas que muestran sus respectivas variables independientes utilizadas en la predicción de sus respectivas variables respuesta, las que luego fueron utilizadas tanto para determinar la ABD, como la estimación de la biomasa foliar a partir de la biomasa total obtenida en PIROTTI et al. (2023).

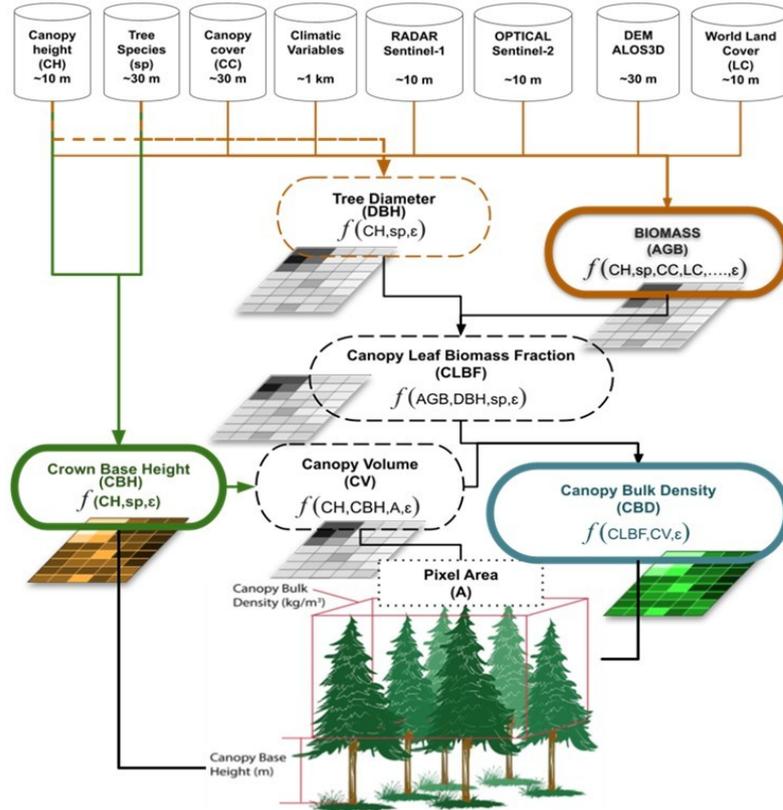


Figura 2. Flujo de trabajo combinando diferentes fuentes de datos de teledetección, inteligencia artificial y relaciones alométricas para determinar la biomasa aérea total y los combustibles de copas a escala paneuropea (KUTCHARTT et al., 2024b).

### 3.4 Métricas de error e incertidumbres en los combustibles de copas

Para la obtención de capas robustas en la estimación de combustibles de copas, tanto para los modelos alométricos creados como para los mapas finales, estas fueron validadas mediante las siguientes métricas de error:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (4)$$

$$ECM = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

$$EPMA^* = \frac{100}{n} \sum \frac{|y_i - \hat{y}_i|}{(y_i + \hat{y}_i)} * 2 \quad (6)$$

Donde, n = número de los valores utilizados para calcular la precisión,

$y_i$   
 $\hat{y}_i$   
 $\bar{y}_i$



El error porcentual medio absoluto (EPMA\*) fue modificado ligeramente con respecto a la fórmula común de EPMA, ya que en este caso el valor observado puede llegar a ser cero para el ABD, siendo habitual que las copas lleguen hasta el suelo, especialmente en árboles jóvenes. Más detalles de como se calcularon la estimación de la incertidumbre, utilizando la regla de la cadena en el caso de la ABD, y la simulación de Monte-Carlo (MC) que incluyó un proceso interactivo, en el caso de la DAD, se encuentran en KUTCHARTT et al. (2024b). Esto último tiene mucha relevancia, ya que existe una propagación del error a partir de los productos de teledetección utilizados, especialmente en la incertidumbre en el mapa de especies forestales, y porque, combinados con las ecuaciones alométricas, los errores aumentan la incertidumbre en los modelos utilizados.

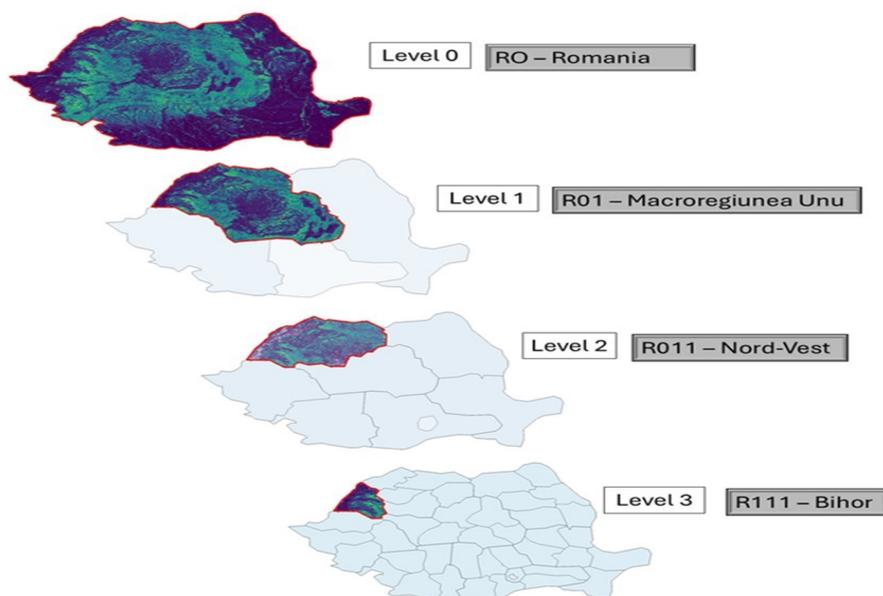
### 3.5 Modelo de combustible superficial

La metodología utilizada para determinar los modelos de combustibles superficiales se basó en SCOTT & BURGAN (2005), con adaptación a un marco europeo por ARAGONESES et al. (2023). A través de la metodología propuesta, los combustibles superficiales quedaron definidos por la disponibilidad de carga de combustible (disponibilidad de biomasa/vegetación) y las condiciones climáticas (húmedo o seco). La vegetación fue dividida en tres principales categorías, bosques, matorrales y pastizales. Otras categorías caracterizaron condiciones incombustibles, como las áreas urbanas, fuentes de agua, nieve, entre otras. Mediante la metodología propuesta, fue de suma importancia llegar a un consenso entre las diferentes coberturas de uso de suelo, CORINE Landcover 2018 a una resolución espacial de 100 m (BÜTTNER et al., 2021), Copernicus global land cover (GLC) a la misma resolución (COPERNICUS, 2021) y ESA World Cover 2021 v100 a 10 m de resolución espacial (ZANAGA et al., 2021). El consenso entre las distintas capas de uso de suelo, también incluyó información sobre la estructura de la vegetación, como la altura y cobertura, y también de la biomasa de la vegetación mediante un proceso de árbol de decisiones. De esta manera, por ejemplo, si la categoría de uso indicaba bosques de coníferas, pero la altura, cobertura y biomasa indicaban valores bajos, esto permitía hacer una verificación, y en caso de ser necesario, una corrección al código final asignado al modelo de combustible, modificando el código inicial a un código referido a una vegetación de matorral o pastizal. Para obtener la codificación final del modelo de combustible, fue necesario cruzar la información de los usos de suelo con valores de humedad calculados a partir de un índice de aridez. Tal índice fue estimado mediante datos bioclimáticos (precipitación, temperaturas, irradiación solar etc.) a una resolución espacial de 1 km por HIJMANS et al. (2005); se distinguieron seis categorías según lo propuesto por la FAO-UNEP (UNEP, 1992).

### 3.6 Desarrollo de una plataforma Web-GIS a escala paneuropea

Todas las capas anteriormente descritas (nueve) fueron incorporadas en una aplicación de *Google Earth Engine* (GEE), la que ofrece una infraestructura de *big-data* necesaria para organizar las capas ráster utilizadas y creadas durante el trabajo, incluyendo, además, las dos capas de incertidumbre referidas a los combustibles de copas. También permite compartir la información en línea mediante un servidor paneuropeo de mapas de combustibles (KUTCHARTT et al., 2024c; ver <https://www.cirgeo.unipd.it/fire-res/app/>). El entorno GEE permite vincular las capas ráster a un portal web, mediante una interfaz de fácil manejo, utilizando también el entorno R para algunos pasos de procesamiento, como el

subconjunto de datos en los distintos niveles administrativos propuestos en los diferentes NUTS geográficos (EUROSTAT, 2022), almacenando más de 1.800 archivos ráster para su descarga (ver ejemplo en Figura 3).



*Figura 3. Demostración de los distintos niveles de capas ráster disponibles en el servidor de combustibles a nivel paneuropeo, desde el nivel 0 hasta el nivel 3 en el caso de Rumanía (KUTCHARTT et al., 2024c).*

Además, el servidor de combustibles a nivel paneuropeo permite al usuario consultar a nivel de píxel. Es decir, el usuario puede interrogar un píxel (en el que se fijará un punto en rojo y permanecerá en activo), en el cual se abrirá una tabla de atributos con todas las variables disponibles de cada uno de los ráster ofrecidos por el servidor. De esta manera, el usuario, antes de descargar los datos, puede explorar la información de manera interactiva. Por último, esta aplicación permite descargar los datos de manera individual por ráster, como también mediante una carpeta comprimida en formato .zip, permitiendo la descarga de los nueve rásters en una única carpeta, además de los dos ráster de incertidumbre en el caso de los combustibles de copas.

#### 4. Resultados

Los resultados presentados en esta comunicación son una síntesis de diversos trabajos realizados y publicados en diferentes revistas por los autores. En general, los resultados reportados tanto para la estimación de la biomasa aérea total (Mg/ha), como de los combustibles de copas, ABD (m) y DAD (kg/m<sup>3</sup>) fueron satisfactorios, considerando especialmente la dificultad en la escala en que se trabajó (paneuropeo), como también en la dificultad de trabajar con las variables de combustibles de copas. Es importante hacer hincapié en que los resultados fueron validados mediante un set de datos robustos, que fueron utilizados como datos independientes aproximados para el año 2020, localizándose en distintas formaciones vegetacionales.

##### 4.1 Resultados del mapa de biomasa

Los resultados obtenidos con el mapa de biomasa fueron separados entre la inclusión y no inclusión de los datos referentes a la vegetación de las 16 especies

forestales entregadas por BONANNELLA et al. (2022), con el objetivo de ver su impacto en las métricas de error. Es decir, de las 49 covariables independientes que se utilizaron para predecir la biomasa, se probó en un principio con tan solo 33 variables exploratorias, para luego utilizar el conjunto completo de datos. Los resultados fueron divididos por las 21 cuadrículas propuestas en la metodología (ver Figura 1), calculando el ECM de cada cuadrícula como se aprecia en la Figura 4. Algunas cuadrículas como la B0, B1, o B4, entre otras no fueron incluidas debido a sus bajos valores de biomasa. El error obtenido que consideró toda Europa fue de un ECM de 32,4 Mg/ha y un EAM de 21,5 Mg/ha, mientras que, al considerar solo las cuadrículas individuales, se apreciaron errores mayores, como en el caso de la cuadrícula D2, en que el ECM fue de 54,7 Mg/ha, la que estuvo fuertemente influenciada por las fuertes pendientes encontradas en regiones alpinas. Sin embargo, a excepción de las cuadrículas D2 y D3, los ECM no superaron los 40 Mg/ha en el caso del modelo que utilizó todas las covariables disponibles. Más detalles se encuentran disponibles en PIROTTI et al. (2023).

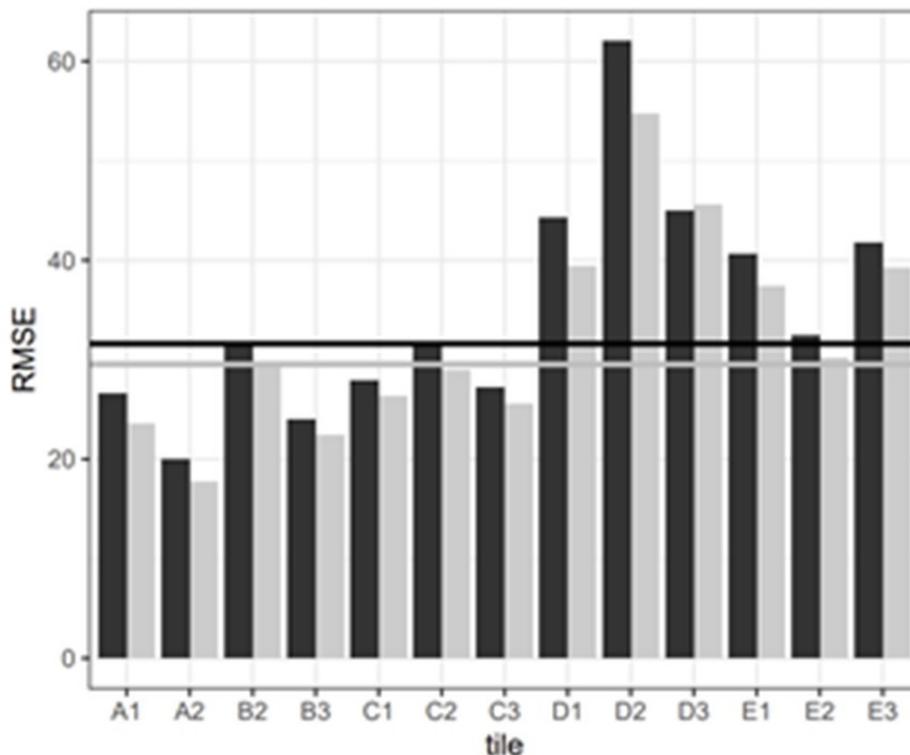


Figura 4. Resultados del ECM (Mg/ha) por cada cuadrícula, utilizando 33 variables exploratorias (negro) y los 16 tipos de vegetación por especies forestales (gris). Los errores disminuyeron en cada una de las cuadrículas (PIROTTI et al., 2023).

Los resultados también fueron comparados con el mapa producido por el Climate Change Initiative Biomass (Biomass\_CCI) de la European Space Agency (ESA) (SANTORO & CARTUS, 2021), obteniendo diferencias que se reflejan a través de una desviación estándar de 55 Mg/ha y un sesgo de 17 Mg/ha (PIROTTI et al., 2023), distribuyéndose los mayores errores en las zonas alpinas y pirineos, que



representaban una gran dificultad por sus terrenos escarpados. Por otra parte, MICHELETTO (2024) comparó los resultados del mapa de biomasa con datos a partir de los inventarios nacionales forestales, dicha información se encontraba disponible a nivel de regiones (datos agregados) en países como Italia, Francia, Alemania, Polonia, Suecia, y Finlandia, identificando los mayores errores en regiones con alta presencia de pendientes, confirmando que el mapa de biomasa incrementa sus errores en base a la caracterización del terreno.

#### 4.2 Resultados de los combustibles de copas

Los resultados obtenidos en los combustibles de copas fueron divididos entre dos tipos de validación. La primera incluyó solo siete áreas específicas en Portugal, que cuantificó el ABD y el DAD con datos LiDAR obtenidos entre los años 2020 y 2021 (MIHAJLOVSKI et al., 2023) mediante tres métricas de error (Tabla 1). La segunda validación incluyó las 804 muestras georreferenciadas de todo el sistema paneuropeo (Tabla 2), distribuyéndose las muestras entre Grecia (153), Italia (64), Noruega (176) y Portugal (411). Las muestreas georreferenciadas en campo fueron tomadas entre los años 2010 y 2020, y las áreas de las muestras variaron entre 314 y 1.256 m<sup>2</sup>.

Tabla 1. Métricas de precisión en siete áreas de Portugal con mapas de combustibles de copas derivados de datos LiDAR (KUTCHARTT et al., 2024a).

Combustibles de copas	ABD (m)	DAD (kg/m <sup>3</sup> )
ECM	0,890	0,020
EPMA	54%	57%
R	0,749	0,987

Tabla 2. Métricas de precisión utilizando los 804 muestreos, y combinando los resultados con las diferentes cubiertas forestales (%), para ambos combustibles de copas (KUTCHARTT et al., 2024a).

Métricas de precisión				
Combustibles de copas	ABD (m)		DAD (kg/m <sup>3</sup> )	
Cubierta forestal (%)	CF >0	CF >80	CF >0	CF > 80
N	804	322	486	225
ECM	3,9	3,8	0,109	0,090
EPMA	61%	50%	77%	56%
R	0,445	0,524	0,309	0,412

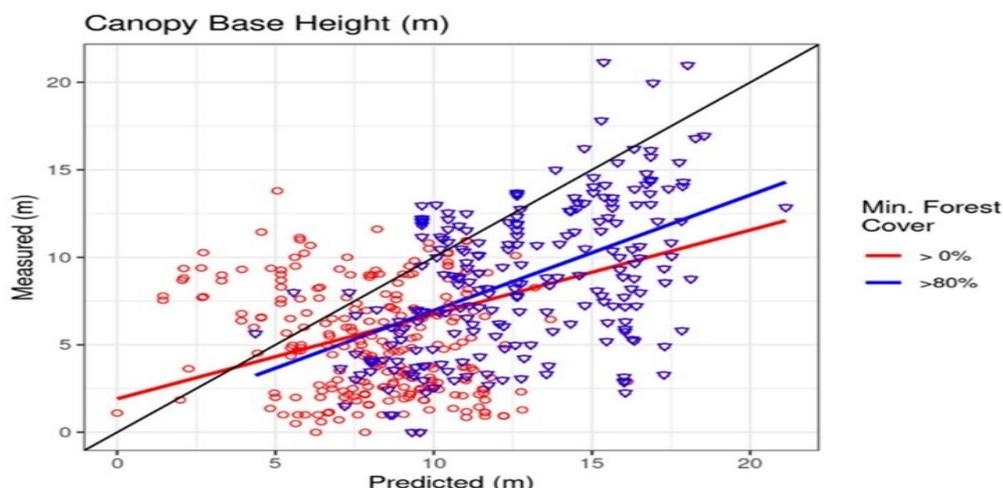


Figura 5. Validación con datos de campo para la altura base del dosel (m) a partir de todas las muestras (rojo) y con las muestras que caen solo en píxeles con una cobertura forestal igual o superior al 80% (azul) (KUTCHARTT et al., 2024b).

Las figuras 5 y 6, muestran la distribución y ajuste sobre el efecto de la cobertura forestal en ambas variables (ABD y DAD), lo que demuestra un mejoramiento en su ajuste a partir de píxeles que concentraban más de un 80% de cobertura.

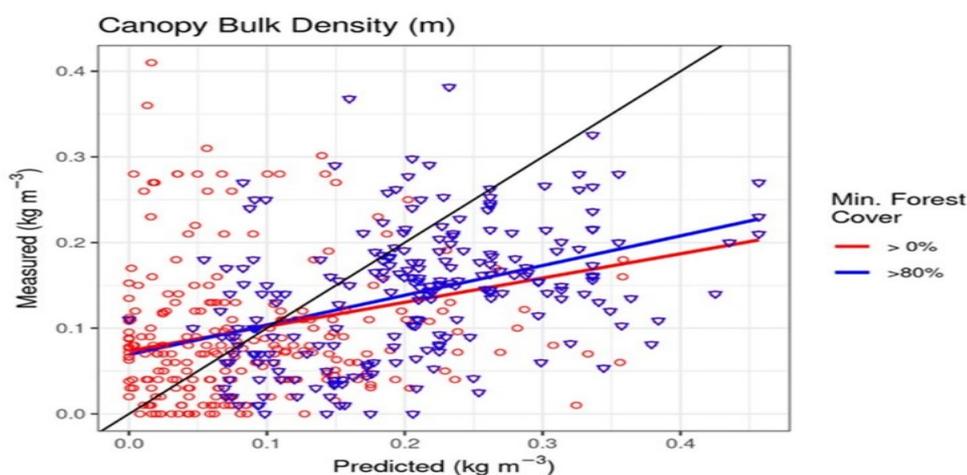


Figura 6. Validación con datos de campo para la densidad aparente del dosel ( $\text{kg}/\text{m}^3$ ) a partir de todas las muestras (rojo) y con las muestras que caen solo en píxeles con una cobertura forestal igual o superior al 80% (azul) (KUTCHARTT et al., 2024b).

Los resultados obtenidos en el mapa de ABD mostraron mayores incertidumbres en las áreas alpinas y zonas boreales, identificándose una sobre estimación en esta variable (Figura 7). En el caso de las zonas boreales, los valores de ABD encontrados fueron relativamente bajos, pero con grandes incertidumbres. En general, se han identificado valores de ECM de entre 3 y 6 metros, lo que están fuertemente influenciado por la capa ráster de altura de dosel disponible de LANG et al. (2023), en la que en muchas áreas se evidencia una sobreestimación de las alturas por los efectos de las pendientes.

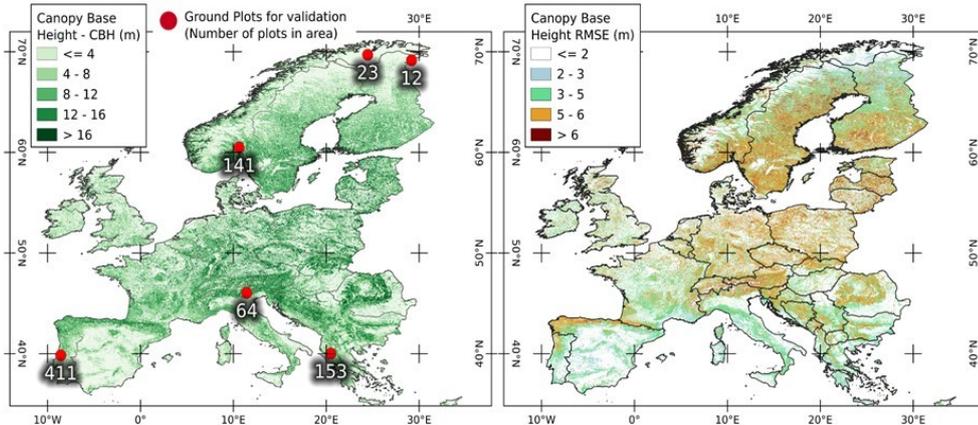
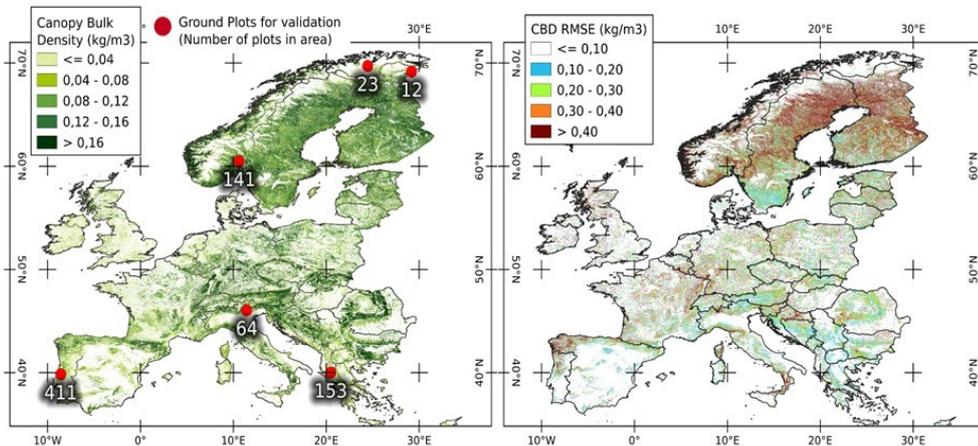


Figura 7. Mapa de la altura base del dosel (ABD) en metros con las ubicaciones aproximadas y número de las muestras de campo (puntos rojos) utilizadas para la validación (izquierda), y mapa de incertidumbre expresado con el error cuadrático medio (derecha) (KUTCHARTT et al., 2024b).

Por otra parte, los resultados obtenidos en la estimación de la DAD están fuertemente correlacionados con la fracción de la biomasa foliar, ya que esta fracción depende tanto de la edad y como del estado de crecimiento en los árboles. Sin embargo, los resultados mostrados en la Figura 8 (izquierda) resultaron relativamente bajos, mostrando una tendencia contraria a los resultados obtenidos en la ABD, concentrándose los valores mayoritariamente menores a 0,04 kg/m<sup>3</sup>. Cabe recordar que, para la estimación de esta variable, el componente de biomasa en las ramas fue excluido de la masa dividida por el volumen del dosel, y también, que, en este último, las copas de los árboles no fueron segmentadas, incluyendo toda el área del dosel sin descontar los claros dentro del dosel.





*Figura 8. Mapa de la densidad aparente del dosel (DAD) en kilogramos por metro cúbico con las ubicaciones aproximadas y número de las muestras de campo (puntos rojos) utilizadas para la validación (izquierda), y mapa de incertidumbre expresado con el error cuadrático medio (derecha) (KUTCHARTT et al., 2024b).*

#### **4.3 Mapa de combustible superficial**

El modelo de combustible paneuropeo fue generado principalmente por coberturas de uso de suelo. Sin embargo, esta información podría tener errores desde el satélite al asignar un tipo de uso de suelo, como también cambios dinámicos por perturbaciones. Mediante la metodología propuesta, los principales modelos de combustibles se basaban en tres tipos de usos de suelo: bosques, matorrales, y pastizales. Para evitar errores al asignar los principales modelos de combustibles, se ha desarrollado una aplicación móvil llamada FIRE-RES Geo-Catch app (KUTCHARTT et al., 2023), que tiene como objetivo recolectar imágenes frontales geo-etiquetadas, que puedan describir el paisaje e incluir información sobre sus coordenadas, precisión en su localización y orientación. De esta manera, se puede validar, por ejemplo, si un píxel al cual se le asignó el código SH7 (147), en el que queda explícitamente que el paisaje debería estar dominado por una condición de matorral, antes de entender si el píxel se encuentra con una alta o baja cantidad de combustible, o si esta en una condición húmeda o seca, es importante validar si el uso de suelo visto en la imagen corresponde con la información que se derivó desde el satélite.

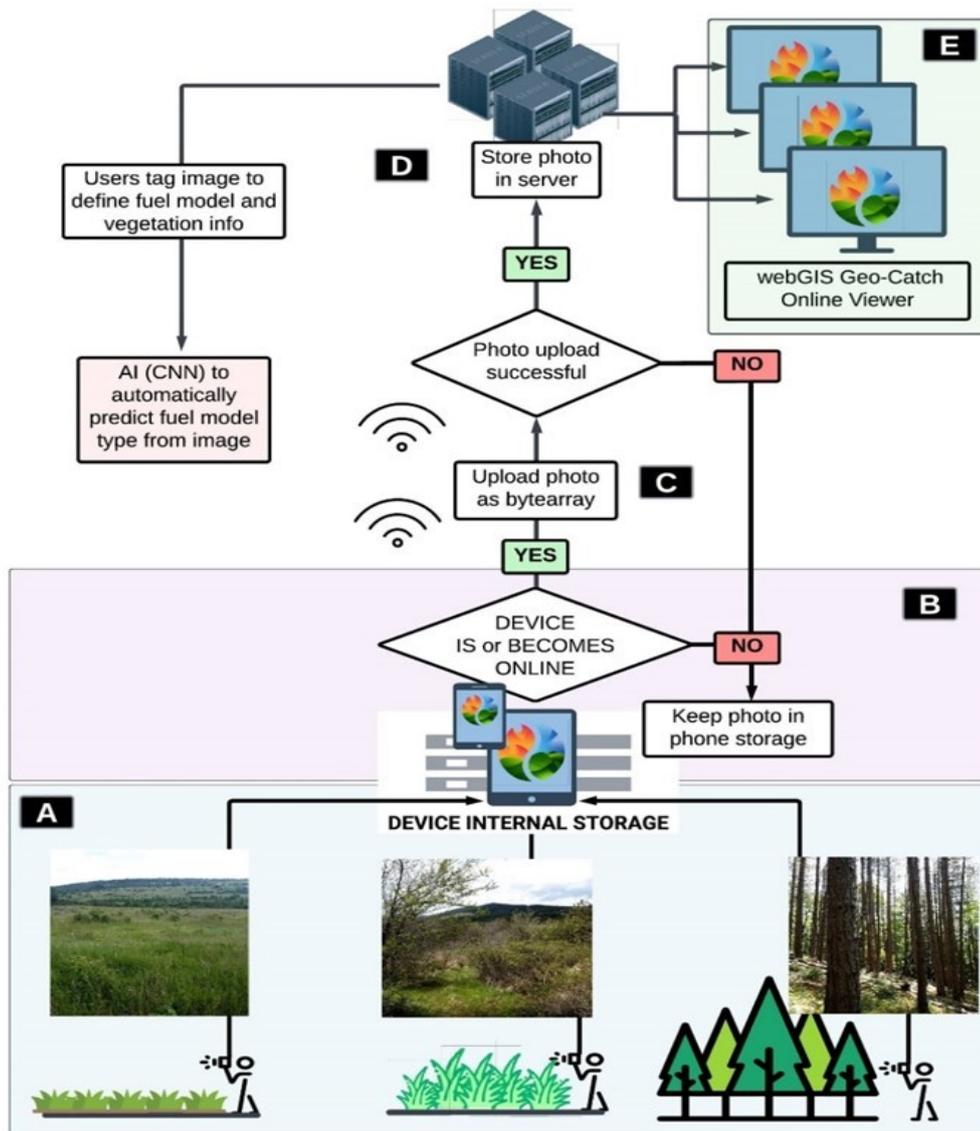
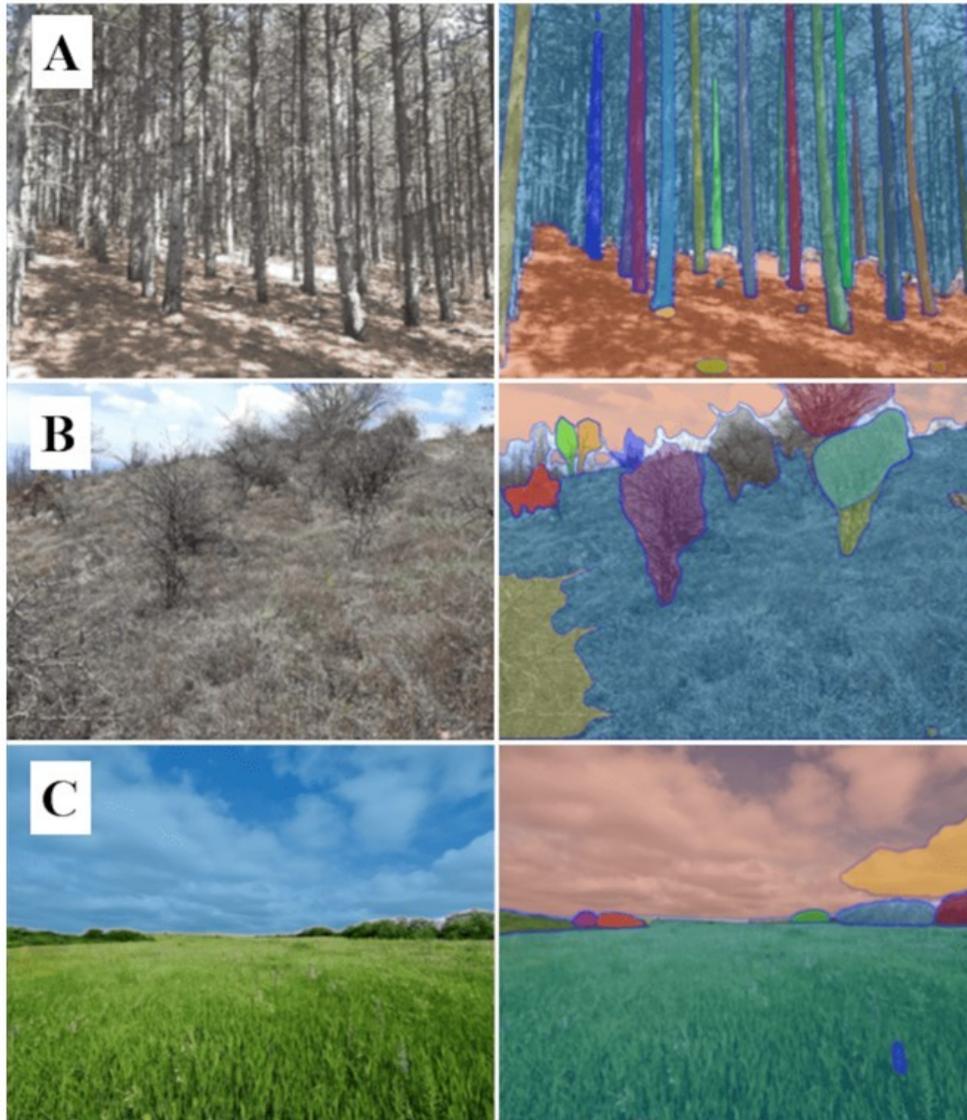


Figura 9. Flujo de trabajo desde la recolección de datos en campo hasta el almacenamiento de las imágenes geo-etiquetadas y orientadas en un servidor (Web-GIS) que almacena la información de manera simultánea, una vez que el usuario captura y carga la imagen en el servidor (KUTCHARTT et al., 2023).

Mediante la Figura 9 se pueden apreciar algunos ejemplos de cómo deben ser tomadas las imágenes geo-etiquetadas para su posterior posprocesamiento. Más ejemplos están disponibles en el manual de SCOTT & BURGAN (2005), en que cada modelo de combustible cuenta con una imagen que representa el paisaje del código de combustible en cuestión.

En la Figura 10 se muestran resultados de la segmentación, en la que las imágenes originales fueron segmentadas, dependiendo del contexto del paisaje. En el ejemplo A, los troncos de los árboles fueron fácilmente identificados, como también los arbustos en el ejemplo B. Por último, en el ejemplo C, se identifica claramente el pastizal de manera continua. Actualmente el servidor cuenta con

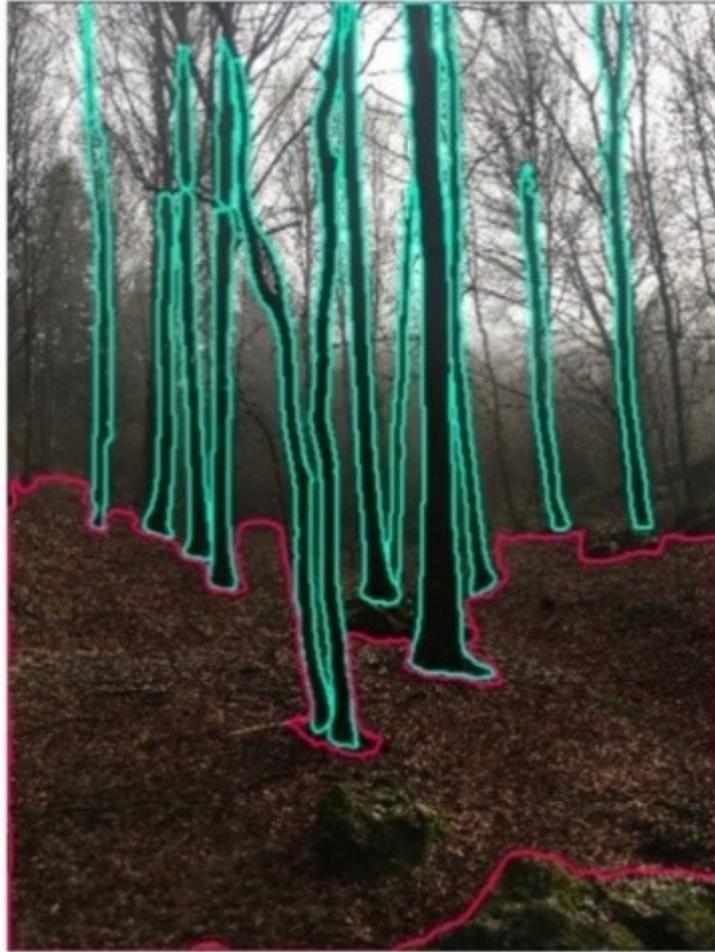
9.647 imágenes geo-etiquetadas como parte de una investigación en curso que permita validar el modelo de combustible paneuropeo con información de campo robusta y bien distribuida por toda Europa.



*Figura 10. Ejemplo de segmentaciones a partir de imágenes geo-etiquetadas a partir de algoritmos encontrados en KIRILLOV et al. (2023).*

Es importante mencionar, que, mediante técnicas de inteligencia artificial, como algoritmos utilizados en Deep Learning, no solo permiten segmentar los objetos, sino, que también permite extraer otros atributos de la vegetación, como rangos en la altura de la vegetación a partir de segmentaciones como la mostrada en la imagen de abajo por CARMELO (2024). Esto permitiría profundizar en la

asignación del código final del combustible, y no solo validando su principal uso de suelo.



*Figura 11. Ejemplo de segmentación de objetos mediante técnicas de Deep Learning a partir de imágenes obtenidas a través de teléfonos móviles (CARMELO, 2024).*

#### **4.4 Servidor de combustibles a escala paneuropea**

Mediante una aplicación de *Google Earth Engine*, que se complementa con funciones en el ambiente de programación en R (AYBAR et al., 2020), se ha creado un servidor de datos, en que todos los ráster creados y recopilados a nivel paneuropeo durante el proyecto FIRE-RES, se encuentran organizados de manera armonizada en una plataforma interactiva. Ella permite visualizar la información y descargar los datos ráster a distintos niveles geográficos, desde países hasta provincias según niveles de NUTS, incluyendo más de 1.800 figuras en formato ráster para su descarga (ver Figura 12). La obtención de la información puede ser mediante la descarga de todo el compilado de rásters en el NUTS seleccionado, a través de una carpeta comprimida en formato zip, como también mediante descargas individuales según la necesidad del usuario. Antes de la descarga, el usuario tiene la posibilidad de interrogar cada píxel, es decir, una vez que se ha seleccionado el píxel, automáticamente se visualiza una tabla con la información de cada una de las capas disponibles en el servidor, incluyendo las capas de incertidumbre en los combustibles de copas.

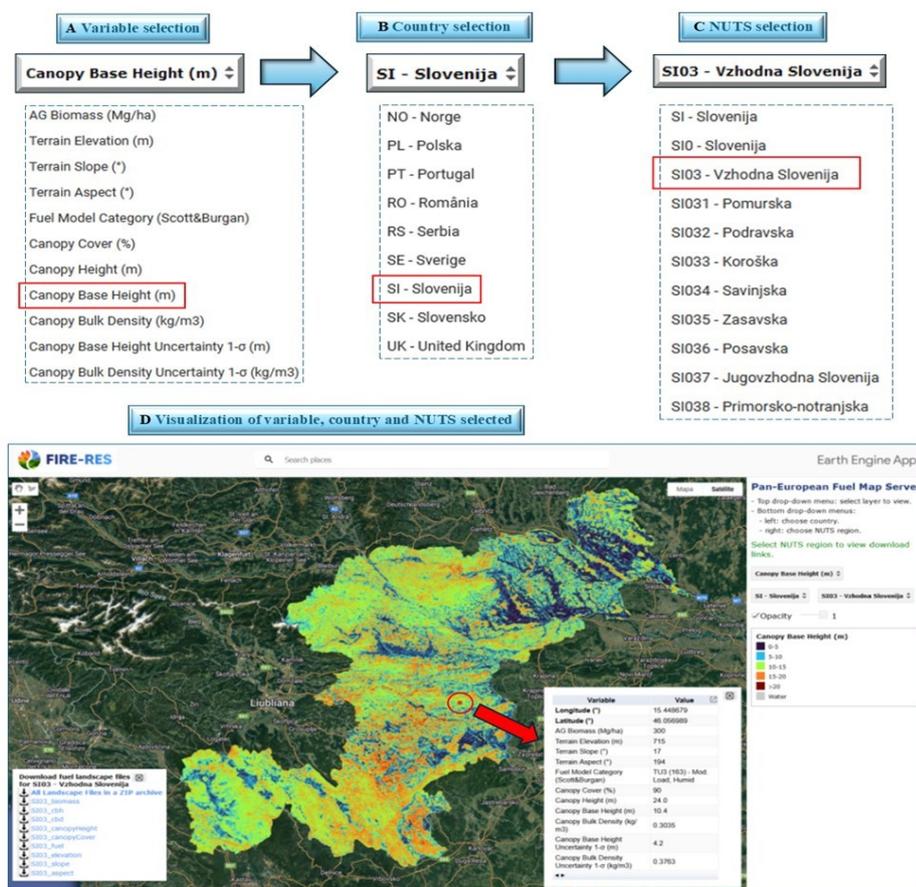


Figura 12. Una vista del servidor y como funciona el proceso de descarga de los datos, seleccionando primero la variable de interés, luego seleccionado el país y el nivel de NUTS requerido, lo que permite visualizar el ráster e interrogar cualquier píxel en cuestión antes de proceder a la descarga de datos (KUTCHARTT et al., 2024c)

## 5. Discusión

El primer mapa que se produjo fue el de la biomasa aérea total. Si bien ya existían mapas a escala global o continental, como los mapas de biomasa que fueron comparados por AVITABILE & CAMIA (2018) para toda Europa, comparando las coberturas de biomasa de diferentes autores entre los años 2008 y 2014, incluyendo información armonizada que contaba con información de campo. Estos mapas no solo provenían de diferentes años, también con distintas resoluciones espaciales y metodologías, siendo necesario desarrollar una metodología propia que permita ir actualizando esta información de manera permanente. En la actualidad, el mapa más utilizado y actualizado ha sido generado por el proyecto de la ESA Climate Change Initiative (Biomass\_cci), siendo actualizado permanentemente con datos satelitales disponibles para el año 2020, principalmente alimentado por datos SAR (ALOS-PALSAR-2 y Santinel-1) y estructura de la vegetación, como altura y densidad de dosel (SANTORO et al., 2024). Dicha información es de gran ayuda para monitorear los cambios de biomasa en el tiempo. La cuantificación de la biomasa no solo permite poder comparar fluctuaciones de carbono, sino que también es una cobertura que ayuda a entender el peligro y el potencial comportamiento de un incendio forestal. La cobertura de biomasa tiene dos funciones, la primera es integrar esta información



como una de las variables en un simulador de incendios, y la segunda, de manera indirecta ayuda a estimar la biomasa foliar, que es una de las variables a considerar en el combustible de copas, específicamente en la DAD (kg/m<sup>3</sup>). Por lo tanto, es fundamental poder contar con información que haya sido rigurosamente validada con datos de campo. Debido a que la resolución espacial es de 100 m, es difícil validar con información proveniente de los inventarios forestales nacionales, ya que esta información se distribuye en superficies menores (500 o 1000 m<sup>2</sup>), lo que no cubre toda la variabilidad del píxel, como se explica en PIROTTI et al. (2023). Otra complicación es la temporalidad de los datos, ya que normalmente los inventarios forestales nacionales se realizan cada 10 años, lo que implica que no necesariamente la información satelital, que normalmente proviene de diferentes años por la combinación de diferentes sensores pueda estar disponible para un mismo año de interés. Haciendo muy difícil que la información satelital pueda ser comparada con información de campo en un mismo año. Aunque la información de campo, en la mayoría de los casos, proviene de años anteriores a la información obtenida mediante la teledetección, esta información puede ser actualizada mediante funciones de crecimiento, aunque no es el escenario ideal para una validación robusta en la estimación de la biomasa, ya que aumenta aún más su incertidumbre en la estimación.

Las capas que se desarrollaron posteriormente fueron los combustibles de copas (ABD y DAD). Debido a la dificultad de contar con información a nivel vertical de la vegetación, y con estratificación de la biomasa a nivel de componentes a escala paneuropea, se ha desarrollado un método innovativo, combinando información derivada de la teledetección con ecuaciones alométricas. Las principales fuentes de información a partir de datos satelitales fueron el mapa de biomasa generado por PIROTTI et al. (2023), un mapa de distribución de especies forestales por BONANNELLA et al. (2022), y una cobertura de altura de dosel generada por LANG et al. (2023). Los resultados son satisfactorios, ya que cuentan con un grado de precisión razonable para ser utilizados en la simulación de incendios forestales a escala paneuropea, sobre todo para países que aún no cuentan con información de combustibles para sus simulaciones. Sin embargo, es importante considerar las limitaciones de este trabajo, que comienzan con la incertidumbre de los productos generados a partir de la teledetección, que luego se une a la incertidumbre de los modelos alométricos específicos que se aplican a cada una de las 16 especies forestales. En el caso del mapa de especies forestales, este solo indica la probabilidad de la presencia de las especies en el píxel en cuestión, considerando que un píxel puede tener la presencia de dos o más especies en un mismo píxel de 100 m, para mitigar este problema, se trabajó mediante ponderadas. La importancia de identificar la especie o las especies de manera correcta dentro del píxel es fundamental, ya que, si esta información es errónea, esto también repercute en la selección del modelo alométrico a utilizar. Otra complicación de trabajar con esta cobertura vegetal, es que cubre solo las 16 especies forestales más importantes de Europa, pero no incluye otras especies importantes, sobre todo en plantaciones forestales que son propensas a incendios forestales, como en el caso de *Eucalyptus spp.*, muy propensas a incendios en el norte de España y Portugal.

En el caso de los modelos de combustibles superficiales, estos se obtienen mediante coberturas de uso de suelo, que integran información meteorológica del estado de humedad en la vegetación (húmeda o seca). El identificar el tipo de vegetación (bosque, matorral, pastizal) permite saber la carga de combustible, la que según la



nomenclatura propuesta por SCOTT & BURGAN (2005), estratifica la vegetación para llegar a un modelo de combustible más específico. Sin embargo, tanto por errores que puedan provenir desde la información satelital, como también por la misma dinámica de la vegetación, es muy difícil poder validar un modelo de combustible, sobre todo al ser una variable cualitativa. Por ello, los códigos asignados al modelo de combustible obtenidos a partir de información satelital podrían ser erróneos. Debido a esta problemática, se ha desarrollado la FIRE-RES Geo-Catch app (KUTCHARTT et al., 2023), con la idea de generar una herramienta que pudiera recolectar información de campo georreferenciada, y en donde, a través de una simple imagen geo-etiquetada que describa el paisaje de la vegetación, pueda validar el modelo de combustible. Esta investigación se encuentra en curso, ya que mediante algoritmos de Deep Learning (DL) se ha logrado segmentar las imágenes y extraer atributos de altura de la vegetación, permitiendo no solo validar el combustible principal, sino también identificar la carga de combustible de manera más robusta.

El servidor de combustibles a nivel paneuropeo viene a suplir una necesidad importante en Europa, en donde la información pueda estar organizada y disponible para su descarga para toda la Unión Europea. Como previamente se ha mencionado, la existencia de servidores de datos no es reciente, ya que ROLLINS (2009) y KRSNIK et al. (2020) han desarrollado estas plataformas, tanto para los Estados Unidos como para Cataluña, respectivamente. Sin embargo, el desafío y el esfuerzo no solo forma parte en la creación de esta plataforma, sino que el principal esfuerzo se debe centrar en su mantenimiento, actualización y mejoramiento. Es muy importante a futuro poder llegar a una escala de resolución más operativa, como la propuesta por ROLLINS (2009) a 30 m de resolución espacial, aunque podría ser complejo para una escala paneuropea. También, sería muy relevante poder integrar trabajos como el de ARAGONESES et al. (2024) y KUTCHARTT et al. (2024b) que cuentan con información valiosa de campo distribuidas en distintas zonas geográficas para la validación en los combustibles de copas, siendo muy importante fusionar ambos trabajos a futuro y poder contar con capas que contengan una menor incertidumbre en sus errores, generando una mayor confianza en los usuarios finales que utilizaran esta información para simular incendios locales en sus regiones.

## 5. Conclusiones

Las capas ráster producidas en este trabajo, desde el mapa de biomasa área (BA), pasando por los combustibles de copas (ABD y DAD), y finalmente produciendo un mapa de combustibles superficiales basándose en la codificación de SCOTT & BURGAN (2005) han resultado satisfactorios para las necesidades sobre la simulación de incendios forestales a una escala paneuropea, obteniendo una resolución espacial de 100 m, siendo de esta forma una cartografía operativa en comparación a otras fuentes de datos de menor resolución (1 km). Por consiguiente, se asume un grado razonable de significancia en los mapas producidos. En el caso de la BA, esta capa fue producida mediante algoritmos de inteligencia artificial, actualizando la información para el año 2020, siendo crucial tanto para incluir una nueva capa ráster en la simulación de los incendios, como también una variable fundamental para extraer la biomasa foliar, y posteriormente poder determinar la DAD. Por otra parte, las ya mencionadas capas de combustibles de copas, que fueron determinadas mediante datos satelitales y procesadas a través de un enfoque mixto utilizando la inteligencia artificial y



modelos alométricos. Estos últimos fueron creados específicamente para ambas variables (ABD y DAD) utilizando datos abiertos y datos proporcionados por los coautores, como también funciones alométricas obtenidas mediante literatura en el caso de las ecuaciones de biomasa a nivel de componente arbóreo (tronco, ramas, y hojas). Ambas capas contaron con sus respectivos valores de incertidumbre, la que conto con un set de datos independientes de 804 muestras, obtenidas mediante datos LiDAR y mediciones de campo en cuatro países que hacen parte del consorcio FIRE-RES (Portugal, Grecia, Italia, y Noruega), cubriendo un amplio rango latitudinal. Por lo tanto, las métricas de error reportadas para el ABD y DAD fueron las siguientes, coeficiente de correlación (R) de 0,45 y 0,31; el error cuadrático medio (ECM) de 3,9 m y 0,110 kg/m<sup>3</sup>; y el error porcentual medio absoluto (EPME) de 61% y 77%, respectivamente. Es importante hacer notar, que las métricas de error mejoran significativamente en píxeles en donde la cubierta forestal supera el 80%. Por otra parte, el mapa de combustibles fue producido bajo el consenso de distintas capas de uso de suelo, incorporando variables de estructura forestal para la obtención de resultados más robustos. En síntesis, las nuevas capas producidas en este trabajo, y la integración de información ya disponible mediante otros autores fue armonizada en un mismo sistema de referencia de coordenadas, a una misma escala de resolución espacial en una aplicación web-GIS, en donde los usuarios pueden visualizar y descargar información para definir planes de prevención y mitigación en incendios forestales en toda Europa.

### 7. Agradecimientos

El presente trabajo ha sido financiado por la European Union Horizon 2020 Research and Innovation Programme a través de proyecto titulado “Innovation technologies & socio-ecological-economic solutions for fire resilient territories in Europe – FIRE-RES” bajo el contrato N°101037419. Además, este trabajo también conto con la financiación de la European Union Horizon 2020 Research and Innovation Programme Marie Skłodowska-Curie bajo contrato N°101007950. El Dr. Erico Kuthartt ha sido financiado por la Fundación Cassa di Risparmio di Padova e Rovigo (CARIPARO), mientras que la Dra. Núria Aquilué ha sido financiada a través de la beca Juan de la Cierva del Ministerio de Ciencia e Innovación (FCJ2020-046387-I). El Dr. Francesco Pirotti ha recibido financiamiento del Centro Nacional de Investigación Agritech, como también por parte de la European Union Next-GenerationEU (Piano Nazionale di Ripresa e Resilienza (PNRR) – Missione 4 Componente 2, Investimento 1.4 – D.D 1032 17/06/2022, CN00000022). También, nos gustaría agradecer al Dr. Víctor Gerding, quién de manera desinteresada ha hecho una revisión completa del documento, aportando con correcciones y observaciones para mejorar la calidad científica del documento final.

### 8. Bibliografía

ARAGONESES, E.; GARCÍA, M.; SALIS, M; RIBEIRO, L.M.; CHUVIECO, E.; 2023. Classification and mapping of European fuels using a hierarchical, multipurpose fuel classification system. *Earth Syst. Sci. Data* 15: 1287:1315.

ARAGONESES, E.; GARCÍA, M.; RUIZ-BENITO, P.; CHUVIECO, E.; 2024. Mapping forest canopy fuel parameters at European scale using spaceborne LiDAR and satellite data. *Remote Sens. Environ.* 303: 114005.



AVITABILE, V.; CAMIA, A.; 2018. An assessment of forest biomass maps in Europe using harmonized national statistics and inventory plots. *For. Ecol. Manag.* 409: 489-498.

AYBAR, C.; WU, Q.; BAUTISTA, L.; YALI, R.; BARJA, A.; 2020. rgee: An R package for interacting with Google Earth Engine. *J. Open Source Softw.* 5(51): 2272.

BÜTTNER, G.; KOSZTRA, B.; MAUCHA, G.; PATAKI, R.; KLEESCHULTE, S.; HAZEU, G.; VITTEK, M.; SCHRODER, C.; LITTKOPF, A.; 2021. Copernicus land monitoring service-CORINE land cover. User Manual 2021. Copernicus Publications.

CARMELO, A.; 2024. Riconoscimento di elementi forestali mediante Deep Learning su immagini da Smartphone. Tesis de maestría, Universidad de Padova, pp. 42.

COPERNICUS.; 2021. GMES Initial Operations / Copernicus land monitoring services – Validation products. Validation services for the geospatial products of the Copernicus land continental and local components including in-situ data (lot1). Validation report CLC2018/CLCC1218, pp 203.

EUROPEAN COMMISSION, JOINT RESEARCH CENTRE.; 2024. Report on the large wildfires of 2022 in Europe. Publications Office of the European Union, Luxembourg. JRC138859.

EUROSTAT.; 2022. Statistical regions in the European Union and partner countries – NUTS and statistical regions 2021 – 2022 edition. Publications Office of the European Union. pp 181.

FINNEY, M.A.; 2004. FARSITE: Fire area simulator-model development and evaluation. USDA Forest Service. Rocky Mountain Research Station. Research Paper RMRS-RP-4.

FINNEY, M.A.; 2006. An overview of FlamMap fire modelling capabilities. USDA Forest Service. Rocky Mountain Research Station. Conference Proceedings RMRS-P-41.

FINNEY, MA.; MCHUGH, C.W.; GRENFELL, I.C.; RILEY, K.L.; SHORT, K.C.; 2011. A simulation of probabilistic wildfire risk components for the continental United States. *Stoch. Environ. Res. Risk. Assess.* 25: 973-1000.

FORRESTER, D.I.; TACHAUER, I.H.H.; ANNIGHOFER, P.; BARBIETO, I.; PRETZSCH, H.; RUIZ-PEINADO, R.; STARK, H.; VACCHIANO, G.; ZLATANOV, T.; CHAKRABORTY, T.; SAHA, S.; SILESHI, G.W.; 2017. Generalized biomass and leaf area allometric equations for European tree species incorporating stand structure, tree age and climate. *For. Ecol. Manag.* 396: 160-175.

HALL, S.A.; BURKE, I.C.; 2006. Considerations for characterizing fuels as inputs for fire behavior models. *For. Ecol. Manag.* 227(1-2): 102-114.

HANSEN, MC.; POTAPOV, P.V.; MOORE, R.; HANCHER, M.; TURUBANOVA, S.A.; TYUKAVINA, A.; THAU, D.; STEHMAN, S.V.; GOETZ, S.J.; LOVELAND, T.R.; KOMMAREDDY, A.; EGOROV, A.; CHINI, L.; JUSTICE, C.O.; TOWNSHEND, J.R.G.; 2013. High-resolution global maps of 21st-century forest cover change. *Science* 342: 850-853.

HEISIG, J.; OLSON, E.; PEBESMA, E.; 2022. Predicting wildfire fuels and hazard in a central European temperate forest using active and passive remote sensing. *Fire* 5(1): 29.

HIJMANS, R.J.; CAMERON, S.E.; PARRA, J.L.; JONES, P.G.; JARVIS, A.; 2005. Very high resolution interpolated climate surfaces for global land areas. *Int. J. Climatol.* 25:



1965-1978.

KIRILLOV, A.; MINTUN, E.; RAVI, N.; MAO, H.; ROLLAND, C.; GUSTAFSON, L.; XIAO, T.; WHITEHEAD, S.; BERG, A.C.; LO, W.Y.; DOLLAR, P.; GIRSHICK, R.; 2023. Segment anything. IEEE/CVF International Conference on Computer Vision (ICCV). Paris, France. pp. 3992-4003.

KRSNIK, G.; BUSQUET OLIVÉ, E.; PIQUÉ NICOLAU, M.; LARRAÑAGA, A.; CARDIL, A.; GARCIA-GONZALO, J.; GONZÁLEZ-OLABARRÍA, J.R.; 2020. Regional level data server for fire Hazard evaluation and fuel treatment planning. *Forests* 12(24): 4124.

KUCUK, O.; SEVINC, V.; 2023. Fire behavior prediction with artificial intelligence in thinned black pine (*Pinus nigra* Arnold) stand. *For. Ecol. Manag.* 529: 120707.

KUDLACKOVA, L.; PODEBRADSKA, M.; BLAHOVA, M.; CIENCIALA, E.; BERANOVA, J.; MCHUGH, C.; FINNEY, M.; NOVOTNY, J.; ZAHRADNICEK, P.; STEPANEK, P.; LINDA, R.; PIKL, M.; VEBROVA, D.; MOZNY, M.; SUROVY, P.; ZALUD, Z.; TRNKA, M.; 2024. Using FlamMap to assess wildfire behavior in Bohemian Switzerland National Park. *Nat. Hazards* 120: 39-43-3077.

KUTCHARTT, E.; GONZÁLEZ-OLABARRIA, J.R.; TRASOBARES, A.; DE-MIGUEL, S.; CARDIL, A.; BOTEQUIM, B.; VASSILEV, V.; PALAIOLOGOU, P.; ROGAI, M.; PIROTTI, F.; 2023. FIRE-RES Geo-Catch: A mobile application to support reliable fuel mapping at a pan-European scale. *iForest* 16(5): 268-273.

KUTCHARTT, E.; GONZÁLEZ-OLABARRIA, J.R.; AQUILUÉ, N.; TRASOBARES, A.; PIROTTI, F.; 2024a. Estimating canopy fuels across Europe with satellite data and allometric equations. *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, XLVIII-3-2024, 279–285.

KUTCHARTT, E.; GONZÁLEZ-OLABARRIA, J.R.; TRASOBARES, A.; AQUILUÉ, N.; GUERRA-HERNÁNDEZ, J.; NUNES, L.; SEQUEIRA, A.C.; BOTEQUIM, B.; HAUGLIN, M.; PALAIOLOGOU, P.; CARDIL, A.; ROGAI, M.; VASSILEV, V.; PIMONT, F.; MARTINDUCUP, O.; PIROTTI, F.; 2024b. Satellite-based mapping of canopy fuels at the pan-European scale. *Geo-spat. Inf. Sci.* 1-29.

KUTCHARTT, E.; GONZÁLEZ-OLABARRIA, J.R.; AQUILUÉ, N.; GARCIA-GONZALO, J.; TRASOBARES, A.; BOTEQUIM, B.; HAUGLIN, M.; PALAIOLOGOU, P.; VASSILEV, V.; CARDIL, A.; NAVARRETE, M.A.; ORAZIO, C.; PIROTTI, F.; 2024c. Pan-European fuel map server: An open-geodata portal for supporting fire risk assessment. *Geomatica* 76: 100036.

LABENSKI, P.; EWALD, M.; SCHMIDTLEIN, S.; HEINSCH, F.A.; FASSNACHT, F.W.; 2023. Quantifying surface fuels for fire modelling in temperate forests using airborne lidar and Sentinel-2: potential and limitations. *Remote Sens. Environ.* 295: 113711.

LANG, N.; JETZ, W.; SCHIMDLER, K.; WEGNER, J.D.; 2023. A high-resolution canopy height model of the earth. *Nat. Ecol. Evol.* 7: 1778-1789.

MATTHEWS, S.; SULLIVAN, A.L.; WATSON, P.; WILLIAMS, R.J.; 2012. Climate change, fuel and fire behaviour in a eucalypt forest. *Glob. Change Biol.* 18(10): 3212-3223.

MEIGS, G.W.; DUNN, C.J.; PARKS, S.A.; KRAWCHUK, M.A.; 2020. Influence of topography and fuels on fire refugia probability under varying fire weather conditions in forests of the Pacific Northwest, USA. *Can. J. For. Res.* 50: 636-447.

MICHELETTO, E.; 2024. Validazione tramite procedure geospaziali di un mappa



pan-europea di biomassa arborea epigea stimata usando dati satellitari e intelligenza artificiale. Tesis de Licenciatura, Universidad de Padova, pp. 29.

MIHAJLOVSKI, B.; FERNANDES, P.M.; PEREIRA, J.M.C.; GUERRA-HERNANDEZ, J.; 2023. Comparing forest understory fuel classification in Portugal using discrete airborne laser scanning data and satellite multi-source remote sensing data. *Fire* 6(9): 327.

MONEDERO, S.; RAMIREZ, J.; CARDIL, A.; 2019. Predicting fire spread and behaviour on the fireline. Wildfire analyst pocket: a mobile app for wildland fire prediction. *Ecol. Modell.* 392: 103-107.

MUTLU, M.; POPESCU, S.C.; ZHAO, K.; 2008. Sensitivity analysis of fire behavior modelling with LIDAR-derived surface fuel maps. *For. Ecol. Manag.* 256(3): 289-294.

PAIS, C.; CARRASCO, J.; MARTELL, D.L.; WEINTRAUB, A.; WOODRUFF, D.L.; 2021. Cell2Fire: a cell-based forest fire growth model to support strategic landscape management planning. *Front. For. Glob. Change* 4: 692706.

PETTINARI, M.L.; CHUVIECO, E.; 2016. Generation of a global fuel data set using the fuel characteristic classification system. *Biogeosciences* 13: 2061-2076.

PIROTTI, F.; GONZÁLEZ-OLABARRIA, JR.; KUTCHARTT, E.; 2023. Updating aboveground biomass at a pan-European scale through satellite data and artificial intelligence. *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, XLVIII-1/W2-2023, 1763-1769

ROLLINS, M.G.; 2009. LANDFIRE: a nationally consistent vegetation, wildland fire, and fuel assessment. *Int. J. Wildland Fire* 18(3): 235-249.

RYAN, K.C.; 2002. Dynamic interactions between forest structure and fire behavior in boreal ecosystems. *Silva Fenn.* 36(1): 548.

SANTORO, M.; CARTUS, O.; 2021. ESA Biomass Climate Change Initiative (Biomass\_cci): Global datasets of forest above-ground biomass for the years 2010, 2017 and 2018, v3.

SANTORO, M.; CARTUS, O.; QUEGAN, S.; KAY, H.; LUCAS, R.M.; ARAZA, A.; HEROLD, M.; LABRIERE, N.; CHAVE, N.; ROSENQVIST, A.; TADONO, T.; KOBAYASHI, K.; KELLNDORFER, AVITABILE, V., BROWN, H.; CARREIRAS, J.; CAMPBELL, M.J.; CAVLOVIC, J.; BISPO, P.C.; GILANI, H.; KHAN, M.L.; KUMAR, A.; LEWIS, S.L.; LIANG, J.; MITCHARD, E.T.A.; PACHECO-PASCAGAZA, A.M.; PHILLIPS, O.L.; RYAN, C.M.; SAIKIA, P.; SCHEPASCHENKO, D.; SUKHDEO, H.; VERBEECK, H.; VIEILLEDENT, G.; WIJAYA, A.; WILLCOCK, S.; SEIFERT, F.M.; 2024. Design and performance of the Climate Change Initiative Biomass global retrieval algorithm. *Sci. Remote Sens.* 10: 100169.

SCOTT, J.H.; BURGAN, R.E.; 2005. Standard fire behavior fuel models: A comprehensive set for use with Rothermel's surface fire spread model. General Technical Report RMRS-GTR-153, USDA Forest Service, Rocky Mountain Research Station, Fort Collins, CO, USA, pp. 72.

TADONO, T.; NAGAI, H.; ISHIDA, H.; ODA, F.; NAITO, S.; MINAKAWA, K.; IWAMOTO, H.; 2016. Generation of the 30 M-MESH global digital surface model by ALOS PRISM. *Arch. Photogramm. Remote Sens. Spatial Inf. Sci.* XLI-B4: 157-162.

TOLAN, J.; YANG, H.I.; NOSARZEWSKI, B.; COUAIRON, G.; VO, H.V.; BRANDT, J.; SPORE, J.; MAJUMDAR, S.; HAZIZA, D.; VAMARAJU, J.; MOUTAKANNI, T.; BOJANOWSKI, P.; JHONS, T.; WHITE, B.; TIECKE, T.; COUPRIE, C.; 2024. Very high



resolution canopy height maps from RGB imagery using self-supervised vision transformer and convolutional decoder trained on aerial lidar. *Remote Sens. Environ.* 300: 113888.

TYMSTRA, C.; BRYCE, R.W.; WOTTON, B.M.; TAYLOR, S.W.; ARMITAGE, O.B.; 2010. Development and structure of Prometheus: The Canadian wildland fire growth simulation model. Canadian Forest Service. North Forestry Centre. Information Report NOR-X-417.

UNEP.; 1992. World atlas of desertification. Vol. 80. London, UK. pp. 69.

ZANAGA, D.; VAN DE KERCHOVE, R.; DE KEERSMAECKER, W.; SOUVERIJNS, N.; BROCKMANN, C.; QUAST, R.; WEVERS, J.; GROSU, A.; PACCINI, A.; VERGNAUD, S.; CARTUS, O.; SANTORO, M.; FRITZ, S.; GEORGIEVA, I.; LESIV, M.; CARTER, S.; HEROLD, M.; LI, L.; TSENDBAZAR, N.E.; RAMOINO, F.; ARINO, O.; 2021. ESA WorldCover 10 m 2020 v100.