



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

**9º CONGRESO FORESTAL ESPAÑOL**

**9CFE-1482**

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

Organiza





## El proyecto AutoForces: una iniciativa hacia la estimación automática de recursos forestales y la productividad en el norte de España

LÓPEZ-SÁNCHEZ, C.A. (1)., BARRIO-ANTA, M. (1)., CÁMARA-OBREGÓN, A. (1)., TEIJIDO-MURIAS, I. (1)., GÓMEZ, C. (2)., CANTERO AMIANO, A. (3)., ALONSO PONCE, R. (4)., GARCÍA-MANTECA, P. (5)., WEHENKEL, C.A. (6)

(1) Grupo de Investigación SmartForest. Departamento de Biología de Organismos y Sistemas, Escuela Politécnica de Mieres, Universidad de Oviedo, Campus Universitario de Mieres, C/Gonzalo Gutiérrez Quirós S/N, 33600 Mieres (España).

(2) iuFOR, EiFAB, Universidad de Valladolid, Campus Universitario Duques de Soria, 42004 Soria (España).

(3) Fundación HAZI. Granja Modelo s/n., Arkaute, Álava 01192 (España)

(4) FÖRA Forest Technologies SLL. Campus Universitario Duques de Soria, Edificio I+D+i, 42004 Soria (España)

(5) Instituto de Recursos Naturales y Ordenación del Territorio (INDUROT), Campus of Mieres, Universidad de Oviedo, Campus Universitario de Mieres, C/Gonzalo Gutiérrez Quirós S/N, 33600 Mieres (España).

(6) Instituto de Silvicultura e Industria de la Madera, Universidad Juárez del Estado de Durango, Blvd. del Guadiana 501, Ciudad Universitaria, 34160 Durango (México).

### Resumen

AutoForces es acrónimo de “Estimación automática del recurso forestal y de la potencialidad del territorio para las principales especies forestales comerciales del norte de España bajo cambio climático”. Se trata de un proyecto desarrollado en Galicia, Asturias, Cantabria y País Vasco que pretende obtener modelos que no precisen toma de nuevos datos de campo para su uso en la estimación de recursos y la productividad del territorio para *Eucalyptus globulus*, *Pinus pinaster* y *Pinus radiata*. La estimación actual de recursos a escala regional o suprarregional precisa de dos modelos secuenciales, de producción y de coberturas forestales; por otro lado, el modelo de productividad permite determinar las zonas de mayor crecimiento. Para el desarrollo de los dos primeros modelos se está usando la base de datos del Inventario Forestal Nacional (IFN) para obtener la verdad terreno e información de las constelaciones de satélites Sentinel 1 y 2 para obtener las variables explicativas. Para construir los modelos de productividad se usan datos geolocalizados de índice de sitio de parcelas de investigación y las capas de información ambiental espacialmente continua disponibles actualmente. Los resultados se presentarán en forma de mapas en un geoportal de acceso público. En esta comunicación se abordan los principales avances conseguidos y los retos que supone el desarrollo de modelos precisos y operativos.

### Palabras clave



IFN, LiDAR, Sentinel-1 y -2, índice de sitio, madera y biomasa

## 1. Introducción

La importancia de los bosques para ayudar a afrontar algunos de los grandes retos de nuestro tiempo es cada día más reconocida debido a que estos proporcionan muchos de los bienes y servicios que nuestra sociedad demanda (FREER-SMITH et al., 2019). Aunque la superficie forestal total del planeta parece haberse reducido en un 4,2% durante el período 1990-2020, la superficie de las plantaciones forestales se ha incrementado en un 72,4% en ese mismo período (FAO, 2020). Dicho aumento está sustentado principalmente por plantaciones forestales con especies de crecimiento rápido como eucaliptos, pinos, chopos, etc.; y responde a la necesidad de satisfacer la incesante demanda de recursos forestales por parte del ser humano. Estas plantaciones juegan también un doble papel en la mitigación del actual cambio climático (FREER-SMITH et al., 2019): *i*) actúan como sumideros eficientes de CO<sub>2</sub>; y *ii*) proporcionan materia prima para la producción de energía eléctrica y/o térmica a partir de biomasa forestal. Por tanto, las plantaciones forestales con especies de crecimiento rápido serán necesarias mientras el ser humano demande sus bienes y servicios y tendrán también un papel relevante en la inevitable transición de las economías actuales basadas en los combustibles fósiles a las nuevas economías basadas en energías limpias o de baja huella de carbono. Para abordar el análisis y la valoración de los servicios ecosistémicos que brindan o pueden brindar los sistemas forestales a la sociedad es preciso conocer en primera instancia los recursos forestales disponibles. En este sentido, el primer aspecto esencial al analizar cualquier recurso natural es disponer de información cuantitativa fiable y actualizada sobre su cantidad, su distribución sobre el territorio y su posible variación temporal. Esta determinación y actualización de la producción forestal se puede llevar a cabo actualmente a través de métodos directos (requieren mediciones en campo para cada determinación o actualización) y métodos indirectos (no requieren la toma de nuevos datos de campo para cada uso de los modelos).

Dentro de los métodos directos están los inventarios forestales clásicos por muestreo, basados en la medición del diámetro normal y la altura total de los árboles en numerosas parcelas, y que todavía continúa siendo el método más habitual para la estimación de las existencias de los montes arbolados (NILSSON et al., 2017). Aunque este método es preciso, es caro, consume mucho tiempo y presenta problemas operacionales ya que sólo se puede aplicar a áreas pequeñas. Sin embargo, estos datos generados a nivel parcela, también se pueden usar como "bases de datos de entrenamiento" para desarrollar modelos forestales basados en variables obtenidas a partir de sensores remotos activos y pasivos (métodos indirectos). Así, en las últimas décadas, la combinación de bases de datos públicas de parcelas de inventario (p.ej., inventarios forestales nacionales) con la adquisición semiautomática de variables de estado de los bosques a través de sensores remotos ha incrementado de manera sustancial la cantidad de datos disponibles para desarrollar modelos predictivos a escala rodal (ÁLVAREZ-GONZÁLEZ et al., 2014).



De hecho, actualmente la cuantificación de recursos es una de las aplicaciones más comunes de los sensores remotos en el apoyo a la gestión sostenible de los ecosistemas forestales, ya que proporcionan datos fiables y permiten superar las dos limitaciones citadas de los métodos tradicionales (carestía y problemas operacionales), proporcionando estimaciones en áreas incluso no muestreadas previamente (MOSEER et al., 2017). Entre los sistemas disponibles actualmente, destacan dos:

- Empleo de sensores remotos activos montados en aeronaves (p.ej., PNOA-LiDAR) o en satélites (p.ej., ICESat-2, GEDI, Sentinel-1, TanDEM-X, ALOS-2 PALSAR-2)
- Uso de sensores remotos pasivos montados en satélites (p.ej., Landsat, Sentinel-2) o aeronaves (PNOA-Imagen)

El escaneado LiDAR aéreo es un método preciso, eficiente y con un coste adecuado para predecir variables forestales de producción. Así, en España el proyecto PNOA-LiDAR (CNIG, 2023) busca cubrir todo el territorio en ciclos de 6 años. Sin embargo, esta periodicidad es uno de los mayores inconvenientes de la metodología ya que los modelos desarrollados no se adecuan plenamente a la realidad tan cambiante de las masas productivas del norte de España, donde algunas masas, como las de eucalipto, tienen una edad de corta de entre 10-13 años. Los otros dos grandes inconvenientes son la falta de coincidencia temporal entre las parcelas de campo del IFN y los vuelos PNOA-LiDAR y la falta de geolocalización precisa de las parcelas de campo (NOVO-FERNÁNDEZ et al., 2019).

Las dificultades asociadas a la resolución temporal del sensor se pueden resolver mediante el empleo de sensores remotos pasivos montados sobre satélites, que permiten disponer de numerosas adquisiciones a lo largo de un año y, por lo tanto, permiten una actualización continua de los parámetros de la vegetación. La aplicación de metodologías estadísticas avanzadas *machine learning* y el uso de estos sensores instalados en satélites permiten la estimación de las variables de producción de las masas forestales de forma rápida y a bajo coste. Sin embargo, la elaboración de este tipo de modelos requiere que:

- se disponga de una geolocalización precisa y coincidencia temporal entre las parcelas de inventario necesarias y los datos radiométricos del satélite
- se lleve a cabo un postprocesado adecuado de las imágenes de satélite

El correcto procesado previo de las imágenes es un punto crítico para mejorar la calidad e interpretación de los datos y consiste en llevar a cabo correcciones geométricas y radiométricas, atmosféricas y topográficas. Las bandas espectrales son las franjas del espectro electromagnético en las que opera el sensor del satélite para captar los niveles de energía emitidos por los objetos y que son traducidas digitalmente en cada uno de los archivos que forman una imagen. La combinación de estas permite calcular los llamados índices de vegetación; y estos índices, así como las bandas espectrales, guardan información referente a la posición que ocupan lo que permite calcular índices derivados del análisis de la textura de la imagen. Con la información proporcionada por el sensor se puede modelizar cualquier característica de la vegetación, como el volumen de madera, la biomasa o el carbono acumulado. Actualmente el empleo de numerosos algoritmos *machine learning* y *deep learning* permite la obtención de modelos matemáticos insesgados y muy robustos.



Los modelos de producción obtenidos a partir de variables procedentes de sensores activos (PNOA-LiDAR) o pasivos (Sentinel-2) sirven de forma inmediata para obtener las producciones de parcelas forestales de las especies para las que se construyeron los modelos. Para ello el usuario debe "recortar" las capas ráster de predicción con el perímetro de su parcela o monte y obtener la variable de producción deseada por agregación de los valores de los píxeles contenidos en su interior. Sin embargo, su aplicación a una escala amplia (desde municipal hasta suprarregional) requiere de una actualizada y correcta delineación de las masas forestales cubiertas por las especies para las cuales se han ajustado los modelos predictivos. Una aproximación rápida consistiría en aplicarlo sobre la última actualización cartográfica oficial (mapa forestal más reciente). Sin embargo, esta aproximación, que puede resultar útil en áreas forestales con especies de crecimiento lento y sujetas a escaso aprovechamiento (una parte importante del área mediterránea española), no lo es en el norte de España con especies de crecimiento rápido y aprovechamiento forestal intensivo. Por tanto, en el norte de España es necesaria una delineación de cubiertas forestales precisa y dinámica donde aplicar o "volcar" los resultados de dichos modelos de estimación de la producción a partir de variables independientes adquiridas con sensores remotos. Mediante un proceso similar al descrito anteriormente, donde la variable objetivo en este caso será una clase de cobertura, se obtiene un modelo cualitativo que clasifica la reflectancia obtenida a partir de las imágenes de satélite en diferentes coberturas vegetales (en este caso, coberturas de especies forestales) en vez de obtener un modelo cuantitativo de regresión correspondiente a la producción de las masas forestales. Ambos procedimientos (modelo cuantitativo para estimar el recurso forestal y cualitativo para la delineación de las diferentes masas forestales) a partir de imágenes de satélites, permiten obtener lo que se puede denominar como producto de cuantificación automática de máxima actualidad de la producción forestal.

Por otro lado, la calidad de estación es la capacidad inherente de un terreno para sostener el crecimiento de una especie determinada y es un indicador de productividad forestal intrínseca, que tradicionalmente se ha cuantificado mediante el índice de sitio (IS) (SKOVSGAARD & VANCLAY, 2008). Si se conoce el IS para una determinada parcela forestal, este se puede relacionar con múltiples variables ambientales para desarrollar modelos de regresión que permiten determinar la calidad de estación sin necesidad de estar poblados por la especie (CLUTTER et al., 1983). Además, la disponibilidad actual de capas de información ambiental de alta resolución espacial permite predecir el IS sin necesidad de trabajo de campo adicional, además de permitir su cartografiado sobre el territorio (BONTEMPS & BOURIAUD, 2014). El conocimiento de la distribución espacial de la calidad de estación permitiría también identificar los terrenos con mayor potencial para la producción, centrando los recursos disponibles y los esfuerzos de gestión en esos lugares. Según la resolución espacial a la que se genera la información, se puede hablar de mapas de calidad de estación a escala paisaje o a escala parcela forestal o monte. La resolución alcanzable depende de varios factores (TEIJIDOMURIAS et al., 2025): *i*) la resolución de las capas de información ambiental espacialmente continuas disponibles, *ii*) el tipo de masas objeto de la estimación (aprovechadas comercialmente o no) y *iii*) el tipo de planificación para la que se va a usar la información (estratégica, táctica u operacional). Así, la cartografía de la calidad de estación de especies productivas a escala paisaje (p.ej., 250 m píxel<sup>-1</sup>) es



muy útil en la planificación táctica para redactar o actualizar Planes Forestales Regionales (RFP) o los documentos que los desarrollan. Por su parte, la cartografía de la calidad de estación a escala parcela forestal (p.ej., resoluciones espaciales mayores de 100 m píxel<sup>-1</sup>) es útil a nivel planificación operativa para desarrollar prescripciones de planificación o predecir el crecimiento y la producción a escala de parcela catastral.

## 2. Objetivos

El objetivo general del proyecto ha sido la elaboración de mapas espacialmente continuos en formato ráster, obtenidos por implementación de modelos matemáticos ajustados a partir de variables de Sentinel-1 y Sentinel-2 y variables ambientales espacialmente continuas, para obtener a nivel suprarregional, para las especies productivas más importantes del norte de España, la estimación automática de superficies ocupadas, su producción (volumen, biomasa y carbono) y la productividad esperable de las zonas potenciales para su crecimiento, así como valorar el efecto del cambio climático en la productividad.

## 3. Metodología

### 3.1. Área de estudio y especies estudiadas

El área de estudio abarcó cuatro regiones del norte de España (Galicia, Asturias, Cantabria y País Vasco), ocupa una superficie total de 5,2 millones de ha y se encuentra principalmente en la Región Biogeográfica Atlántica Europea, excepto el sureste de Galicia que pertenece a la Región Biogeográfica Mediterránea (RIVAS-MARTÍNEZ et al., 2004). En la región de estudio, las masas arboladas ocupan una superficie de 2,5 millones de ha (MAPAMA, 2019), lo que representa el 47,6 % de la superficie total. Dentro de estas, las plantaciones forestales tienen gran relevancia ya que se trata de una de las áreas con mayor productividad forestal de toda Europa y están constituidas principalmente por tres especies de crecimiento rápido: el pino pinaster (*Pinus pinaster* Aiton), el pino radiata (*Pinus radiata* D. Don) y el eucalipto blanco (*Eucalyptus globulus* Labill.). Estas plantaciones tienen una gran importancia socioeconómica como lo ponen de relieve los 10,8 millones de m<sup>3</sup> de madera cortados anualmente de media en las cuatro comunidades en el período 2005-2021. Dicho volumen de corta supuso el 67% de la madera cortada anualmente en España en ese período, representando las tres especies citadas el 92% de esos 10,8 millones de m<sup>3</sup> (MITECO, 2024). Esas cifras tan importantes de corta hicieron que estas tres especies fueran las elegidas para el desarrollo del proyecto AutoForces.

### 3.2. Datos utilizados

#### 3.2.1. Parcelas de campo y variables forestales



Para el desarrollo de modelos de producción se utilizaron los datos de la última actualización del cuarto Inventario Forestal Nacional que se realizó en el año 2018 (conocido entre los forestales como IFN4.5) para las tres especies forestales más productivas del norte: *Eucalyptus globulus*, *Pinus pinaster* y *Pinus radiata*. Las parcelas de las tres especies de interés utilizadas se correspondieron con masas puras (área basimétrica de la especie principal  $\geq 80\%$  del área basimétrica total). Siguiendo este criterio, se dispuso para el análisis de un total de 1.471 parcelas dentro del área de estudio. Entre estas parcelas, 589 se encuentran dominadas por *E. globulus*, 474 por *P. pinaster* y 408 por *P. radiata*. Se calcularon dos variables de producción (volumen total con corteza, TV y biomasa total aérea, AGB). Es importante reseñar que, de las 1.471 parcelas remedidas, el equipo del IFN4.5 volvió a geolocalizar con GPS de precisión submétrica un 73% de ellas.

Las parcelas utilizadas para determinar la cobertura forestal están incluidas en la red de parcelas permanentes utilizadas en el cuarto Inventario Forestal Nacional (IFN4) y están ubicadas en los nodos de una cuadrícula UTM de 1 km. Para la clasificación precisa de la cobertura de las parcelas, la fotointerpretación se basó en imágenes del Programa Nacional de Ortofotografía de 2017 (PNOA-2017) y de la actualización del cuarto Inventario Forestal Nacional para las especies forestales más productivas en 2018 (IFN4.5) y del cuarto IFN4 para las especies forestales restantes. Las parcelas de muestra necesarias para representar otras clases de cobertura del suelo no forestal se obtuvieron utilizando dos cuadrículas UTM, de 1 km x 1 km y 5 km x 5 km respectivamente. Se consideraron un total de 2.991 parcelas para el análisis en este estudio, distribuidas entre las clases de uso del suelo en proporción a su extensión en el territorio. En este caso, la fotointerpretación de las parcelas se basó en PNOA-2017 y *Corine Land Cover* de 2018 (CLC-2018).

Para los estudios de productividad se usaron datos del índice de sitio de cada especie que se obtuvieron de diversas fuentes: i) parcelas instaladas en el área de estudio en el marco de los trabajos del proyecto, ii) parcelas propias del grupo de investigación, iii) datos georreferenciados de parcelas usadas en publicaciones, iv) parcelas de otros grupos de investigación y; v) parcelas suministradas por empresas del sector. Todo ello para buscar un número alto de parcelas (1.102 para *E. globulus*, 182 para *P. pinaster* y 167 *P. radiata*), que se distribuyeran por toda el área de distribución de las especies en el norte de España y cubrieran el mayor rango posible de condiciones ambientales.

### 3.2.2. Variables independientes

Para el desarrollo de modelos de coberturas y producción se emplearon 15 imágenes multispectrales obtenidas en agosto de 2018 de la constelación satelital Sentinel-2 con una resolución espacial de 10 y 20 m píxel<sup>-1</sup> y una resolución temporal de 5 días (dos satélites en la misma órbita polar), disponibles para descarga en los servidores del *Copernicus Open Access Hub* (<https://scihub.copernicus.eu/>). Estas imágenes se sometieron a diversos procesos



de corrección y se seleccionaron varias bandas espectrales, índices y variables de textura como variables independientes para el desarrollo de los modelos. Se usaron también variables auxiliares de terreno obtenidas a partir del modelo digital del terreno (MDT) de 5 m píxel<sup>-1</sup>, elaborado por el Centro Nacional de Información Geográfica de España (CNIG) y variables climáticas extraídas del Atlas Climático Digital de la Península Ibérica (NINYEROLA et al., 2005) con 200 m de resolución espacial.

Para el desarrollo de modelos de productividad se obtuvieron variables topográficas a partir del MDT de 5 m píxel<sup>-1</sup> del CNIG y se consideraron dos fuentes diferentes de variables climáticas: i) variables climáticas extraídas del Atlas Climático Digital de la Península Ibérica (NINYEROLA et al., 2005) con 200 m de resolución espacial, y ii) variables bioclimáticas obtenidas del *WorldClim* (HIJMANS et al., 2005) con una resolución espacial de 30 segundos de arco (aproximadamente 800 m). Además, se consideraron variables características de la estación compiladas a partir de SoilGrids250m (HENGL et al., 2017) y variables relacionadas con las propiedades físicas y químicas del suelo obtenidas de mapas ráster con resolución espacial de 500 m producidos por BALLABIO et al. (2016) y la base de datos LUCAS 2009 TOPSOIL del Centro Europeo de Datos de Suelos (ESDAC) (PANAGOS et al., 2012). Para valorar la litología, se utilizó un mapa específico de clases litológicas reclasificadas elaborado por el Instituto de Recursos Naturales y Ordenación del Territorio de Asturias (INDUROT) (GARCÍA-MANTECA et al., 2024). Para predecir los efectos del cambio climático se emplearon los Modelos de Clima Global (GCM) para 2050 y 2070 basados en el modelo CMIP5 del quinto Informe de Evaluación del IPCC (<http://www.worldclim.org/CMIP5>).

### ***3.3. Estrategias de desarrollo de modelos***

#### ***3.3.1. Modelos de producción***

Para el ajuste de los modelos de producción se comprobó la influencia de varios factores importantes: i) precisión de la geolocalización de las parcelas y ii) tipo de corrección de las imágenes de satélite. La ausencia de parcelas IFN con geolocalización submétrica en el IFN4, llevó a los responsables de este a medir nuevas coordenadas con errores menores a 1 m en el 73,36% de las parcelas en la última remediación de 2018 en el norte de España para las especies más productivas (IFN4.5). Además, debido a la orografía tan compleja de la zona de estudio, se probaron tres tipos de datos a partir de imágenes de satélite: datos corregidos radiométrica y geoméricamente, datos que además de las anteriores correcciones incluían corrección atmosférica y finalmente datos que además de las correcciones anteriores incluían corrección topográfica. Además, para comprobar la contribución de cada grupo o tipo de variables se crearon varias bases de datos que iban incluyendo de forma secuencial los distintos grupos de variables independientes.

#### ***3.3.2. Modelos de clasificación de coberturas***



Se desarrollaron modelos de coberturas multinivel usando para ello como base la clasificación jerárquica de tres niveles de CLC-2018: el primer nivel L1 clasifica el territorio en 5 grandes clases (superficies artificiales, áreas agrícolas, bosques y áreas semi-naturales, humedales y masas de agua) y los restantes L2 y L3 van subdividiendo los grupos del primer nivel en clases cada vez más detalladas. A esta clasificación se le añadió un nivel más (L4) para discriminar las especies forestales ya que el objetivo final de nuestro trabajo es el desarrollo de modelos de clasificación de coberturas que discrimine adecuadamente las superficies de las 3 especies de interés en el proyecto.

Para el ajuste del modelo de clasificación de coberturas se comprobó también la influencia de varios factores importantes: *i)* el tipo de corrección de las imágenes de satélite, *ii)* la eficacia de distintos algoritmos de corrección, tanto atmosférica como topográfica, *iii)* la influencia de la resolución del MDT en las correcciones topográficas de las imágenes, y *iv)* el efecto de la fenología de las especies a través del análisis de una serie temporal anual de imágenes.

### **3.3.3. Modelos de productividad**

Para el ajuste de los modelos de productividad se abordaron los modelos a dos escalas espaciales diferentes: paisaje y parcela forestal. En este sentido, las variables predictoras consideradas inicialmente fueron utilizadas o no en cada tipo de escala espacial dependiendo de: *i)* su resolución espacial original, *ii)* su utilidad de remuestreo y *iii)* la escala espacial final prevista para los modelos a ajustar. Así, en el modelo de productividad a escala de paisaje se utilizó una resolución espacial de 250 m píxel<sup>-1</sup>. Este modelo es útil a nivel de planificación táctica y también para analizar el efecto del cambio climático en la productividad forestal. Se probaron modelos a escala parcela forestal a varias resoluciones espaciales diferentes: desde 10 hasta 100 m píxel<sup>-1</sup>. Los modelos anteriores son de especial utilidad a nivel de planificación operativa para predecir producciones futuras de pequeñas parcelas forestales plantadas con las especies y para elegir las zonas más productivas para llevar a cabo nuevas plantaciones.

### **3.4. Métodos de ajuste y evaluación de modelos**

Aunque en algunos casos se probaron varios algoritmos *machine learning*, el algoritmo más utilizado ha sido *Random Forest* (RF) (BREIMAN, 2001). Para la evaluación de los modelos se usó el método de validación cruzada con datos divididos en 10 grupos iguales y 10 repeticiones para obtener las predicciones y sus errores asociados. En la evaluación de los modelos de producción y productividad se obtuvieron el coeficiente de determinación, los valores absoluto y relativo del error medio absoluto y del error medio cuadrático. En el caso de los modelos de clasificación de coberturas se usaron los estadísticos Kappa y la precisión global para evaluar los modelos. Para seleccionar los predictores finales de cada modelo, se utilizó la medida de importancia variable expresada en valores relativos, que permite identificar las variables independientes que más aportan al poder predictivo del modelo. Para conocer las relaciones funcionales subyacentes entre la productividad y cada variable independiente se usaron también gráficos



de respuesta marginal, que permiten explorar las relaciones entre la variable dependiente y las variables predictivas más importantes (CHOUDHURY et al., 2021).

#### 4. Resultados, limitaciones y mejoras futuras

##### 4.1. Modelos de producción

Los resultados del proyecto han demostrado la utilidad de las bases de datos públicas (tanto de campo como las derivadas de sensores remotos instalados en satélites y plataformas aerotransportadas) para la elaboración de modelos forestales de producción. Previamente, NOVO-FERNÁNDEZ et al., 2019 demostraron que es posible una puesta en común de los datos de campo del Inventario Forestal Nacional de España (IFN) con los datos LiDAR del proyecto PNOA-LiDAR para la elaboración de modelos de producción insesgados, aplicando metodologías de armonización temporal y espacial de datos debido a la falta de coincidencia temporal entre los vuelos del PNOA-LiDAR y los trabajos de campo del IFN y a la falta de geolocalización submétrica de las parcelas del IFN. De hecho, estas dificultades de armonización han sido el principal impedimento por el que no hay más modelos de producción con datos combinados IFN y PNOA-LiDAR a escala regional en España. Los resultados obtenidos han permitido validar la metodología para ser aplicada en todo el norte de España.

Se obtuvieron modelos de producción insesgados en formato ráster con una resolución espacial de 10 m píxel<sup>-1</sup> a partir de datos del IFN y del satélite Sentinel-2. Los R<sup>2</sup> de los modelos de producción oscilaron entre 0,41 y 0,46, dependiendo de las especies (NOVO-FERNÁNDEZ et al., 2024). Los modelos no necesitaron armonización temporal ya que es posible seleccionar imágenes de satélite que coincidan con la fecha de realización de los trabajos de campo del IFN (Figura 1). Sin embargo, en este proyecto se comprobó la importancia o necesidad de realizar correcciones topográficas de las imágenes en terrenos con pendientes pronunciadas o con topografía compleja como ocurre en el norte de España. A diferencia de los modelos IFN4-PNOA-LiDAR, se pueden desarrollar modelos forestales IFN-Sentinel-2 razonablemente precisos, a partir de datos procedentes de sensores remotos pasivos sin un requerimiento tan elevado de precisión en la geolocalización.

Se comprobó que es posible obtener una ganancia significativa en precisión de los modelos como consecuencia de incluir secuencialmente grupos de variables predictoras (bandas espectrales, índices espectrales, variables de textura, topográficas y climáticas), cuyo resultado dependió de una mezcla compleja de las variables de masa y especies forestales (y su estructura y distribución forestal) analizadas y, por lo tanto, se recomienda utilizar este enfoque de trabajo para el desarrollo de dichos modelos (NOVO-FERNÁNDEZ et al., 2024). Por otro lado, la actualización de los datos de producción en volumen con carácter anual sólo requiere aplicar el modelo de producción en volumen ( $TV$ , en m<sup>3</sup>ha<sup>-1</sup>) a un nuevo conjunto de imágenes de Sentinel-2. La actualización de la biomasa se consigue de

la misma forma.

Actualmente los modelos basados en datos Sentinel-2 pueden usarse para cubrir las carencias de los modelos desarrollados a partir del proyecto PNOA-LiDAR en temporalidades superiores a los 3-5 años. A pesar de que la estimación de variables de producción basadas en imágenes Sentinel-2 son menos robustas que las obtenidas a partir de datos LiDAR, éstas son insesgadas y, por lo tanto, se esperan estimaciones relativamente precisas cuando están referidas a la unidad de superficie de la hectárea, ya que los valores se obtienen promediando las predicciones obtenidas para 100 píxeles (resolución de 10 m píxel<sup>-1</sup>), lo que supone una compensación de los errores esperados.

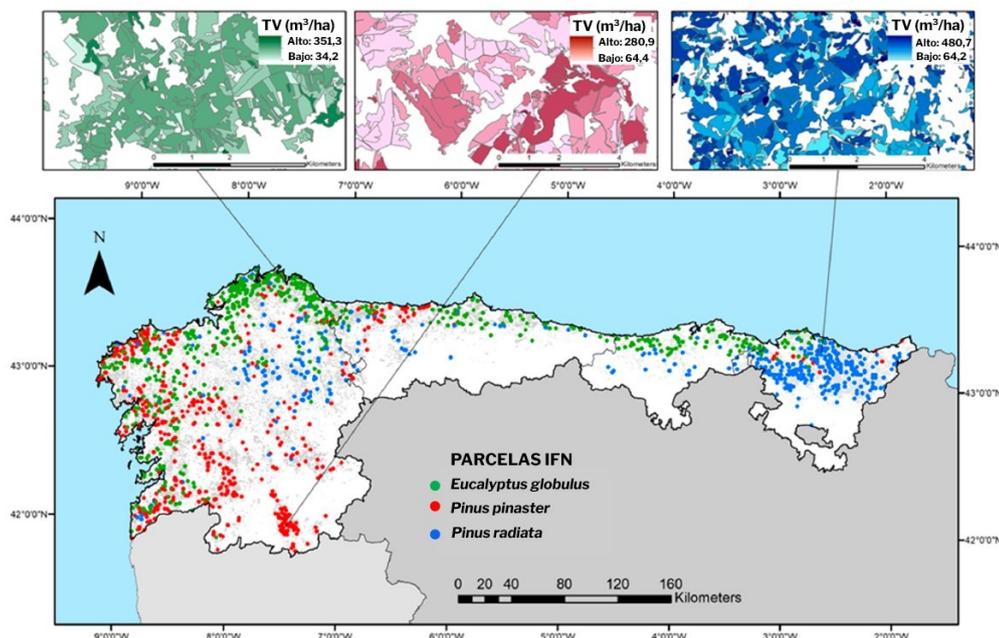


Figura 1. Ejemplo de generación de mapas de producción para teselas de cada especie del Mapa Forestal de España (MFE 1:25.000).

Como principales limitaciones de los trabajos desarrollado se citan las siguientes:

1. El estudio se ha centrado en el norte de España (Galicia, Asturias, Cantabria y País Vasco) y solo ha abordado masas puras ( $\geq 80\%$  del área basimétrica corresponden a la especie principal) de las 3 principales especies comerciales (*E. globulus*, *P. pinaster* y *P. radiata*).
2. Todos los modelos ajustados presentaron un comportamiento similar, con sobreestimación de las estimaciones para valores más bajos observados y subestimación para valores más altos.
3. La precisión de los modelos se reduce bastante en masas maduras con elevada densidad debido a la saturación que la información de la cubierta de copas produce en la señal de los sensores remotos pasivos.

Como mejoras futuras, es deseable generalizar la metodología desarrollada para

aplicarla a las principales especies forestales del norte de España y tanto a masas puras como a masas mixtas. Además, es necesario seguir probando nuevas variables independientes y auxiliares procedentes de sensores instalados en otros satélites de acceso gratuito (p.ej., variables radar, etc.).

#### 4.2. Modelos de clasificación de coberturas

Se ha abordado por primera vez (hasta donde nosotros sabemos) el cartografiado automático de coberturas a nivel suprarregional en España utilizando fuentes de datos públicas. A pesar de las dificultades que se están encontrando en el logro de este objetivo, los resultados hasta ahora son muy valiosos y han puesto de relieve la influencia o el impacto de factores estructurales del territorio como la orografía o el tamaño de la propiedad forestal en la precisión de las clasificaciones. Debido a lo anterior, se ha observado la necesidad de llevar a cabo correcciones topográficas con un modelo digital del terreno preciso en las imágenes de satélite, así como la importancia de realizar una segmentación previa, que permita trabajar una clasificación orientada a objetos (parcelas catastrales) en vez de píxeles (TEIJIDOMURIAS et al., 2024). Se debe añadir que el uso de novedosas metodologías de aprendizaje profundo (Deep Learning) va a tener una relevancia especial en este trabajo al cambiar el paradigma tradicional entre lo que debe predecir y cómo debe aprender el modelo, por lo que cabe esperar una reducción de los procesos previos en las imágenes, así como en la información necesaria para realizar estos análisis. Los mapas actuales (con incorporación de la fenología y variables auxiliares) es la mejor herramienta disponible para llevar a cabo la clasificación automática de coberturas en el norte de España en espera de incorporar nuevas mejoras en las que actualmente seguimos trabajando en colaboración con centros de investigación internacionales que puedan retroalimentar nuestros procesos (Figura 2).

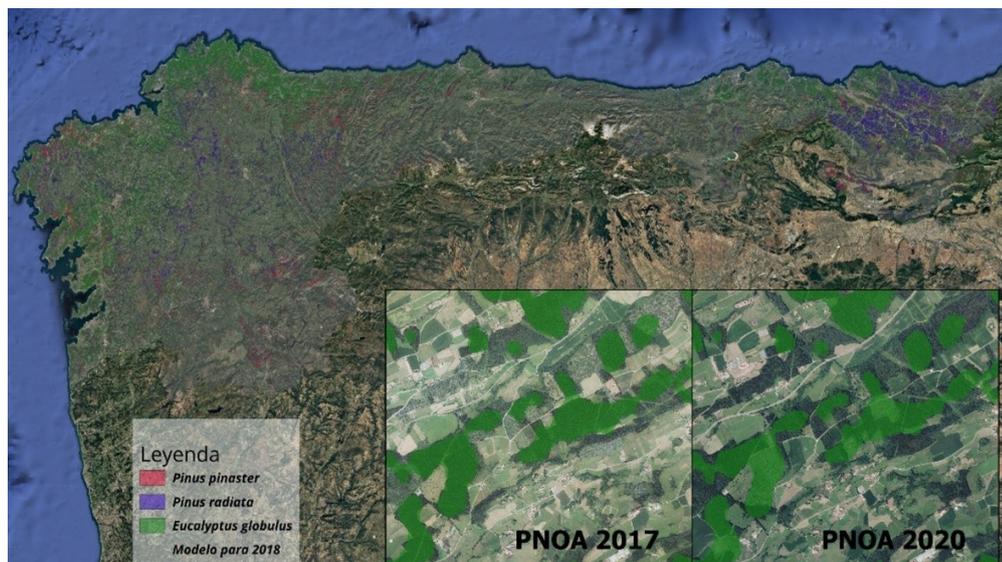


Figura 2. Modelo preliminar de clasificación automática de coberturas de las



*especies de interés en el norte de España sin incluir la fenología de las especies.*

Como principales limitaciones de los trabajos desarrollado se citan las siguientes:

1. La no disponibilidad de una serie temporal consistente, libre de nubes, o un mosaico anual para toda el área de estudio.
2. Tampoco existe un repositorio con una colección de imágenes de reflectancia en superficie solo con correcciones atmosféricas o bien con correcciones topográficas utilizando un modelo digital del terreno de alta resolución, lo más parecido son las imágenes Sentinel-2 nivel 2A.
3. La resolución de las imágenes satélite Sentinel-2, con 10 m pixel<sup>-1</sup> no permite capturar con precisión la variabilidad del terreno y su rápido cambio de cobertura.
4. Se está abordando el trabajo en la plataforma *Google Earth Engine* (GGE), y su uso impone limitaciones para realizar correcciones atmosféricas y topográficas de las imágenes al no encontrarse estas integradas en la misma, así como a la hora de exportar los productos generados. No obstante, se considera una valiosa herramienta en este trabajo.

En cuanto a las mejoras que se están llevando, se citan las siguientes:

1. Análisis de la serie temporal, entendiéndose esta como una sucesión de imágenes en todo un año.
2. Segmentación previa del territorio utilizando como base el catastro.
3. Implementación de un algoritmo *Deep Learning U-net*, utilizando la segmentación semántica para la detección de las 3 especies de interés.

#### **4.3. Modelos de productividad**

Se dispone por primera vez de mapas de productividad actual para *P. pinaster*, *P. radiata* y *E. globulus* en todo el noroeste de España (Galicia, Asturias, Cantabria y País Vasco) (Figura 3), además de mapas espacialmente continuos que valoran el efecto previsto en la productividad bajo distintos escenarios de cambio climático para los horizontes temporales de 2050 y 2070 (Figura 4). Se trata de contribuciones valiosas, tanto desde el punto de vista científico (por las metodologías usadas y por su interés para otros trabajos científicos), como desde el punto de vista operativo, como herramientas para que planificadores, gestores y propietarios forestales fundamenten sus decisiones en planificación y gestión del territorio.

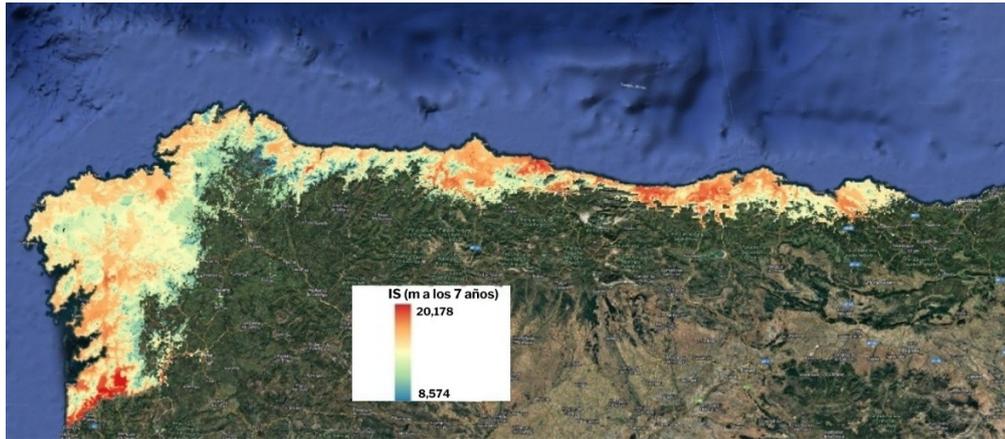


Figura 3. Ejemplo de mapa de productividad para *E. globulus* su área de distribución óptima de la especie en el norte de España.

Nuestros resultados han demostrado que, con las capas ráster de variables del terreno, climáticas y litológicas actualmente disponibles, es posible su escalamiento ascendente (agregación) o descendente (desagregación), permitiendo obtener estimaciones de productividad razonablemente precisas e insesgadas a resoluciones espaciales de entre 10 y 250 m píxel<sup>-1</sup>, con porcentajes de variabilidad explicada alrededor del 45-50% (TEIJIDO-MURIAS et al., 2025).

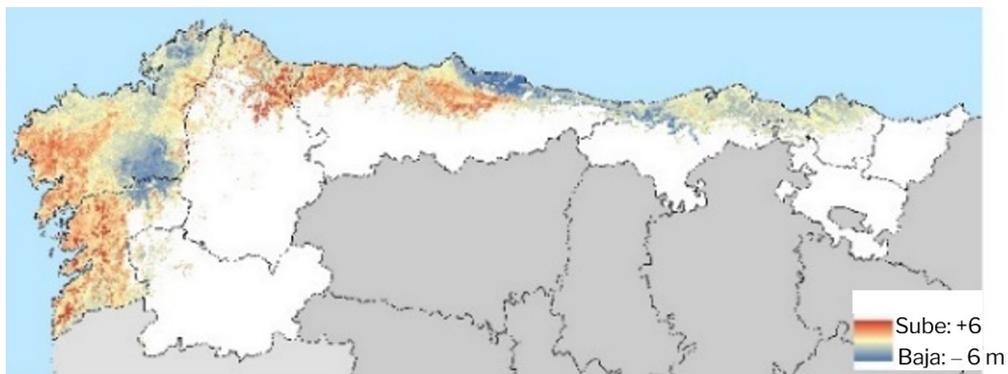


Figura 4. Ejemplo de mapa de cambio productividad para *E. globulus* en su área de distribución óptima en el norte de España para el año 2050 y un escenario de cambio climático moderado (RCP 4.5). Nota: subida de IS en tonalidades granates, bajada de IS en tonalidades azules y sin cambio o cambio leve de IS en tonalidades amarillas.

No obstante, existen numerosas limitaciones que impiden obtener estimaciones más precisas de la productividad. Según su origen, estas las hemos clasificado en tres grupos o factores (TEIJIDO-MURIAS et al., 2025): i) factores de gestión; ii) factores naturales y iii) factores operativos. Los factores de gestión se refieren a aspectos como la introducción a lo largo de los años de material forestal de reproducción con distintos orígenes y grados de mejora genética (esto es muy determinante en el caso de *E. globulus*), la coexistencia de rodales gestionados y no gestionados y también entre masas procedentes de brinzal y de chirpial (en el caso de *E. globulus*). En cuanto a los factores naturales, existe disminución en la

productividad de muchas masas debido al efecto pasado de plagas y/o enfermedades. Tanto los factores de gestión como los naturales están habitualmente embebidos en los datos e introducen variabilidad en la productividad de la estación no atribuible a factores intrínsecos (los que determinan la capacidad productiva inherente o natural de los terrenos). La principal limitación operativa se refiere a la disponibilidad de datos ambientales espacialmente continuos. Así, la resolución espacial de las capas disponibles actualmente sobre variables edáficas sigue siendo insuficiente para desarrollar modelos de productividad de alta resolución espacial (mayor de 250 m píxel<sup>-1</sup>).

Como mejora futura, se tratarán de desarrollar capas ráster que redigan las principales variables edáficas de los 20 cm superiores del suelo (*Topsoil*) con resoluciones espaciales superiores a 100 m píxel<sup>-1</sup> para su uso como variables independientes en los modelos de productividad. Para ese propósito, hemos recopilado durante los últimos años más de 2.000 muestras de suelo geolocalizadas procedentes de diferentes fuentes en el norte de España (Figura 5). Aunque el número total de muestras es alto, en alguna región como Cantabria el número es bajo. Por ello, el proyecto está abierto a la colaboración de cualquier investigador/organización que quiera poner a nuestra disposición sus muestras de suelo geolocalizadas para conseguir una base de datos lo más representativa posible del territorio estudiado.



Figura 5. Distribución espacial de las muestras de suelo geolocalizadas disponibles a fecha actual.

#### 4.4. Geoportal y visor de mapas

Los mapas finales de producción, coberturas y productividad generados en el proyecto son accesibles de manera pública a través de un visor al que se accede a través del enlace: <http://quercus.uniovi.es> (Figura 6)

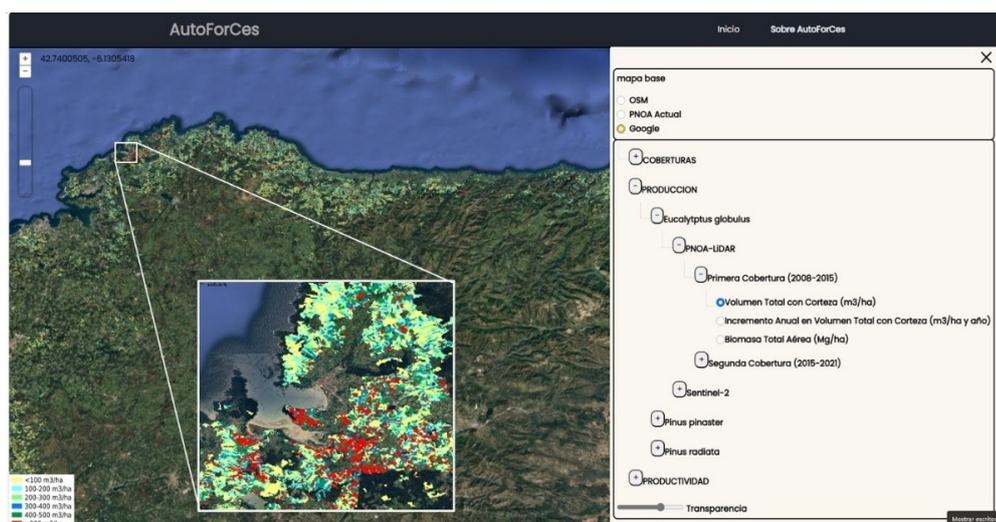


Figura 6. Aspecto del visor de mapas del geoportal de AutoForCes.

## 5. Conclusiones

Los resultados del proyecto AutoForCes han demostrado que hoy en día es posible elaborar modelos de productividad forestal de alta resolución espacial y también modelos de crecimiento y producción con alta resolución espacial y temporal. Aunque actualmente existen limitaciones que impiden una mejor precisión, las rápidas innovaciones y mejoras en los sensores instalados en los satélites, y la disponibilidad de nuevas capas espacialmente continuas con información ambiental más detallada permitirán ir mejorando los modelos ya elaborados y abordar la construcción de otros nuevos para aquellas especies para las que no están disponibles actualmente.

## 6. Agradecimientos

El proyecto de investigación AutoForCes, con código MCI-21-PID2020-112839RB-I00 ha sido financiado por la Agencia Estatal de Investigación (AEI) del Ministerio de Ciencia e Innovación (MCIN/AEI/10.13039/501100011033).

## 7. Bibliografía

ÁLVAREZ-GONZÁLEZ, J.G.; CAÑELLAS, I.; ALBERDI, I.; GADOW, K.V.; RUIZ-GONZÁLEZ, A.D.; 2014. National Forest Inventory and forest observational studies in Spain: Applications to forest modelling. *For. Ecol. Manag.* 316,54–64.

BALLABIO, C.; PANAGOS, P.; MONTANARELLA, L.; 2016. Mapping topsoil physical properties at European scale using the LUCAS database. *Geoderma* 261, 110–123.



BONTEMPS, J.D.; BOURIAUD, O.; 2014. Predictive approaches to forest site productivity: recent trends, challenges and future perspectives. *Forestry* 87(1), 109–128.

BREIMAN, L.; 2001. Random forests. *Mach. Learn.* 45 (1), 5–32.

CHOUNDHURY, P.; ALLEN, R.T.; ENDRES, M.G.; 2020. Machine learning for pattern discovery in management research. *Strat. Magmt. J.*, 42: 30–57.

CLUTTER, J.; FORTSON, J.; PIENAAR, L.; BRISTER, H.; BAYLEY, R.; 1983. *Timber management: a quantitative approach*. Wiley, New York

CNIG; 2023. Centro Nacional de Información Geográfica (CNIG). Datos ALS. Disponible online: <http://centrodedescargas.cnig.es/CentroDescargas/buscadorCatalogo.do?> .

FAO; 2020. Global Forest Resources Assessment 2020. Main Report. <http://www.fao.org/3/ca9825en/CA9825EN.pdf>.

FREER-SMITH, P.; MUYS, B.; BOZZANO, M.; DRÖSSLER, L.; FARRELLY, N.; JACTEL, H.; KORHONEN, J.; MINOTTA, G.; NIJNIK, M.; ORAZIO, C.; 2019. Plantation forests in Europe: challenges and opportunities. *From Science to Policy* 9. European Forest Institute.

GARCÍA-MANTECA, P.; MARQUÍNEZ, J.; MENÉNDEZ-DUARTE, S.; 2024. Aproximación a un mapa de potencialidad edáfica de interés en la distribución de la vegetación en la Cornisa Cantábrica. *Naturalia Cantabricae* 12(3): 43–52.

HENGL, T.; MENDES DE JESUS, J.; HEUVELINK, G.B.M.; RUIPEREZ GONZALEZ, M.; KILIBARDA, M.; BLAGOTIC, A.; SHANGGUAN, W.; WRIGHT, M.N.; GENG, X.; BAUER-MARSCHALLINGER, B.; GUEVARA, M.A.; VARGAS, R.; MACMILLAN, R.A.; BATJES, N.H.; LEENARS, J.G.B.; RIBEIRO, E.; WHEELER, I.; MANTEL, S.; KEMPEN, B.; 2017. SoilGrids250m: global gridded soil information based on machine learning. *PloS ONE* 12 (2), e0169748.

HIJMANS, R.J.; CAMERON, S.E.; PARRA, J.L.; JONES, P.; JARVIS, A.; 2005. Very high resolution interpolated climate surfaces for global land areas. *Int. J. Climatol.* 25, 1965–1978.

MAPA; 2019. Actualización del cuarto inventario forestal español. Ministerio de Agricultura, Pesca y Alimentación. Gobierno de España (Disponible para investigadores bajo solicitud).



MITECO; 2024. Anuario de Estadística Forestal. Ministerio para la Transición Ecológica y el Reto Demográfico. Gobierno de España. 2022.

MOSER, P.; VIBRANS, A.C.; MCROBERTS, R.E.; NÆSSET, E.; GOBAKKEN, T.; CHIRICI, G.; MURA, M.; MARCHETTI, M.; 2017. Methods for variable selection in Lidar-assisted forest inventories. *Forestry*, 90: 112–124.

NILSSON, M.; NORDKVIST, K.; JONZÉN, J.; LINDGREN, N.; AXENSTEN, P.; WALLERMAN, J.; EGBERTH, M.; LARSSON, S.; NILSSON, L.; ERIKSSON, J.; OLSSON, H.; 2017. A nationwide forest attribute map of Sweden predicted using airborne laser scanning data and field data from the National Forest Inventory. *Remote Sens. Environ.* 194: 447–454.

NINYEROLA, M.; PONS, X.; ROURE, J.M.; 2005. Atlas Climático Digital de la Península Ibérica. Metodología y Aplicaciones en Bioclimatología y Geobotánica, Universidad Autónoma de Barcelona: Bellaterra, España.

NOVO-FERNÁNDEZ, A.; BARRIO-ANTA, M.; RECONDO, C.; CÁMARA-OBREGÓN, A.; LÓPEZ-SÁNCHEZ, C.A.; 2019. Integration of National Forest Inventory and Nationwide Airborne Laser Scanning Data to Improve Forest Yield Predictions in North-western Spain. *Remote Sensing*, 11(14), 1-25.

NOVO-FERNÁNDEZ, A.; LÓPEZ-SÁNCHEZ, C.A.; CÁMARA-OBREGÓN, A.; BARRIO-ANTA, M.; TEIJIDO-MURIAS, I.; 2024. Estimating Forest Variables for Major Commercial Timber Plantations in Northern Spain Using Sentinel-2 and Ancillary Data. *Forests* 15, 99.

PANAGOS, P.; VAN LIEDEKERKE, M.; JONES, A.; MONTANARELLA, L.; 2012. European Soil Data Centre: response to European policy support and public data requirements. *Land Use Policy* 29, 329–338.

RIVAS-MARTÍNEZ, S., PENAS, A., DÍAZ, T.E., 2004. Biogeographic map of Europe, Cartographic Service, Universidad de León.

SKOVSGAARD, J.P.; VANCLAY, J.K.; 2008. Forest site productivity: a review of the evolution of dendrometric concepts for even-aged stands. *Forestry* 81, 13–31.

TEIJIDO-MURIAS, I.; BARRIO-ANTA, M.; LÓPEZ-SÁNCHEZ, C.A.; 2024. Evaluation of correction of Sentinel-2 images implemented in Google Earth Engine for use in land cover classification in Northern Spain. *Forests* 15(12), 2192.

TEIJIDO-MURIAS, I.; LÓPEZ-SÁNCHEZ, C.A.; GARCÍA-MANTECA, P.; GARCÍA-VILLABRILLE, J.D.; ROJO-ALBORECA, A.; RUIZ, F.; BARRIO-ANTA, M.; 2025. A multi-



scale framework for mapping the site productivity for *Eucalyptus globulus* Labill. plantations in Northern Spain using spatially explicit environmental variables as predictors. For. Ecosyst. In Press.