



2025 | 16-20
GIJÓN | JUNIO

9º CONGRESO FORESTAL ESPAÑOL

9CFE-1459

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

Organiza





Predicción del volumen total forestal en el norte de España utilizando enfoques de aprendizaje automático y aprendizaje profundo

TEIJIDO-MURIAS, I.(1), ANTROPOV, O.(2), LÓPEZ-SÁNCHEZ, C.A.(1),

MOLINIER, M.(2), BARRIO-ANTA, M.(1) and MIETTINEN, J.(2)

(1) SMartForest Research Group. Department of Organismal and Systems Biology, Mieres Polytechnic School, University of Oviedo, Mieres University Campus, C/Gonzalo Gutiérrez Quirós S/N, 33600 Mieres (Spain).

(2) VTT Technical Research Centre of Finland, P.O. Box 1000, FI-02044 VTT, Finland.

Resumen

En este trabajo se presentan diferentes enfoques de aprendizaje automático para predecir el volumen total con corteza en rodales forestales del norte de España utilizando variables predictoras obtenidas a partir de imágenes satelitales. La variable objetivo fue obtenida de las parcelas de campo de la cuarta actualización del Inventario Forestal Nacional para el norte de España (IFN4.5). Se implementaron técnicas de aprendizaje automático para predecir los volúmenes con los modelos no paramétricos k-Nearest Neighbors (kNN) y Random Forest (RF). Además, se exploró el uso del aprendizaje profundo a través de redes neuronales convolucionales (CNN), empleando arquitecturas como U-Net. Debido a la complejidad en el entrenamiento de modelos basados en redes neuronales, que requieren información espacialmente continua, es posible optar por utilizar un modelo previamente entrenado y reajustarlo, utilizando solo información puntual de la región de interés. Esta estrategia permitió aprovechar el conocimiento preexistente de grandes conjuntos de datos y adaptar los modelos a las condiciones específicas de la zona de estudio, mejorando así la precisión en la predicción de variables forestales. El estudio incluyó una comparación de la precisión entre los modelos basados en kNN y Random Forest frente a los modelos de aprendizaje por transferencia. La combinación de enfoques tradicionales y avanzados permitió identificar las mejores técnicas para la predicción a gran escala del volumen total. Los resultados de este trabajo contribuirán a mejorar la monitorización y gestión forestal, especialmente en áreas con datos de campo limitados debido a la compleja topografía, ofreciendo una solución eficiente para evaluar recursos forestales, como el volumen con corteza o la biomasa forestal.

Palabras clave

Sentinel-2, knn, random-forest, unet, cnn, deep-learning

1. Introducción

El uso de datos de teledetección para la estimación de parámetros forestales es actualmente una herramienta bien conocida que permite obtener estimaciones espacialmente continuas de una variable de interés mediante su modelización a partir de datos obtenidos en trabajos de campo y datos de sensores remotos (FANG et al., 2023; NOVO-FERNÁNDEZ et al., 2024). El trabajo de campo intensivo en silvicultura realizado por los gobiernos en las últimas décadas, combinado con los altos presupuestos disponibles para la observación de la Tierra a través de sensores satelitales ha permitido generar una gran cantidad de datos que han hecho que estas técnicas sean actualmente posibles y también económicamente viables (AGUIRRE et al., 2022).

Desde una perspectiva forestal, la tecnología LiDAR es una de las más precisas para obtener estimaciones espacialmente continuas de las variables forestales (NOVO-FERNÁNDEZ et al., 2019). Sin embargo, su adquisición requiere un alto presupuesto, ya que no existe aún un sensor LiDAR satelital continuo, limitándose



a datos puntuales o lineales como la misión GEDI o ICESAT-2.

Dentro de las técnicas disponibles para la modelización no paramétrica, podemos generalizarlas en dos grandes grupos dentro de la inteligencia artificial: el aprendizaje automático (Machine Learning, ML) (ALSHARI et al, 2022) y el aprendizaje profundo (Deep Learning, DL) (GE et al, 2022). El aprendizaje automático permite a los algoritmos aprender de los datos. Los modelos de ML, como los árboles de decisión, se entrenan con conjuntos de datos limitados para hacer predicciones de una variable basada en algoritmos matemáticos. De esta manera, se puede generar un modelo con un no muy extenso número de datos de entrenamiento. Por otro lado, el aprendizaje profundo utiliza redes neuronales artificiales inspiradas en el funcionamiento del cerebro humano; múltiples capas de neuronas permiten la detección de patrones complejos en grandes volúmenes de datos. Por lo tanto, requieren grandes cantidades de datos y una alta capacidad computacional para ser efectivos. Para entrenar modelos de DL, es necesario tener datos espacialmente continuos de la variable de interés, ya que estos modelos trabajan con información raster, a diferencia de los métodos ML que utilizan información en forma tabular. Desafortunadamente, todavía no existe una fuente de datos armonizada para crear estos modelos espacialmente continuos a partir de predictores obtenidos con LiDAR en el Norte de España, donde los datos de campo y los vuelos tengan una correlación temporal. Una vez que se han obtenido estos modelos y se han predicho las variables de interés de manera continua, es posible utilizarlos como datos de entrada en los diferentes modelos de DL desarrollados específicamente para este objetivo.

Es necesario aclarar tres conceptos que se utilizarán a continuación, sin los cuales la comprensión del texto puede ser tediosa. Por un lado, tenemos el “entrenamiento” de un modelo, que parte de los datos de entrada y la arquitectura neuronal definida con el objetivo de modelizar una variable específica. A partir de este modelo, ya entrenado, podemos obtener un mapa espacialmente continuo de la variable de interés, este proceso se llama “aplicar” el modelo. Ambas definiciones son idénticas en todos los métodos propuestos, DL y ML. Sin embargo, cuando tratamos con modelos de DL tenemos una opción más, que llamaremos “transferencia” y no es más que, a partir de un modelo entrenado para una área y variable específica, llevar a cabo su “transferencia” a otra área. Para dar un ejemplo forestal, imaginemos que tenemos un ingeniero en una empresa para realizar tasaciones en bosques de eucalipto en Galicia, pero la empresa ha decidido abrir una línea de negocio en Huelva. El ingeniero encargado de realizar las tasaciones conoce el entorno forestal, conoce la especie y está acostumbrado a medir volúmenes, pero al transferirlo a otra región necesitará aprender estas nuevas particularidades y aprender las diferencias entre ambas áreas. Este mismo efecto se logra al transferir un modelo que ha sido previamente entrenado con un objetivo específico en una área concreta. Por lo tanto, la transferencia consiste en entrenar un modelo con un propósito específico, en este caso la predicción del volumen total con corteza, en un área donde se dispone de información espacialmente continua; para a continuación, volver a entrenar ese modelo, transferirlo, a otra área donde solo conocemos observaciones puntuales, como las parcelas del IFN (GE et al, 2023).

De esta manera, al usar un modelo preentrenado es posible mejorar las predicciones, las estadísticas de bondad de ajuste, de los modelos de Machine Learning (ML).

2. Objetivos



El objetivo de esta investigación fue comparar los modelos de aprendizaje profundo (DL) por transferencia a la región norte de España con los modelos machine learning desarrollados para predecir el volumen total con corteza en plantaciones forestales de *E. globulus*, *P. pinaster* y *P. radiata*

3. Metodología

3.1. Datos utilizados

Para el desarrollo de este estudio se utilizaron dos tipos diferentes de datos: i) datos de campo y ii) datos de teledetección.

Los primeros corresponden a las parcelas de campo de la cuarta actualización del inventario forestal para especies productivas en el norte de España (IFN 4.5, 2018), de las cuales se extrajo la geolocalización, así como la variable volumen con corteza por hectárea. Esta red de parcelas ha sido utilizada con objetivos similares en estudios previos, y sus especificaciones pueden consultarse en NOVO-FERNÁNDEZ (2024).

Los datos de teledetección utilizados corresponden a imágenes proporcionadas por la Agencia Espacial Europea (ESA) a través de la constelación de satélites Sentinel-2. Sentinel-2 es una misión satelital de la ESA diseñada para obtener imágenes ópticas de alta resolución. Está compuesta por dos satélites que proporcionan datos multiespectrales en 13 bandas, con un tiempo de revisita de 5 días en el Ecuador (2-3 días en latitudes medias). Para nuestra área de estudio, seleccionamos imágenes con ángulos de observación mínimos, condiciones libres de nubes y adquiridas durante los meses de verano. Utilizamos productos Sentinel-2 de nivel 2A, que incluyen corrección atmosférica y topográfica (basada en un modelo digital del terreno (MDT) de 90 m de resolución).

Las bandas utilizadas para estimar la variable dependiente fueron *B2*, *B3*, *B4*, *B5*, *B6*, *B7*, *B8*, *B8A*, *B11* y *B12*. Además, se obtuvo la banda de Evaluación de Calidad (*BQA*) para la detección de valores atípicos. Todas las imágenes se descargaron utilizando la plataforma Forestry-TEP desarrollada por VTT (<https://f-tep.com/>).

Todas las bandas fueron remuestreadas a una resolución espacial de 10 m utilizando el método del vecino más cercano.

En el caso de las parcelas utilizadas para el ajuste de transferencia, todas las parcelas del IFN 4.5 para el área de estudio fueron rasterizadas, para obtener una capa ráster con dicha información, que estuviese corregida con las imágenes Sentinel-2.

3.2. Análisis

Se ajustaron cuatro modelos diferentes para predecir el volumen total con corteza basado en las bandas espectrales de Sentinel-2: dos modelos de aprendizaje automático, ML (kNN (COVER y HART, 1967) y Random forest (BREIMAN, 2001)) y la arquitectura de red neuronal convolucional (U-NET (RONNEBERGER et al., 2015)) con dos enfoques, la aplicación directa del modelo entrenado previamente por el VTT y la transferencia del modelo preentrenado por VTT utilizando las parcelas del IFN4.5 (GE et al., 2023 y GE et al., 2022).

El modelo entrenado previamente al que se hace referencia en el texto para Cataluña fue desarrollado por el VTT; partiendo de mapas espacialmente continuos de volumen total, se entrenó una red neuronal U-NET cuya aplicación está limitada al área de estudio para el que está desarrollada. Para solventar esta limitación se recurre a la transferencia espacial del modelo a otras áreas.

Para ello, se utilizaron bases de datos de campo en formato vectorial, con las estadísticas zonales de las 10 bandas consideradas para los modelos de aprendizaje automático. En el caso de los modelos de aprendizaje profundo, la base de datos se generó a partir de las mismas parcelas en formato ráster y las imágenes Sentinel-2,



utilizando una ventana de recorte de 512 píxeles x 512 píxeles.

Para los modelos de aprendizaje automático (ML) se realizó una validación cruzada de 10 carpetas para evaluar el ajuste de los modelos. Este método divide el conjunto de datos en 10 partes iguales, donde cada parte se utiliza una vez como conjunto de validación, mientras que las partes restantes se utilizan para el entrenamiento.

Para los modelos de aprendizaje profundo (DL), los datos se dividieron en tres subconjuntos de la siguiente manera: un conjunto de entrenamiento (60% del tamaño total), un conjunto de validación (20% del tamaño total) y un conjunto de prueba (el 20% restante).

Los modelos fueron evaluados utilizando métricas como el error cuadrático medio (RMSE) y el pseudocoefficiente de determinación (R^2).

4. Resultados

Los estadísticos de bondad del ajuste de los modelos ajustados puede verse en la Tabla 1.

Tabla 1. Estadísticos de bondad del ajuste de los modelos.

Modelo	R^2	EMC
kNN	0,25	132,9
Random Forest	0,26	132,1
U-Net entrenado en Cataluña aplicado en la región Norte	0,14	130,6
U-Net entrenado en Cataluña transferido a la región Norte	0,49	103,2

Para evaluar los modelos DL, una vez aplicado el modelo U-Net entrenado sobre Cataluña, y utilizando las parcelas del IFN4.5 como verdad terreno se obtiene el diagrama de dispersión de valores observados (reales) frente a los valores predichos (estimados) que puede verse en la figura 1.

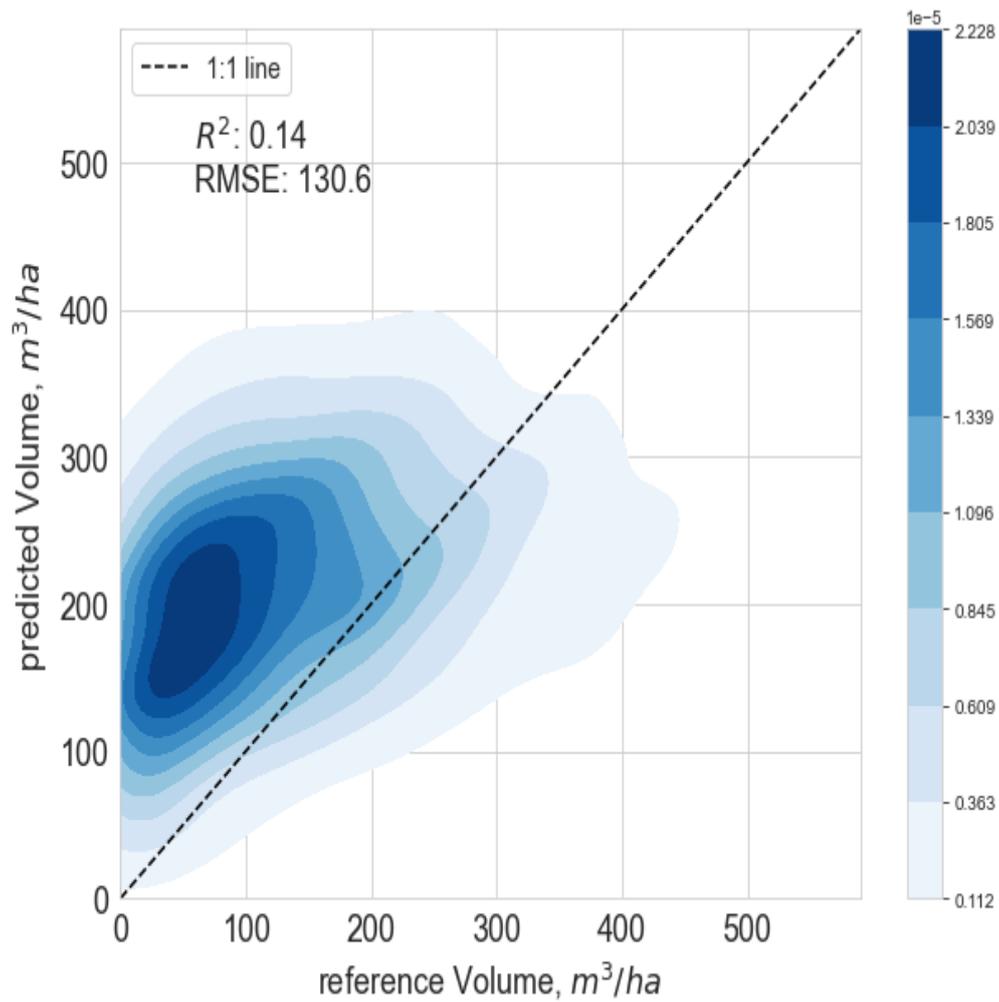


Figura 1. Diagrama de dispersión de valores observados (reales) frente a los valores predichos (estimados) en la aplicación del modelo U-Net entrenado por el VTT.

Cuando se transfiere el modelo previamente entrenado por el VTT para Cataluña a la zona objetivo utilizando las parcelas del IFN4.5 los resultados mejoran significativamente, como se puede observar en la Figura 2.

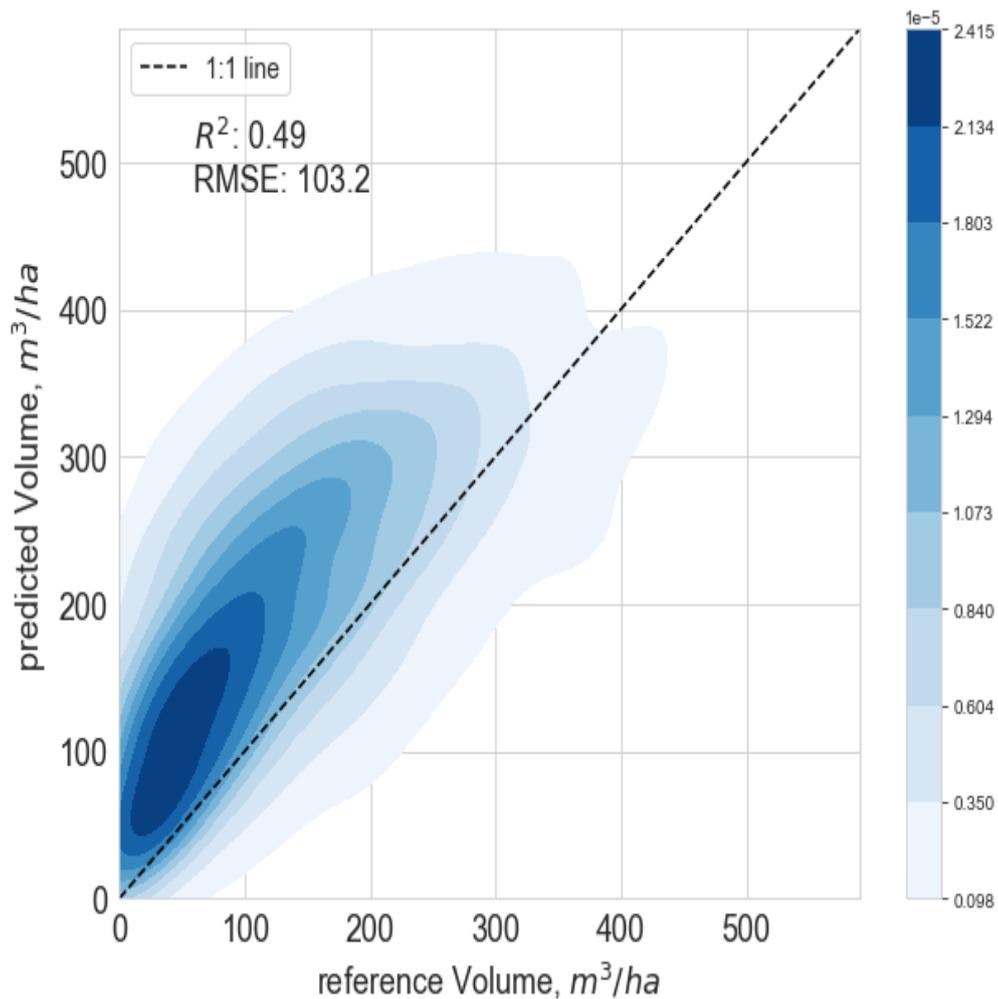


Figura 2. Diagrama de dispersión de valores observados (reales) frente a los valores predichos(estimados) en la transferencia, utilizando las parcelas del IFN4.5, del modelo U-Net entrenado por el VTT.

5. Discusión

5.1. Precisión de los modelos de ML

La Tabla 1 presenta las estadísticas de bondad de ajuste de los modelos desarrollados con técnicas de Machine Learning. El modelo KNN obtuvo un coeficiente de determinación (R^2) de 0.25, un sesgo de -2.87 y un error medio cuadrático (RMSE) de 132.9. El modelo Random Forest mostró un R^2 de 0.26, un sesgo de 1.39 y un RMSE de 132.1, evidenciando un rendimiento ligeramente superior en términos de ajuste y precisión del modelo. Los resultados mostrados por estos modelos que utilizan únicamente información espectral de un solo instante son los esperados y coinciden con los presentados por NOVO-FERNÁNDEZ et al. (2024) para estas variables predictoras. Para mejorar estos ajustes, los autores tradicionalmente han recurrido a incorporar otros tipos de variables, climáticas o del terreno, como es el caso de NOVO-FERNÁNDEZ et al. (2024). Se debe destacar que los modelos ML presentados en este estudio son peores que aquellos que incluyen más variables independientes como los presentados por ASTOLA et al., (2019), DOS REIS et al., (2018) o NOVO-FERNÁNDEZ et al. (2024), pero su finalidad no es la de ser un producto final; si no la de establecer un punto de comparación. A través de las técnicas estadísticas utilizadas hasta el momento y como variables independientes únicamente imágenes Sentinel-2 se ha comparado el resultado .



Con los avances recientes en técnicas estadísticas, es posible explorar otras vías como el uso de técnicas de Deep Learning (DL), en lugar de incluir una lista extensa de variables predictoras en el análisis.

5.2. Precisión de los modelos de DL

El modelo U-Net fue originalmente entrenado por el VTT en Cataluña, utilizando mapas espacialmente continuos de variables forestales obtenidos a partir de datos LiDAR aéreos.

La Figura 1 muestra la predicción del volumen total con corteza aplicando directamente el modelo U-Net original desarrollado por el VTT. En este caso, el coeficiente de determinación (R^2) es de 0,14 y el error medio cuadrático (RMSE) alcanza un valor de 130.6 m³/ha, indicando un pobre ajuste del modelo e inexactitud en las estimaciones. En comparación con los modelos de ML, tiene un RMSE algo menor, pero hay una falta de consistencia en términos de R^2 . Este resultado es esperado, puesto que la ecología de las masas mediterráneas difiere de las condiciones de las masas atlánticas, más aún si centramos el foco en las plantaciones de especies de crecimiento rápido. De esta forma se comprueba que la aplicación de modelos DL fuera de su zona de entrenamiento no permite obtener resultados positivos, siendo necesaria realizar una transferencia de los mismos.

La Figura 2 muestra la mejora obtenida al aplicar la transferencia a nuestra área de estudio del modelo previamente entrenado por el VTT. Este modelo fue posteriormente transferido a la región objetivo utilizando las parcelas del IFN4.5 como datos de referencia. Con este enfoque, el R^2 mejora notablemente hasta 0,49 y el RMSE disminuye a 103,2 m³/ha, reflejando un ajuste mucho más preciso y una reducción significativa en los errores de predicción. Es evidente que la transferencia del modelo logra una distribución más cercana a la línea 1:1, confirmando la mejora en el rendimiento del modelo, aunque tiende a sobreestimar. Aún así se hace evidente que la transferencia de modelos es una herramienta muy útil para obtener estimaciones precisas a partir de información satelital en áreas donde no se dispone de información espacialmente continua de la variable a modelar.

6. Conclusiones

Los modelos de aprendizaje automático (ML) mostraron baja precisión en la estimación del volumen total con corteza al utilizar únicamente la información provista por la constelación de sensores Sentinel-2. Por otro lado, los modelos de aprendizaje profundo (DL), si se aplican obviando las diferencias entre las diferentes masas forestales presentan problemas de generalización, reflejados en un R^2 bajo y un RMSE alto. Sin embargo, al transferir los modelos con parcelas puntuales del área de estudio, la precisión mejora significativamente, lo que demuestra la utilidad de la transferencia de modelos como una herramienta efectiva para mejorar las estimaciones a partir de información satelital en áreas donde no se dispone de datos espaciales continuos para entrenar los modelos DL, contribuyendo a una monitorización forestal más precisa y eficiente en regiones con datos limitados.

7. Agradecimientos

Este trabajo es el resultado del proyecto de investigación PID2020-112839RB-I00 financiado por la Agencia Estatal de Investigación (AEI) del Ministerio de Ciencia e Innovación (MCIN/AEI/10.13039/501100011033).

El trabajo de OA y JM fue financiado por la Agencia Espacial Europea (ESA), contrato 4000135015/21/I-NB - Monitoreo de Carbono Forestal, bajo el programa EOEP5.



El trabajo se llevó a cabo mientras IT-M. recibía una Beca para Estancias Cortas en Centros de Investigación del Principado de Asturias (código EB24-26) en el VTT, disfrutando de un contrato Severo Ochoa del Gobierno del Principado de Asturias (código BP21-125).

8. Bibliografía

AGUIRRE, A.; MORENO-FERNANDEZ, D.; ALBERDI, I.; HERNANDEZ, L.; ADAME, P.; CAÑELLAS, I.; MONTES, F. 2022. Mapping forest site quality at national level, *Forest Ecology and Management*, Volume 508, 120043, ISSN 0378-1127, <https://doi.org/10.1016/j.foreco.2022.120043>.

ALSHARI, E.; GAWALI, B. 2022. Analysis of Machine Learning Techniques for Sentinel-2A Satellite Images. *Journal of Electrical and Computer Engineering*. 2022. 1-16. 10.1155/2022/9092299.

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

COVER, T. y HART, P. 1967. Nearest neighbor pattern classification, *IEEE Transactions on Information Theory*, vol. 13, no. 1, pp. 21-27

FANG, G.; XU, H.; YANG, S.-I.; LOU, X.; FANG, L.; 2023. Synergistic use of Sentinel-1, Sentinel-2, and Landsat 8 in predicting forest variables. *Ecol. Indic.* 151: 110296.

GE, S.; ANTROPOV, O.; HAME, T.; MCROBERS, R.E. y MIETTINEN, J; 2023. Deep Learning Model Transfer in Forest Mapping Using Multi-Source Satellite SAR and Optical Images. *Remote Sens.* , 15, 5152.

GE, S; GU, H; SU, W; PRAKS, J. y ANTROPOV, O; 2022. Improved Semisupervised UNet Deep Learning Model for Forest Height Mapping With Satellite SAR and Optical Data, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 15, pp. 5776-5787,

NOVO-FERNÁNDEZ, A., BARRIO-ANTA, M., RECONDO, C., CÁMARA-OBREGÓN, A., LÓPEZ-SÁNCHEZ, 2019. Integration of National Forest Inventory and Nationwide Airborne Laser Scanning Data to Improve Forest Yield Predictions in North-Western Spain. *Remote Sensing*, 11(7), 1693. <https://doi.org/10.3390/rs11141693>

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(1): 99.

RONNEBERGER, O., FISCHER, P., BROX, T. 2015. U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab, N., Hornegger, J., Wells, W., Frangi, A. (eds) *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. MICCAI 2015. Lecture Notes in Computer Science(), vol 9351. Springer, Cham.