

 **2025** | **16-20**  
GIJÓN | JUNIO  
**9º CONGRESO FORESTAL ESPAÑOL**

**9CFE-1746**

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

Organiza  **SECF**  
Sociedad Española  
de Ciencias Forestales



## Monitorización de parcelas a través de imágenes de satélite y escáner láser

JIMENEZ GONZALO, C. (1), GARCÍA MATEOS, A (1). CRESPO CADORNIGA, J. (2), CABO GOMEZ, C. (3), GARCÍA DE LA CRUZ LÓPEZ, J. (1), GARO HERNANDEZ, A. (2), ORDOÑEZ GALAN, C (3),

(1) Carbon2Nature

(2) Imageryst

(3) Universidad de Oviedo

### Resumen

La monitorización periódica de las masas forestales es esencial para la gestión forestal tanto desde la perspectiva ambiental como económica. Gestionar superficies forestales extensas implica recurrir a técnicas de detección remota, empleando imágenes de satélite y/o nubes de puntos obtenidas mediante escáneres láser aerotransportados. El objetivo de este proyecto es analizar la viabilidad de dichas técnicas para realizar inventarios forestales a gran escala y, posteriormente, estimar la biomasa y evaluar su capacidad de absorción de carbono.

En una primera fase se analizaron las posibilidades de cada una de las dos tecnologías de manera individual, habiéndose obtenido resultados muy positivos, aunque también se detectaron algunas limitaciones y aspectos en los que se debe continuar investigando.

En una segunda fase, aún por realizar, está previsto construir modelos de regresión cuya variable de respuesta sea la biomasa estimada a partir de las nubes de puntos 3D, mientras que las variables explicativas (índices de vegetación, reflectancia, etc.) serán las obtenidas a partir de imágenes de satélite. Este estudio ha demostrado que las imágenes de satélite y las nubes de puntos 3D de escáner láser móvil son herramientas viables para el inventario forestal y la estimación de biomasa. La identificación de especies mediante segmentación semántica ha mostrado alta precisión, y el escaneo láser ha permitido detectar árboles y estimar variables dasométricas con fiabilidad. Aunque existen limitaciones, como la dificultad en la discriminación de clases y la captura de datos en terrenos densos, la integración de ambas tecnologías promete mejorar la monitorización forestal y la gestión de proyectos de reforestación.

### Palabras

**clave**

Monitorización, imágenes de satélite, escáner láser, captura de carbono, biomasa.

### 1.

### Introducción

El inventario de grandes masas forestales es imprescindible para conocer la biomasa disponible en las mismas y de ahí su capacidad para capturar carbono. El inventario a gran escala no puede hacerse mediante métodos tradicionales basados en la toma directa de datos en campo debido a la gran cantidad de recursos humanos y al elevado coste económico que acarrearán. Por este motivo es necesario recurrir a técnicas de medida indirectas que utilizan imágenes y/o nubes de puntos 3D, que si bien en general no son tan exactas como las tradicionales, al realizar un balance entre exactitud y coste resultan claramente favorables (MASELLI AND CHIANUCCI, 2020).

Entre las técnicas de observación indirectas más utilizadas para el inventario forestal y la estimación de la biomasa a gran escala están las que utilizan imágenes



de satélite, gracias a su capacidad para discriminar zonas forestales cubriendo grandes áreas de terreno y sin la necesidad de desplazar equipos al campo (ZARCO-TEJADA ET AL., 2014). Estas imágenes proporcionan información valiosa sobre la estructura y el estado de los ecosistemas forestales, permitiendo, en combinación con otras fuentes, una estimación aproximada de la biomasa, la identificación de especies y el monitoreo de cambios en la cobertura forestal (LEFSKY AND SKOWRONSKI, 2013). No obstante, tienen limitaciones importantes, entre ellas el hecho de proporcionar información en dos dimensiones que no permite estimar de forma directa variables que son importantes para el cálculo preciso de la biomasa (altura y volumen de las copas, vegetación arbustiva, etc.). Para suplir esa carencia se hace uso de las tecnologías basadas en LiDAR (LIGHT DETECTION AND RANGING) que utilizan pulsos láser para crear mapas tridimensionales precisos del dosel forestal (DANDOIS AND ELLIS, 2021). De cualquier manera, las estimaciones de biomasa mediante imágenes de satélite y nubes de puntos 3D se deben contrastar con medidas hechas en campo. Además, las medidas en campo, tomadas en un número limitado de parcelas, pueden ser utilizadas para estimar parámetros de modelos matemáticos de estimación de biomasa a partir de fuentes de datos remotas (LU ET AL., 2012). Los sistemas de medida en campo han evolucionado en el tiempo. Así, existen actualmente dendrómetros digitales que permiten medir continuamente el crecimiento de árboles individuales, sin necesidad de la presencia constante de un operador de campo (SMITH AND WEST, 2018). Una línea de investigación en auge es el uso de escáneres láser de mano, ligeros y económicos, que permite, con un software adecuado (LAINO ET AL., 2024), obtener medias muy exactas de variables como el diámetro de tronco a cualquier altura, la altura de copa, o también segmentar las nubes diferenciando entre matorral, tronco o copa (OVIEDO ET AL., 2024).

El uso de tecnologías remotas que se apoyen en imágenes de satélite y nubes de puntos, y su combinación con datos de campo se presenta como una solución prometedora para superar los desafíos de la monitorización de masas forestales a gran escala. Sin embargo, aunque cada una de estas herramientas posee aspectos muy positivos también tienen limitaciones que deben ser superadas mediante un enfoque integrador para generar resultados fiables y coherentes. De hecho, la integración de datos de múltiples fuentes que combinen las imágenes satelitales, LiDAR y mediciones en campo, constituye una de las líneas de investigación más prometedoras en el ámbito de la gestión forestal (TIAN ET AL., 2023). Este proyecto, realizado mediante una colaboración Empresa-Universidad, tiene como objetivo evaluar las diversas herramientas tecnológicas disponibles para el monitoreo, gestión y mantenimiento de proyectos de reforestación de manera remota, así como para la estimación de la biomasa y la captura de carbono. Mediante una prueba de concepto (PoC) se pretende identificar sus capacidades y sus límites, las posibles mejoras y los métodos de integración de estas tecnologías. En particular, el estudio se enfoca en el uso de imágenes satelitales de alta y media resolución, nubes de puntos 3D obtenidas con escáner láser móvil y dendrómetros digitales, combinando datos obtenidos remotamente con los datos recogidos directamente en campo. Los resultados obtenidos en la primera fase son muy prometedores, habiéndose establecido que la exactitud de las estimaciones realizadas por cada una de las técnicas es bastante alta.

## 2.

## Objetivos



Mediante esta PoC se busca evaluar la fiabilidad y exactitud de la información que se obtiene a partir de imágenes de satélite y nubes 3D de escáner láser terrestre móvil, así como el análisis de sus limitaciones y detección de puntos de mejora, con el fin último de evaluar la biomasa presente en grandes masas forestales, y de gestionar y mantener proyectos de reforestación optimizando los recursos disponibles. Concretamente, se quiere estudiar la aplicabilidad de estas tecnologías en las siguientes fases de un proyecto:

- Análisis técnico-forestal del potencial del proyecto.
- Monitorización de la evolución de captura de carbono de la masa forestal.
- Monitorización del estado fitosanitario y detección temprana de alteraciones sobre la masa.
- Gestión integral del proyecto en desarrollo y soporte para la mejora en la toma de decisiones.

Particularmente este PoC se centra en el análisis del estado la tecnología basada en el uso de imágenes satélite y escáner láser terrestre para el apoyo en la toma de decisiones y la monitorización de masas forestales. Las líneas principales de actuación planteadas son:

- Detección y clasificación del arbolado presente de forma remota.
- Monitorización del crecimiento de la biomasa forestal empleando de forma conjunta metodología de campo y de satélite.

### 3. Metodología

#### 3.1 Adquisición de datos

Los trabajos realizados durante el desarrollo de este proyecto pueden diferenciarse en dos bloques: (1) Segmentación semántica de parcelas a partir de imágenes por satélite y (2) Inventario forestal a nivel de parcela utilizando escáneres láser terrestres de mano. El primer bloque se llevó a cabo en un monte de 176 ha ubicado en el término municipal de Castropol, Asturias. El segundo bloque, si bien en un primer momento se planteó para llevarlo a cabo en este mismo monte, las condiciones del terreno no lo hicieron posible dado el difícil acceso y la densidad de sotobosque presente, detectando así una primera barrera en el uso de esta tecnología. Por ello, el inventario forestal realizado con láser terrestre de mano se llevó a cabo en 6 parcelas ubicadas en un monte público del concejo de Tineo. Una de las primeras problemáticas a la que nos enfrentamos fue la falta de información oficial generada por entidades públicas o gubernamentales necesaria como punto de partida para llevar a cabo el entrenamiento de los modelos de segmentación semántica. Se revisaron diferentes fuentes oficiales y se vio que la precisión de los datos no era buena, estaba desactualizada o no se correspondía con la realidad. Finalmente, se optó por confeccionar el conjuntos de datos a mano utilizando una combinación entre un visor web “Forest Explorer”, Google Street View e imagen de satélite. Contrastando los datos proporcionados por dicho visor y Google Street View, se pudo identificar si la parcela a utilizarla como datos de entrenamiento era correcta. Una vez perfilado el modelo, se utilizó para etiquetar y obtener así más muestras, siguiendo una metodología “*Teacher-Student*”. Sea analizaron diversos proveedores de imágenes y la resolución que proporcionaban. Con resoluciones a partir de 10 m se pudieron encontrar:

- Imágenes ópticas de media resolución (MR): Con tamaños de píxel entre 5 y 30

metros. A partir de 10x10 metros de tamaño de píxel ya se encuentran imágenes gratuitas como Sentinel-2 y Landsat.

- Imágenes ópticas de alta resolución (HR): Con tamaños de píxel entre 1 y 5 metros. Son imágenes de pago.

Se utilizaron imágenes de diferentes épocas del año para la misma zona de estudio con el fin de analizar los estados fenológicos de las especies. En lo que respecta a las nubes de puntos 3D, se obtuvieron utilizando escáner láser móvil de bajo coste *MandEye*. Este dispositivo está diseñado para capturar datos tridimensionales del entorno mediante la tecnología de *Simultaneous Localization and Mapping* (SLAM). Combina sensores láser con unidades de medición inercial (IMU) para rastrear la posición y orientación del dispositivo mientras el operador se desplaza por el entorno. El resultado son nubes de puntos tridimensionales que representan fielmente la geometría del área escaneada. El operador sostiene el escáner con unas y se mueve de manera libre por la parcela, capturando datos a medida que avanza. Los algoritmos de SLAM integrados en el dispositivo procesan los datos, permitiendo el registro de los puntos en un único sistema de referencia. Para facilitar el registro de los escaneos y georreferenciar las nubes de puntos en un sistema de referencia absoluto (UTM ETRS89, huso 29) se utilizaron esferas a las que se dieron coordenadas con un receptor GNSS (*Global navigation system*) diferencial. En total se colocaron 25 esferas reflectantes visibles. La figura 1 muestra fotografías tomadas en dos de estas parcelas. En las cinco primeras hay una mezcla de castaño, pino y roble, mientras que en la sexta hay también una zona con abedules.



Figura 1. Fotografías tomadas en dos de las seis parcelas en las que se realizaron los escaneos.

**3.2 Preprocesamiento de los datos**

Con las diferentes bandas de las imágenes de satélite se construyeron varios índices de vegetación (EVI, NDVI, SAVI), que se utilizaron como variables de entrada, junto con la reflectividad de las imágenes, para construir modelos de



segmentación semántica. Para entrenar estos modelos fue necesario asignar a cada píxel una etiqueta. Es importante tener en cuenta que la resolución de las imágenes influye en los resultados de los modelos, por lo que se probaron imágenes de diferentes resoluciones. La estación del año en la que se capturan las imágenes es también una variable que afecta a resultados de la segmentación, y por ello por lo que se utilizaron en entrenamiento de los modelos imágenes de cada estación del año. La nubosidad y la posición del sol fueron otras de las variables que se tuvieron en cuenta a la hora de entrenar los modelos. Las clases a identificar inicialmente eran numerosas, y a veces con poca distinción entre unas y otras. Por ejemplo, se hizo difícil distinguir entre dos especies de pino o entre cultivos de eucaliptos de otras especies de cultivo. Debido a que la precisión de las imágenes de satélite no llega a obtener información suficiente para una correcta distinción entre especies, se agruparon algunas de con características similares. Se realizan diferentes pruebas para determinar el comportamiento de los algoritmos dependiendo de la agrupación de las diferentes clases contempladas y las bandas e índices se utilizados. En lo que respecta a las nubes de puntos, una vez alienadas y georeferenciadas, se procedió a eliminar ruido y *outliers* que pudieran afectar a la posterior estimación de variables dasométricas.

### 3.3 Procesamiento de los datos

Las imágenes preprocesadas, con las respectivas etiquetas asignadas a cada píxel, se dividieron en muestra de entrenamiento y test, en una proporción de 80% a 20%, respectivamente. Para realizar la segmentación semántica se probaron tres clasificadores ampliamente conocidos: *Naive Bayes*, *Random Forest* y *Support Vector Machine* (SVM) (MOHAMMADPOUR, 2023). Se hicieron ensayos con algunas o todas las bandas, y con uno, dos, tres o ningún índice de vegetación. También se ejecutaron los algoritmos con diferentes número de especies, con el fin de ver cuántas se podían discriminar con una exactitud admisible. En los resultados sólo se muestran los obtenidos con SVM, al ser el clasificador que proporcionó mayores tasas de acierto. En cuanto a las nubes de puntos 3D, se procesaron con el software 3Dfin (LAINO ET AL., 2024) que permite diferenciar árboles individuales y hacer estimaciones de altura de copa, DBH y diámetro de tronco a cualquier altura sobre el terreno. El procesamiento básico no exige intervención alguna por parte del usuario, más allá de cargar las nubes de puntos y ejecutar el programa, si bien el software permite hacer modificando de algunos parámetros para los usuarios más especializados.

## 4. Resultados

### 4.1 Identificación de especies a partir de imágenes de satélite

La Figura 2 muestra el resultado de realizar la segmentación semántica mediante SVM cuando se utilizan todas las bandas y los tres índices de vegetación. Se incluye también la matriz de confusión y el índice kappa como métrica para evaluar cuán buena es la clasificación utilizando un único estadístico. Como se puede ver, los resultados obtenidos son buenos, especialmente a la hora de distinguir algunas eucaliptos, cultivos herbáceos y pastos.

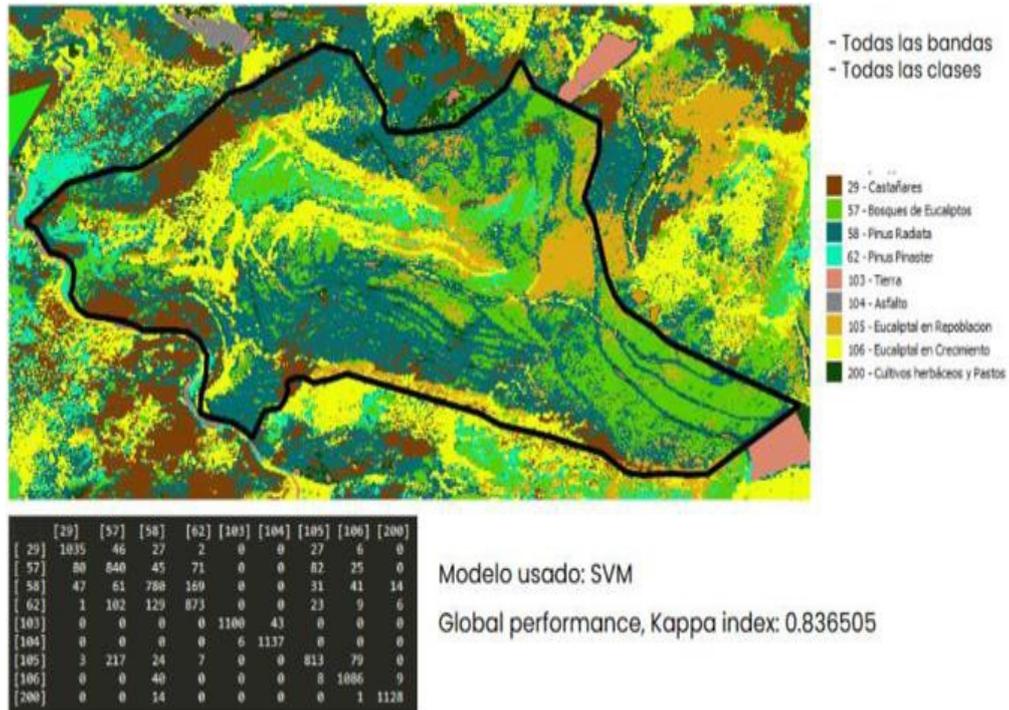


Figura 2. Resultado de la segmentación semántica con SVM sobre la muestra de test. Las variables de entradas son las bandas del satélite y los índices de vegetación NDVI, EVI y SAVI.

El acierto sobre los datos de validación empeora alrededor de un 10% cuando se utilizan únicamente los índices para realizar las predicciones. Los resultados mejoran ligeramente cuando se agrupan las clases de *Pinus radiata* y *Pinus pinaster*, siendo Kappa = 0,87. Como se observaron errores en la predicción con las clases Bosques de Eucaliptos (57) y Eucaliptos en Repoblación (105), se decidió agruparlas en una única clase, reduciéndose así los errores en la matriz de confusión y aumentando el índice Kappa hasta 0,91 (Figura 3).

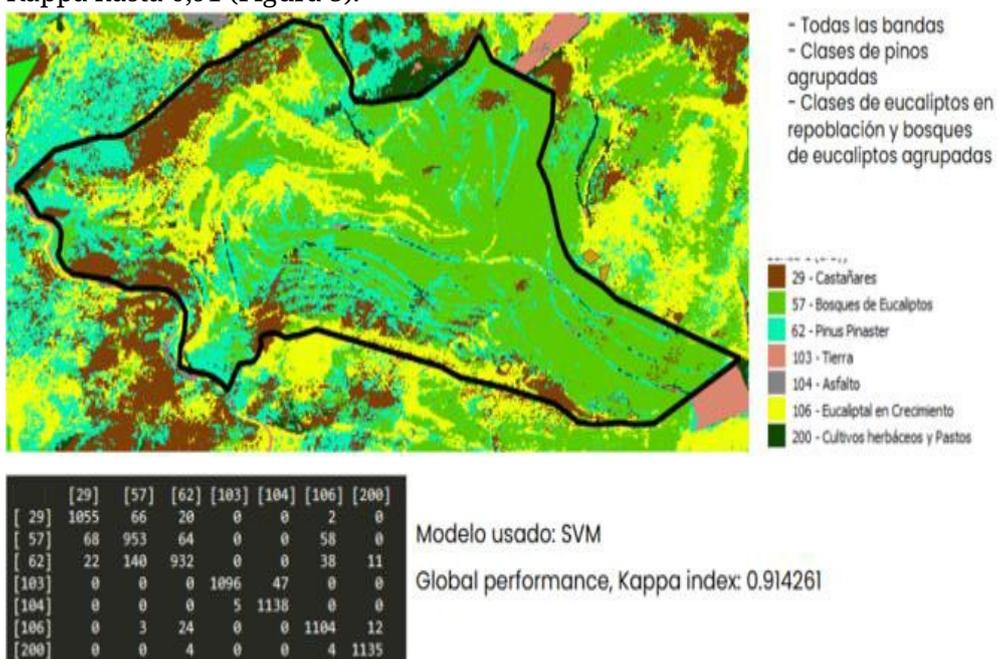


Figura 3. Resultado de agrupar en una única clase los bosques de eucaliptos y los eucaliptos en repoblación.

En la figura 4 se representa un mapa con diferentes especies obtenido a partir de trabajo en campo y el correspondiente mapa obtenido mediante segmentación semántica de las imágenes de satélite. El modelo muestra una buena precisión general, especialmente en la clasificación de las clases "Eucaliptos" y "Pinos". Las predicciones de "Pinos" coinciden de manera precisa en la zona central, donde los polígonos de estas clases están bien representados. Sin embargo, también se observan predicciones de pinos en polígonos adyacentes que corresponden a áreas fuera de la clase original, lo que sugiere un pequeño desajuste en la segmentación.

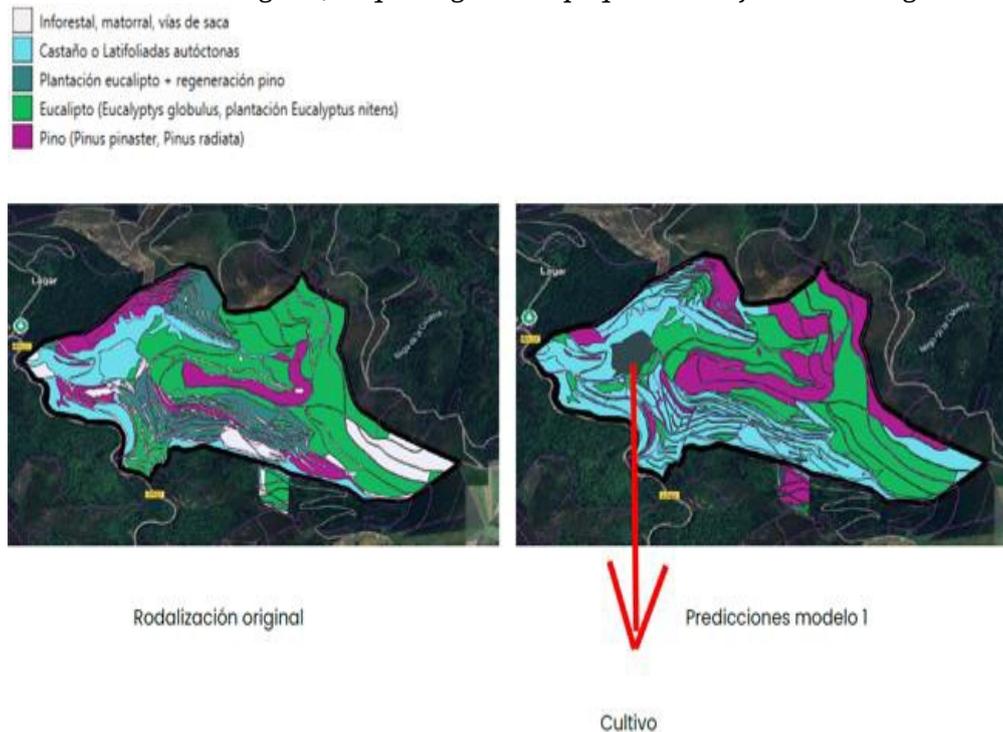


Figura 4. Rodalización procedente de trabajo de campo (izquierda) y del procesamiento de la imágenes de satélite (derecha).

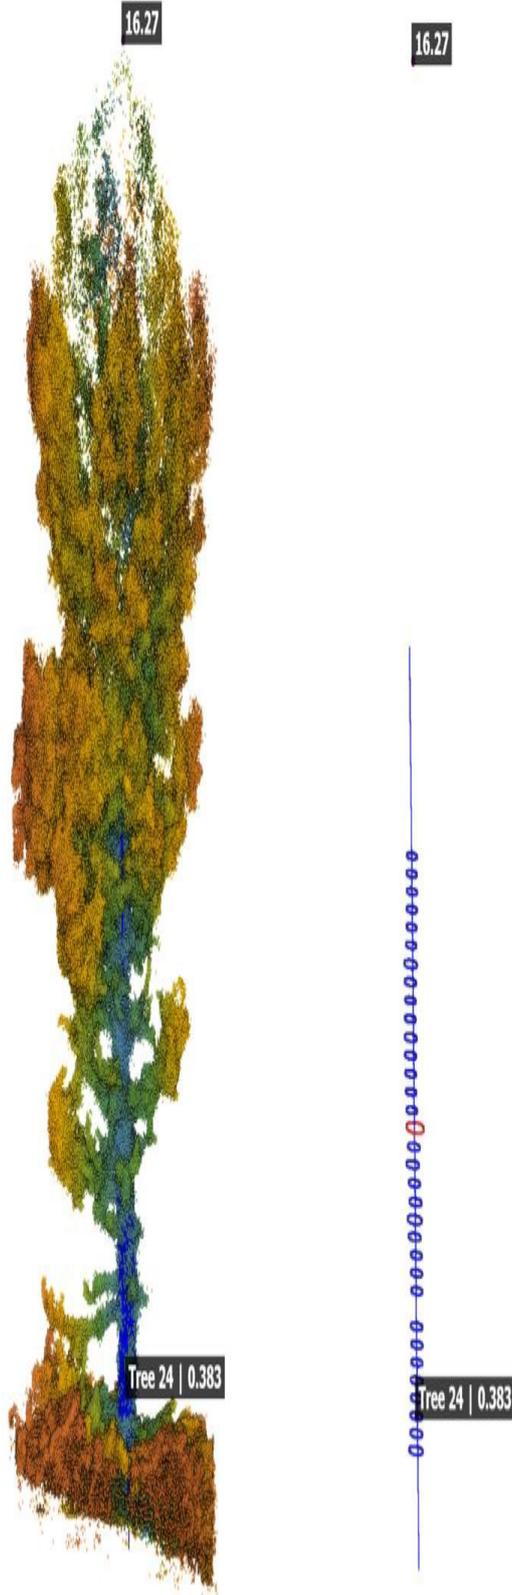
#### 4.2 Identificación de árboles individuales y estimación de variables dasométricas a partir de nubes de puntos 3D.

Tras procesar los resultados se discretizó cada árbol, y en cada uno de ellos se estimó el DBH, la altura y los diámetros del tronco a diferentes alturas. La mayoría de las medidas de diámetro y altura se clasificaron como fiables. Las medidas no fiables suelen estar asociadas a:

- Oclusiones: Zonas donde el escáner no pudo capturar datos debido a obstáculos o densidad excesiva de vegetación.
- Ruido en los Datos: Puntos aislados o erróneos que pueden afectar la estimación de las secciones.
- Geometrías Complejas: Árboles con formas irregulares o bifurcaciones cerca del suelo.

La figura 4 muestra los resultados obtenidos aplicando 3DFin a un árbol concreto.

Parámetros árbol			UTM ETRS89 H29	
unidades: m	TH	DBH	X	Y
T24	16,9905849	0,169279	703551,707	4794935,46



Parámetros secciones				
	UTM ETRS89 H29		unidades: m	
Altura	X	Y	T21	Fiable?
0,3	703551,7208	4794935,466	0,408795	no
0,5	703551,721	4794935,467	0,449155	sí
0,7	703551,7111	4794935,465	0,448396	sí
0,9	703551,7154	4794935,444	0,42583	sí
1,1	703551,7336	4794935,458	0,418395	sí
1,3	703551,7068	4794935,457	0,410747	sí
1,5	703551,5732	4794935,378	0,409675	sí
1,7	703551,7256	4794935,445	0,402508	sí
1,9	703551,7302	4794935,444	0,403361	sí
2,1	703551,7044	4794935,436	0,422592	no
2,3	703551,734	4794935,423	0,41982	sí
2,5	703551,7749	4794935,434	0,395436	sí
2,7	703552,1535	4794935,821	0,379524	sí
2,9	703551,1647	4794934,983	0,375225	sí
3,1	703551,7536	4794935,379	0,376216	sí
3,3	703551,5836	4794935,474	0,380153	sí
3,5	703551,798	4794935,412	0,407931	sí
3,7	703551,7877	4794935,416	0,408655	sí
3,9	703551,7727	4794935,414	0,369571	sí
4,1	703551,7785	4794935,409	0,361915	no
4,3	703551,7844	4794935,431	0,355798	sí
4,5	703551,7573	4794935,401	0,392153	sí
4,7	703551,7333	4794935,379	0,360665	sí
4,9	703551,574	4794934,938	0,367106	sí
5,1	703551,7224	4794935,371	0,346077	sí
5,3	703551,6975	4794935,331	0,344387	sí
5,5	703551,8208	4794934,997	0,346026	sí
5,7	703551,7207	4794935,048	0,358818	sí
5,9	703551,4609	4794934,871	0,340927	sí
6,1	703087,8362	4794049,564	0,34155	sí
6,3	703551,6914	4794935,326	0,319913	sí
6,5	703551,6675	4794935,301	0,324376	sí
6,7	703551,6174	4794935,286	0,362023	sí
6,9	703553,8204	4794936,846	0,3811	sí
7,1	703553,8568	4794936,801	0,339682	sí



Figura 5. Reconstrucción de un árbol a partir de la nube de puntos 3D y estimaciones del DBH, altura de copa (TH) y diámetro del tronco a diferentes alturas sobre el suelo.

La figura 5 muestra la nube de puntos de una parcela y otra salida del software 3DFin, en la que se ven los ejes del tronco de cada árbol y las alturas de copa.

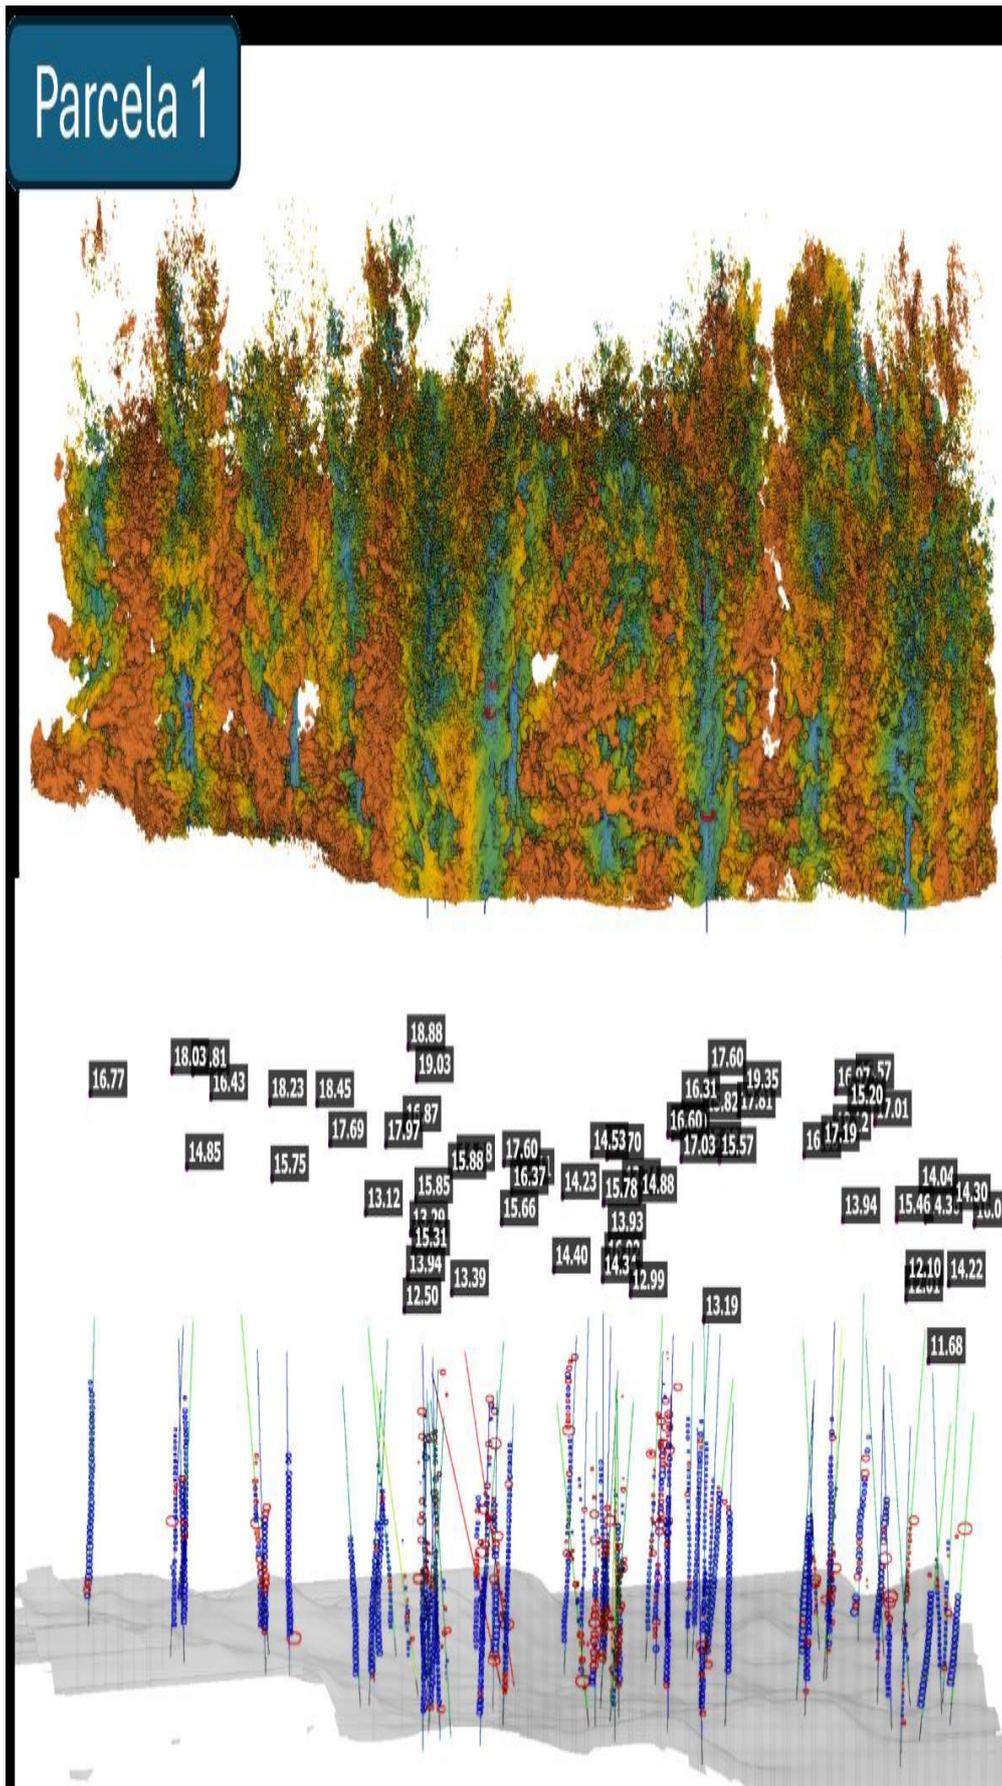


Figura 6. Nube de puntos obtenida con el escáner de mano y salida gráfica del

software 3DFin en la que se aprecian los ejes de los árboles y el modelo de elevaciones a cotar cero que permite estimar la altura de copa.

#### 4.

#### Resultados

En la tabla 1 se resume la información obtenida en cada parcela, con indicación de su extensión, el número de árboles detectados, los puntos de la nube 3D y valores del DBH y la altura de copa medios.

Tabla 1. Datos de cada parcela y valores medios resultantes del procesamiento de las nubes de puntos.

Parcela	Superficie (m <sup>2</sup> )	Nº de árboles	Nº puntos escaneados (millones)	DBH medio (cm)	Altura media (m)
1	1.700	65	65	30	15,6
2	1.900	54	42	26	14,6
3	2.000	61	67	32	21,1
4	1.950	52	41	31	15,6
5	2.200	59	45	33	16,3
6	2.050	95	47	24	12

#### 5.

#### Discusión

En líneas generales los resultados obtenidos en esta PoC han sido positivos y prometedores, habiéndose conseguido altas tasas de acierto en la identificación de especies a partir de imágenes de satélite, y también en la detección de árboles y en la estimación de algunas variables dasométricas a partir de los datos obtenidos con el escáner láser móvil. En lo que respecta a los problemas y limitaciones de las técnicas ensayadas, podemos decir que una de las principales limitaciones identificadas en el uso de imágenes de satélite es la falta de coincidencia exacta entre algunas clases originales y las clases predichas por el modelo. En particular, la clase "Cultivos", que aparece en las predicciones no tiene un equivalente directo en la rodalización original. La ausencia de clases específicas como "Vías de saca" o "Inforestal" en el conjunto de entrenamiento afecta la capacidad del modelo para representar correctamente esas áreas. La inclusión de estas clases podría mejorar sustancialmente la precisión y la utilidad del modelo en aplicaciones futuras, permitiendo una clasificación más completa y detallada. Se observa una mayor diferenciación entre las zonas de plantación o crecimiento cuando se introducen más clases en el conjunto de datos de entrenamiento. Este aumento en la granularidad de las clases permite una segmentación más precisa de las áreas de repoblación y de crecimiento, lo que facilita la identificación y clasificación de áreas específicas dentro del área de interés. En cuanto al uso del escáner láser para detectar árboles y estimar variables dasométricas, comparado con los métodos tradicionales, se reduce mucho el tiempo de trabajo, se eliminan errores groseros y se puede obtener muchas más información, que es además muy visual. En una jornada de trabajo se midieron en campo seis parcelas, con una extensión total de algo más de una ha, mientras que el posterior tratamiento de las nubes de puntos es muy sencillo y rápido. No obstante, uno de los problemas detectados es la dificultad e incluso la imposibilidad de hacer mediciones en algunas parcelas por tener demasiado matorral, si bien este problema es común a los métodos de campo tradicionales. Por otro lado, aunque trabajos anteriores han demostrado que las estimaciones realizadas con estos métodos son aceptables para un inventario forestal, en este



trabajo no se contrataron con medidas realizadas por métodos directos tradicionales.

## 6.

### Conclusiones

Los estudios realizados en esta prueba de concepto han permitido establecer unas primeras conclusiones acerca de la viabilidad del uso de imágenes de satélite y de las nubes de puntos tomada con escáneres láser 3D para el inventario forestal como paso previo a la estimación de la biomasa y de la captura de carbono en grandes masas forestales. Los modelos de machine learning para identificar especies a partir de imágenes de satélite han resultado ser bastante exactos, si bien es necesario seguir profundizando en la investigación para tratar de paliar algunos de los problemas detectados. Con algunas mejoras en el conjunto de datos de entrenamiento y una integración más precisa de las predicciones a nivel de píxel se podría obtener un modelo más robusto y adaptado a necesidades más específicas. En cuanto al uso de escáneres láser móviles, el trabajo realizado ha permitido establecer las ventajas de este método con respecto a los tradicionales. A pesar de algunas limitaciones, las ventajas en términos de eficiencia, coste y accesibilidad tecnológica hacen de esta metodología una opción atractiva para la gestión y estudio de bosques a nivel de parcela. Está previsto continuar este proyecto integrando ambas tecnologías, en la línea de construir modelos estadísticos de estimación de la biomasa en grandes áreas de bosque a partir de imágenes de satélite, utilizando como variable de respuesta las estimaciones de la biomasa a nivel de parcela procedentes de procesar nubes de puntos 3D de escáner láser móviles. De esta manera se pretende aprovechar los puntos fuertes de cada tecnología, reduciendo a la vez sus limitaciones.

## 7.

### Agradecimientos

Expresar nuestro sincero agradecimiento a todas las personas e instituciones que han hecho posible el desarrollo de este proyecto. En primer lugar, agradecer al equipo de Perseo Iberdrola, que han hecho posible esta sinergia, apostando por un crecimiento innovador y una colaboración interdisciplinaria. Nuestro más profundo reconocimiento a Imageryst, como empresa pionera especializada en soluciones tecnológicas basadas en inteligencia artificial aplicada a sensorica remota. A la Universidad de Oviedo, por su valiosa contribución y su experiencia en el ámbito forestal. Agradecer también a todo el equipo de Carbon2Nature por su búsqueda continua de mejora y aprendizaje.

## 8.

### Bibliografía

Dandois, J. P.; Ellis, E. C. (2021). Advancements in LiDAR technology for forest inventory and biomass estimation. *Forest Ecology and Management*, 483, 118842.  
 Laino, D.; Cabo, C.; Prendes, C.; Janvier, R.; Ordonez, C.; Nikonovas, T.; Doerr, S.; Santin, C. (2024). 3DFin: a software for automated 3D forest inventories from terrestrial point clouds, *Forestry: An International Journal of Forest Research*, Volume 97, 4, 479–496  
 Lefsky, M. A.; Skowronski, N. S. (2013). LiDAR remote sensing of forest biomass: A comparison of lidar methods for estimating forest biomass. *Remote Sensing of Environment*, 154, 1-10.  
 Lu, D.; Chen, Q.; Wang, G.; Moran, E.; Batistella, M.; Zhang, M.; Laurin, G.; Saah, D. (2012). Aboveground Forest Biomass Estimation with Landsat and LiDAR Data and Uncertainty Analysis of the Estimates. <https://doi.org/10.1155/2012/436537>



- Maselli, F.; Chianucci, F. (2020). Remote sensing in forestry: A comprehensive review of the recent literature. *Remote Sensing*, 12(8), 1313.
- Mohammadpour, P.; Viegas, DX; Viegas, C. (2022) Vegetation Mapping with Random Forest Using Sentinel 2 and GLCM Texture Feature—A Case Study for Lousã Region, Portugal. *Remote Sensing*. 14(18):4585.
- Oviedo de la Fuente, M.; Cabo, C.; Roca-Pardiñas, J.; Loudermilk, E.L.; Ordóñez, C. (2024). 3D Point Cloud Semantic Segmentation Through Functional Data Analysis. *JABES* 29, 723–744.
- Smith, W. B.; West, P. W. (2018). Use of digital dendrometers for continuous monitoring of forest growth. *Forest Science*, 64(2), 171-179.
- Tian, L.; Wu, X.; Tao, Y.; Li, M.; Qian, C.; Liao, L.; Fu, W. (2023). Review of Remote Sensing-Based Methods for Forest Aboveground Biomass Estimation: Progress, Challenges, and Prospects. *Forests*, 14, 1086.
- Zarco-Tejada; P. J., Berjón; A.; González-Dugo, M. P. (2014). Forest biomass and productivity estimation in Mediterranean ecosystems using remote sensing data. *Remote Sensing of Environment*, 155, 63-77.