



**2025** | **16-20**  
GIJÓN | JUNIO

**9º CONGRESO FORESTAL ESPAÑOL**

# 9CFE-2042

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

Organiza





## Nubes de puntos terrestres segmentadas para entrenar modelos de Inteligencia Artificial en parcelas forestales

LAÍÑO REBOLLIDO, D. (1), CABO GÓMEZ, C. (2), ORDÓÑEZ GALÁN, C. (2), BOLAÑOS CHAMORRO, R. (1), PARSONS, R. (3), HUDAK, A. (4), HERRMANN, M. (5), GIULIONI, F. (6), PÉREZ VALLEJO, M. (1), SANTÍN NUÑO, C. (1)

(1) Instituto Mixto de Investigación en Biodiversidad (IMIB), CSIC-Universidad de Oviedo-Principado de Asturias, Mieres, España.

(2) Departamento de Explotación y Prospección de Minas, Área de Ingeniería Cartográfica, Geodésica y Fotogrametría, Universidad de Oviedo, Mieres, España.

(3) US Forest Service, Fire Sciences Laboratory, Missoula, Estados Unidos.

(4) US Forest Service, Rocky Mountain Research Station, Moscow, Estados Unidos.

(5) Institute of Geographical Sciences, Freie Universität Berlin, Berlín, Alemania.

(6) Department of Agricultural, Food and Environmental Sciences, Università Politecnica delle Marche, Ancona, Italia.

### Resumen

La aplicación de la inteligencia artificial a nubes de puntos terrestres ha abierto nuevas vías para la obtención de información detallada sobre la estructura de masas forestales. Más concretamente, la segmentación semántica, esto es, clasificar cada punto en una categoría (por ejemplo, terreno, sotobosque, tronco, rama) ofrece un gran potencial de automatización y mejora del monitoreo y gestión forestal. Sin embargo, un requisito global para todos los modelos de segmentación semántica es la de poseer abundantes datos de entrenamiento de calidad y, actualmente, existe una gran carencia de datos públicos de este tipo. Presentamos aquí un conjunto de 14 nubes de puntos terrestres obtenidas en diversos tipos de masas forestales y localizaciones y que han sido manualmente segmentadas en diferentes clases (“terreno”, “sotobosque”, “tronco”, “ramaje” y “otros elementos”). En total, el dataset abarca más de dos hectáreas de bosques y plantaciones en cuatro países e incluye cerca de mil millones de puntos. Su finalidad es la de facilitar el desarrollo de modelos de segmentación semántica de parcelas forestales y avanzar así el análisis de la estructura forestal.

### Palabras clave

Aprendizaje profundo, lidar, lidar móvil, lidar terrestre, teledetección

#### 1. Introducción

Las tecnologías de LiDAR terrestre, como el escaneo láser terrestre (TLS) o el escaneo móvil terrestre (MLS), son herramientas frecuentemente utilizadas para la generación de modelos tridimensionales (3D) de objetos físicos. Estas tecnologías generan nubes de puntos 3D que capturan la distribución espacial de los elementos con una gran precisión (CALDERS *et al.*, 2020). En el contexto forestal, la disponibilidad de datos detallados provenientes de escaneos terrestres y móviles ha generado nuevas oportunidades para comprender la estructura de los ecosistemas forestales (CALDERS *et al.*, 2020). Además de parámetros básicos de inventario forestal (Ej. diámetro, altura y posición de los árboles) (LIANG *et al.*,



2018; KRISANSKI *et al.*, 2021; LAINO *et al.*, 2024), las nubes de puntos terrestres permiten derivar descriptores cuantitativos más complejos de la estructura forestal. Existen así algoritmos para computar a partir de este tipo de datos el volumen maderable de los troncos (PULETTI *et al.*, 2019; HYYPPÄ *et al.*, 2020; ALVITES *et al.*, 2021; PRENDES *et al.*, 2021), características del dosel (CHIANUCCI *et al.*, 2020; SCHRAIK *et al.*, 2021) o la composición del sotobosque (ALONSO-REGO *et al.*, 2020; TIAN *et al.*, 2023). A través de las nubes de puntos 3D se puede, por tanto, caracterizar la estructura de las masas forestales de una manera mucho más rápida, precisa y pormenorizada de lo que era posible en campo. Esto es posible gracias a que, en las nubes de puntos se determina con precisión la posición espacial de cada elemento. Esto permite, potencialmente, establecer relaciones espaciales entre los diferentes elementos y, a partir de ellas, resolver la estructura forestal.

Es en este contexto donde entra la Inteligencia Artificial y el Aprendizaje Profundo (AP) por medio de redes neuronales. Las redes neuronales modernas son capaces de aprender representaciones jerárquicas de las nubes 3D a partir de la información posicional contenida en los puntos (QI *et al.*, 2017; GUO *et al.*, 2020; ENGEL *et al.*, 2021; ZHAO *et al.*, 2021; ROBERT *et al.*, 2023). A partir de estas representaciones jerárquicas, son capaces de relacionar unos puntos con otros en base a su posición en el espacio y, tras ello, clasificarlos en diferentes categorías (por ejemplo, en el caso que nos ocupa, clasificar los puntos en “tronco”, “rama”, “sotobosque”, “terreno” ...). A este proceso se le denomina segmentación semántica de la nube de puntos.

El proceso de asignar una clase específica a cada punto de la nube permite descomponer las nubes de puntos forestales en componentes estructurales específicos e interpretables. Esta técnica tiene el potencial de transformar y automatizar significativamente la gestión forestal, permitiendo análisis más precisos y eficientes (LINES *et al.*, 2022a; KAIJALUOTO *et al.*, 2022).

Sin embargo, para desarrollar métodos basados en AP es requisito indispensable disponer de conjuntos de datos masivos, diversos y de alta calidad (MA *et al.*, 2023). A pesar del enorme potencial para la gestión forestal de la segmentación semántica de nubes de puntos a través de AP, no existen prácticamente conjuntos de datos públicos para este propósito (LINES *et al.*, 2022b; KULICKI *et al.*, 2024). Existe, no obstante, un conjunto de datos público segmentado manualmente a partir de datos LiDAR obtenidos mediante UAV, presentado por PULITI *et al.* (2023), que incluye una clasificación detallada en siete clases semánticas: “terreno”, “vegetación baja”, “tronco”, “ramas vivas”, “ramas muertas”, “puntos fuera de la parcela” y “otros”. Aunque representa un avance relevante, al estar basado en observaciones aéreas, presenta limitaciones para capturar con precisión la estructura interna del bosque, especialmente en ambientes de denso sotobosque o con copas cerradas. Actualmente y a nuestro conocimiento, el único conjunto de datos público dedicado específicamente a la segmentación semántica de nubes de puntos terrestres es el presentado por CHENG *et al.* (2023), que incluye nubes MLS de parcelas forestales y plantaciones de frutales en Estados Unidos. Sin embargo, este conjunto de datos ofrece una categorización limitada de los puntos, clasificando



solo en “tronco”, “suelo” y “otros elementos”. Para una determinación más completa de la estructura forestal, es necesario ir un paso más allá y clasificar los puntos en un espectro más amplio de categorías (p.e., separar el dosel del sotobosque).

## 2. Objetivos

Dada la escasez actual de datasets públicos para desarrollar modelos de segmentación semántica en el contexto de nubes de puntos terrestres de masas forestales, así como su importancia para diversas aplicaciones forestales, nuestro objetivo es proporcionar el primer conjunto de datos público extenso para el desarrollo de modelos de segmentación semántica basados en AP. Al ofrecer este recurso, pretendemos fomentar la innovación en el desarrollo de nuevos métodos que requieran este tipo de datos, así la estandarización y la colaboración en el análisis de nubes de puntos 3D, permitiendo a los investigadores desarrollar, probar y comparar métodos en diversos entornos forestales.

## 3. Metodología

El nuevo conjunto de datos incluye 14 nubes de puntos adquiridas utilizando tanto MLS como TLS durante diferentes campañas de muestreo realizadas entre 2017 y 2022 en España, Austria, Escocia y Estados Unidos. En total, el conjunto de datos está compuesto por cerca de mil millones de puntos.

Las nubes de puntos MLS (6 de las 14) fueron escaneadas con un GeoSLAM ZEB Horizon (GeoSLAM, 2023). El GeoSLAM ZEB Horizon tiene un alcance de 100 m, un campo de visión (FOV) de  $360^\circ \times 270^\circ$ , y puede capturar 300.000 puntos por segundo con una precisión relativa de hasta 6 milímetros.

Parcelas escanadas con MLS:

- MLS-01: *Pinus pinaster* en Cáceres, España
- MLS-02: *Fagus sylvatica* en Asturias, España
- MLS-03: *Quercus robur* en Escocia, Reino Unido
- MLS-04: *Quercus pyrenaica* en Cantabria, España
- MLS-05: *Pinus radiata* (plantación) en Cantabria, España
- MLS-06: *Eucalyptus globulus* (plantación) en Cantabria, España

Las otras 8 parcelas se escanearon utilizando escaneo láser terrestre (TLS) multiposicional. Dos parcelas fueron escaneadas utilizando un escáner Riegl VZ-2000i TLS (RIEGL Laser Measurement Systems GmbH, 2023a). El Riegl VZ-2000i ofrece un campo de visión de  $100^\circ \times 360^\circ$ , captura hasta 500.000 puntos por segundo, tiene una precisión relativa de hasta 5 milímetros y un alcance de hasta 2.500 metros. El resto de nubes TLS (6) fueron adquiridas utilizando un dispositivo TLS Riegl VZ-400i (Riegl Laser Measurement Systems GmbH, 2023b). El Riegl VZ-400i tiene especificaciones similares al Riegl VZ-2000i, pero un alcance más reducido, de hasta 800 metros, y una mayor precisión relativa de hasta 3

milímetros. Los escaneos se realizaron variando el número de posiciones de escaneo en función de las características de la parcela.

#### Parcelas escaneadas con TLS:

- TLS-01: *Fagus sylvatica* en Viena, Austria
- TLS-02: *Fagus sylvatica* y *Fraxinus excelsior* en Viena, Austria
- TLS-03: *Picea abies* y *Fagus sylvatica* en Viena, Austria
- TLS-04: *Abies alba* y *Picea abies* en Viena, Austria
- TLS-05: *Picea abies* en Viena, Austria
- TLS-06: *Pinus palustris* (plantación) en Georgia, Estados Unidos
- TLS-07: *Pinus Ponderosa* en Oregón, Estados Unidos
- TLS-08: *Pinus ponderosa* en Oregón, Estados Unidos

El conjunto de datos incluye nubes de puntos de una amplia gama de tipos de masas forestales. En total, abarca más de 2 hectáreas de superficie arbolada, que incluyen tanto masas de frondosas, como de coníferas y mixtas. Incluye, a la vez, tanto plantaciones como bosques naturales, ofreciendo un amplio espectro de ecosistemas forestales. El conjunto de datos incorpora masas de diferentes grados de madurez, desde rodales maduros hasta jóvenes, pasando por formaciones con estratos de diferentes edades. Además, algunas parcelas presentan una densa vegetación de sotobosque, incluyendo arbustos, diseminados y brinzales, mientras que otras tienen un sotobosque más abierto, proporcionando una gama de complejidad estructural vertical. El conjunto de datos también incluye masas con distintos niveles de alteración, como parcelas con árboles caídos, madera muerta, cortafuegos y otras heterogeneidades estructurales.

Las parcelas varían en tamaño, abarcando entre 700 m<sup>2</sup> y 3600 m<sup>2</sup>. En la tabla 1 se puede encontrar un resumen cuantitativo de las características del conjunto de datos.

*Tabla 1. Características de las nubes de puntos MLS. Se muestran valores aproximados del número de puntos que contiene cada nube, así como el área que ocupa cada parcela escaneada, la densidad de pies, el área basimétrica y la especie principal.*

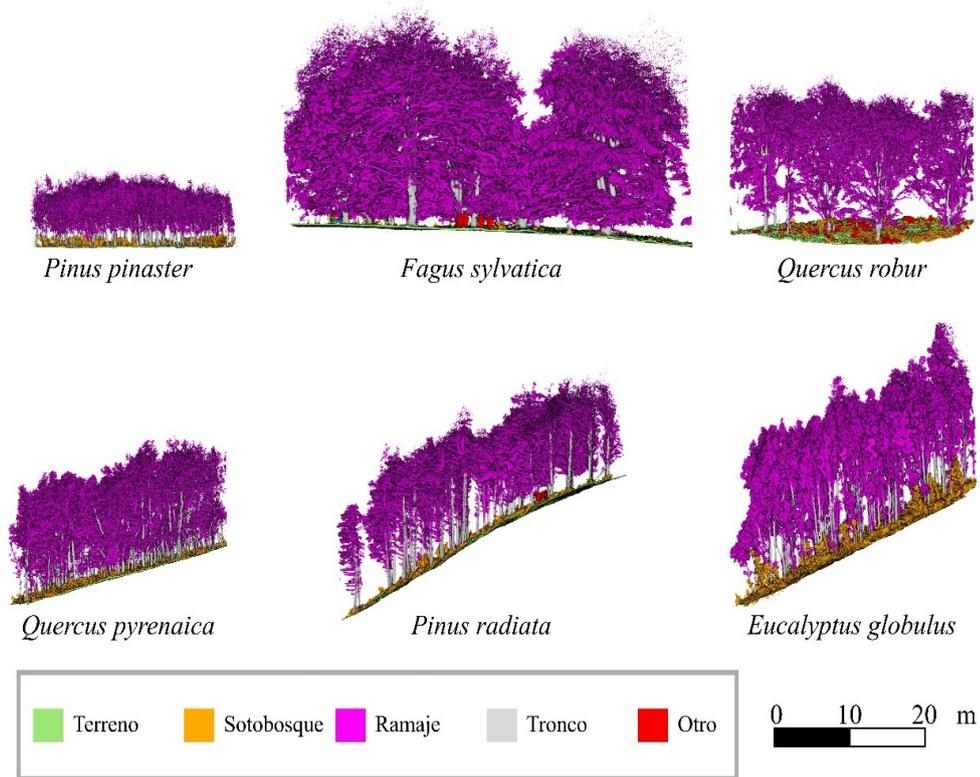
Parcela	Número de puntos (millones)	Área (ha)	Densidad (pies / ha)	Área basimétrica (m <sup>2</sup> / ha)	Especie principal
MLS-01	31	0,068	3620	43,71	<i>Pinus pinaster</i>
MLS-02	24	0,210	280	66,53	<i>Fagus sylvatica</i>
MLS-03	19	0,090	300	23,86	<i>Quercus robur</i>
MLS-04	21	0,065	3840	39,20	<i>Quercus pirenaica</i>
MLS-05	42	0,156	860	59,43	<i>Pinus radiata</i>

MLS-06	33	0,093	1620	18,57	<i>Eucalyptus globulus</i>		
TLS-01	77	0,130	530	24,99	<i>Fagus sylvatica</i>		
TLS-02	281	0,139	2030	38,65	<i>Fagus sylvatica</i>	y	<i>Fraxinus excelsior</i>
TLS-03	73	0,146	580	44,11	<i>Picea abies</i>	y	<i>Fagus sylvatica</i>
TLS-04	43	0,143	180	19,41	<i>Abies alba</i>	y	<i>Picea abies</i>
TLS-05	59	0,141	910	43,41	<i>Picea abies</i>		
TLS-06	95	0,249	330	15,94	<i>Pinus palustris</i>		
TLS-07	61	0,359	150	6,60	<i>Pinus ponderosa</i>		
TLS-08	65	0,323	90	7,00	<i>Pinus ponderosa</i>		

Las nubes de puntos fueron procesadas en el software libre CloudCompare (Girardeau-Montaut, 2024). Los puntos fueron clasificados a mano en las categorías “terreno”, “sotobosque”, “tronco”, “ramaje” y “otros”. La categoría “terreno” incluye tanto puntos del terreno como herbáceas de poco porte, la categoría “sotobosque” incluye matorral, madera muerta y árboles de poco porte (desde diseminado hasta latizal bajo, con diámetros menores a 10 centímetros), la categoría “tronco” incluye los troncos de los árboles con cierto porte (latizal alto a fustal, diámetros de más de 10 centímetros) y la categoría “ramaje” incluye las ramas y hojas de los árboles de cierto porte. El proceso de segmentación manual llevó aproximadamente unas 100 h por nube. Esta fue llevada a cabo por 6 operadores diferentes. Si bien se siguió un criterio común, todas las nubes fueron revisadas cuidadosamente por un único operador, para asegurar la consistencia del criterio a la hora de clasificar los puntos en las diferentes categorías.

#### 4. Resultados

El conjunto de datos estará disponible en el repositorio de datos del Consejo Superior de Investigaciones Científicas (CSIC) <https://digital.csic.es/>. Las nubes estarán almacenadas en archivos en formato PLY (Polygon File Format). Las clases asignadas a los puntos se encontrarán disponibles en un campo escalar denominado “Class”. Datos adicionales sobre el origen, preprocesamiento y postprocesamiento de las nubes de puntos se incluirán en un fichero de metadatos. La Figura 1 ilustra las parcelas escaneadas con MLS ya segmentadas manualmente, y la Figura 2 muestra las TLS.



*Figura 1. Parcelas escaneadas con MLS y la clasificación manual de estas. En general, las nubes MLS contienen más ruido que las TLS. Se puede apreciar visualmente las diferencias entre parcelas en el tamaño, pendiente del terreno, cobertura de arbustos, densidad del ramaje, la altura de los árboles y la densidad de troncos.*

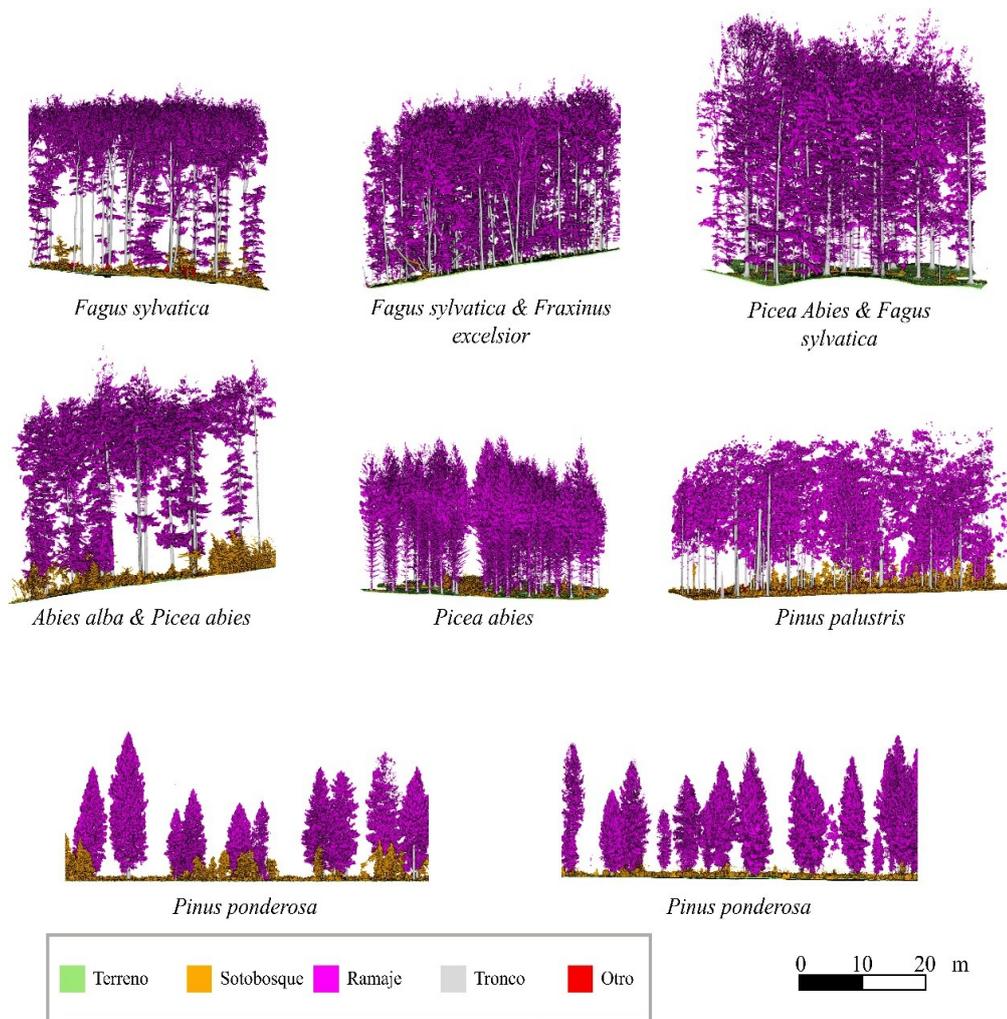


Figura 2. Parcelas escaneadas con TLS y la clasificación manual de estas. Se puede apreciar visualmente las diferencias entre parcelas en el tamaño, pendiente del terreno, cobertura de arbustos, densidad del ramaje, la altura de los árboles y la densidad de troncos.

## 5. Discusión

El conjunto de datos presentado aquí contiene 14 nubes de puntos terrestres segmentadas manualmente. Estas capturan diversas condiciones ecológicas, tipologías forestales y tecnologías de escaneado. Esta amplia cobertura ofrece un punto de referencia para desarrollar y evaluar modelos de aprendizaje profundo. La comparación con conjuntos de datos similares es difícil debido a la escasez de alternativas disponibles públicamente. La alternativa más directa es la presentada por CHENG et al. (2023), donde se proporcionan datos MLS anotados de 3,2 hectáreas de masas forestales y 46 hectáreas de plantaciones de pistachos y almendros en Estados Unidos. Aunque la superficie total cubierta es extensa, las categorías de este conjunto de datos son mínimas, ya que al único componente vegetal al que se asigna una etiqueta específica es a los troncos. A todos los demás puntos se clasifican como «terreno» u «otros elementos». Este etiquetado limitado restringe su uso para aplicaciones que requieren una comprensión detallada de las estructuras forestales.



También cabe destacar el conjunto de datos publicado por PULITI et al. (2023), que proporciona nubes LiDAR UAV segmentadas manualmente. Este conjunto incluye una mayor riqueza semántica —con clases como “vegetación baja”, “terreno”, “tronco”, “ramas vivas”, “ramas muertas”, “puntos fuera de la parcela” y “otros”—, y cubre una superficie total de 2,8 hectáreas distribuidas en 29 parcelas ubicadas en cinco países: Noruega (20 parcelas), República Checa (3), Austria (1), Australia (1) y Nueva Zelanda (4). Si bien representa un valioso recurso para el desarrollo de modelos de segmentación semántica, su naturaleza aérea (ULS) limita la capacidad de capturar con detalle la estructura interna del bosque, especialmente en áreas con copas densas o sotobosque desarrollado.

En cambio, el conjunto de datos que presentamos incluye nubes de puntos clasificadas de una superficie menor (2,3 hectáreas), pero abarca diversos países y múltiples condiciones ecológicas. Además, y lo que es más importante, nuestro conjunto de datos ofrece una mayor variedad de categorías. Estas dividen los componentes vegetales en sotobosque, tronco y copas, excluyendo los objetos de otra índole (vallas, rocas, estacas, gente, etc.) y el terreno. Este hecho hace al conjunto de datos presentado aquí especialmente adecuado para desarrollar y evaluar comparativamente modelos de segmentación semántica para aplicaciones más amplias en el seguimiento y la gestión de las masas forestales.

## 6. Conclusiones

El conjunto de datos que se presenta supone un avance significativo en el campo de la investigación de nubes de puntos forestales, ya que ofrece un recurso único para el desarrollo y la evaluación comparativa de modelos de AP de segmentación semántica. Con cerca de mil millones de puntos y cubriendo más de dos hectáreas de bosque, el conjunto de datos proporciona una base sólida para avanzar en los modelos de segmentación basados en aprendizaje profundo en silvicultura.

## 7. Agradecimientos

Este trabajo se ha financiado bajo el proyecto [NE/T001194/1]: ‘*Advancing 3D Fuel Mapping for Wildfire Behaviour and Risk Mitigation Modelling*’ del *Natural Environment Research Council* (NERC) de Reino Unido, el proyecto [PID2021-126790NB-I00]: ‘Nuevos métodos para estimaciones de emisiones de carbono en incendios mediante inteligencia artificial aplicada a nubes de puntos terrestres en 3D’ del Subprograma Estatal de Generación de Conocimiento de la Agencia Estatal de Investigación, y los proyectos RC20-1025 y RC20-1046 del *Strategic Environmental Research and Development Program* del Departamento de Defensa de Estados Unidos.

## 8. Bibliografía

ALONSO-REGO, C.; ARELLANO-PÉREZ, S.; CABO, C.; ORDÓÑEZ, C.; ÁLVAREZ-GONZÁLEZ, J. G.; DÍAZ-VARELA, R. A.; RUIZ-GONZÁLEZ, A. D.; 2020. Estimating fuel loads and structural characteristics of shrub communities by using terrestrial laser scanning. *Remote Sensing* 12(22) 1–21.



ALVITES, C.; SANTOPUOLI, G.; HOLLAUS, M.; PFEIFER, N.; MAESANO, M.; MORESI, F. V.; MARCHETTI, M.; LASSERRE, B.; 2021. Terrestrial laser scanning for quantifying timber assortments from standing trees in a mixed and multi-layered Mediterranean forest. *Remote Sensing* 13(21).

CALDERS, K.; ADAMS, J.; ARMSTON, J.; BARTHOLOMEUS, H.; BAUWENS, S.; BENTLEY, L. P.; CHAVE, J.; DANSON, F. M.; DEMOL, M.; DISNEY, M.; GAULTON, R.; KRISHNA MOORTHY, S. M.; LEVICK, S. R.; SAARINEN, N.; SCHAAF, C.; STOVALL, A.; TERRY, L.; WILKES, P.; VERBEECK, H.; 2020. Terrestrial laser scanning in forest ecology: Expanding the horizon. *Remote Sensing of Environment* 251 112102.

CHENG, D.; CLADERA OJEDA, F.; PRABHU, A.; LIU, X.; ZHU, A.; GREEN, P. C.; EHSANI, R.; CHAUDHARI, P.; KUMAR, V.; 2023. TreeScope: An agricultural robotics dataset for LiDAR-based mapping of trees in forests and orchards. *arXiv*.

CHIANUCCI, F.; PULETTI, N.; GROTTI, M.; FERRARA, C.; GIORCELLI, A.; COALOA, D.; TATTONI, C.; 2020. Nondestructive tree stem and crown volume allometry in hybrid poplar plantations derived from terrestrial laser scanning. *Forest Science* 66(6) 737–746.

ENGEL, N.; BELAGIANNIS, V.; DIETMAYER, K.; 2021. Point Transformer. *IEEE Access* 9 134826–134840.

GEOSLAM (A FARO Technologies, Inc. Company); 2023. Geoslam ZEB Horizon RT. Retrieved December 05, 2024, from: <https://geoslam.com/solutions/zeb-horizon-rt/>.

GIRARDEAU-MONTAUT, D.; 2024. CloudCompare (version 2.13.2) [Computer software]. Retrieved 08 August, 2024, from: <http://www.cloudcompare.org>.

GUO, M.-H.; CAI, J.; LIU, Z.-N.; MU, T.-J.; MARTIN, R. R.; HU, S.-M.; 2020. PCT: Point cloud transformer. *arXiv*.

HYYPÄ, E.; KUKKO, A.; KAIJALUOTO, R.; WHITE, J. C.; WULDER, M. A.; PYÖRÄLÄ, J.; LIANG, X.; YU, X.; WANG, Y.; KAARTINEN, H.; VIRTANEN, J.-P.; HYYPÄ, J.; 2020. Accurate derivation of stem curve and volume using backpack mobile laser scanning. *ISPRS Journal of Photogrammetry and Remote Sensing* 161 246–262.

KAIJALUOTO, R.; KUKKO, A.; EL ISSAOUI, A.; HYYPÄ, J.; KAARTINEN, H.; 2022. Semantic segmentation of point cloud data using raw laser scanner measurements and deep neural networks. *ISPRS Open Journal of Photogrammetry and Remote Sensing* 3 100011.

KRISANSKI, S.; TASKHIRI, M. S.; GONZALEZ ARACIL, S.; HERRIES, D.; TURNER, P.;



2021. Sensor Agnostic Semantic Segmentation of Structurally Diverse and Complex Forest Point Clouds Using Deep Learning. *Remote Sensing* 13(8) 1413.

KULICKI, M.; CABO, C.; TRZCINSKI, T.; BĘDKOWSKI, J.; STEREŃCZAK, K.; 2024. Artificial intelligence and terrestrial point clouds for forest monitoring. *Current Forestry Reports* 11.

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* 97(4) 479–496.

LIANG, X.; HYYPPÄ, J.; KAARTINEN, H.; LEHTOMÄKI, M.; PYÖRÄLÄ, J.; PFEIFER, N.; HOLOPAINEN, M.; BROLLY, G.; PIROTTI, F.; HACKENBERG, J.; HUANG, H.; JO, H.-W.; KATOH, M.; LIU, L.; MOKROŠ, M.; MOREL, J.; OLOFSSON, K.; POVEDA-LOPEZ, J.; TROCHTA, J.; WANG, D.; WANG, J.; XI, Z.; YANG, B.; ZHENG, G.; KANKARE, V.; LUOMA, V.; YU, X.; CHEN, L.; VASTARANTA, M.; SAARINEN, N.; WANG, Y.; 2018. International benchmarking of terrestrial laser scanning approaches for forest inventories. *ISPRS Journal of Photogrammetry and Remote Sensing* 144 137–179.

LINES, E. R.; FISCHER, F. J.; OWEN, H. J. F.; JUCKER, T.; 2022a. The shape of trees: Reimagining forest ecology in three dimensions with remote sensing. *Journal of Ecology* 110(8) 1730–1745.

LINES, E. R.; ALLEN, M.; CABO, C.; CALDERS, K.; DEBUS, A.; GRIEVE, S. W. D.; MILTIADOU, M.; NOACH, A.; OWEN, H. J. F.; PULITI, S.; 2022b. AI applications in forest monitoring need remote sensing benchmark datasets. *arXiv*.

PRENDES PÉREZ, C.; ACUNA, M.; CANGA, E.; ORDÓÑEZ, C.; CABO, C.; 2023. Optimal bucking of stems from terrestrial laser scanning data to maximize forest value. *Scandinavian Journal of Forest Research* 38 1–15.

PULETTI, N.; GROTTI, M.; SCOTTI, R.; 2019. Evaluating the eccentricities of poplar stem profiles with terrestrial laser scanning. *Forests* 10(3).

PULITI, S.; PEARSE, G.; SUROVÝ, P.; WALLACE, L.; HOLLAUS, M.; WIELGOSZ, M.; ASTRUP, R.; 2023. FOR-instance: a UAV laser scanning benchmark dataset for semantic and instance segmentation of individual trees. *arXiv*.

MA, Z.; DONG, Y.; ZI, J.; XU, F.; CHEN, F.; 2023. Forest-PointNet: A deep learning model for vertical structure segmentation in complex forest scenes. *Remote Sensing* 15(19) 4793.



QI, C. R.; SU, H.; MO, K.; GUIBAS, L. J.; 2017. PointNet: Deep learning on point sets for 3D classification and segmentation. *arXiv*.

RIEGL LASER MEASUREMENT SYSTEMS GMBH.; 2023a. RIEGL Vz-2000i. Retrieved December 05, 2024, from: <http://www.riegl.com/nc/products/terrestrial-scanning/produktdetail/product/scanner/58/>.

RIEGL LASER MEASUREMENT SYSTEMS GMBH.; 2023b. RIEGL Vz-400i. Retrieved December 05, 2024, from: <http://www.riegl.com/nc/products/terrestrial-scanning/produktdetail/product/scanner/48/>.

ROBERT, D.; RAGUET, H.; LANDRIEU, L.; 2023. Efficient 3D semantic segmentation with superpoint transformer. *Proceedings of the IEEE/CVF International Conference on Computer Vision*.

SCHRAIK, D.; HOVI, A.; RAUTIAINEN, M.; 2021. Crown level clumping in Norway spruce from terrestrial laser scanning measurements. *Agricultural and Forest Meteorology* 296 108238.

TIAN, J.; LI, H.; SUN, X.; ZHOU, Y.; MA, W.; CHEN, J.; ZHANG, J.; XU, Y.; 2023. Quality assessment of shrub observation data based on TLS: A case of revegetated shrubland, Southern Qinghai-Tibetan Plateau. *Land Degradation and Development* 34(5) 1570–1581.

ZHAO, H.; JIANG, L.; JIA, J.; TORR, P.; KOLTUN, V.; 2021. Point Transformer. *arXiv*.