

# 9CFE-1614

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



Organiza



# Estimación del volumen maderable mediante LiDAR y fotogrametría en bosques mediterráneos mixtos

DISSANAYAKE C.T.M<sup>1</sup>, TUPINAMBÁ-SIMÕES F<sup>1</sup>., VÁZQUEZ-VELOSO A.<sup>1</sup>, BRAVO-NUÑEZ A.<sup>1</sup>, BRAVO F.<sup>1</sup>

1 SMART Ecosystems research group, iuFOR - Instituto Universitario de Investigación en Gestión Forestal Sostenible, ETS de Ingenierías Agrarias de Palencia, Universidad de Valladolid, España. **Resumen** 

Las estimaciones precisas del volumen de los bosques son vitales para los objetivos de gestión forestal. Este estudio compara datos LiDAR, obtenidos mediante Handheld Laser Scanner (HLS), condatos fotogramétricos, obtenidos mediante Structure from Motion (SfM) para la estimación automatizada del volumen del tronco, con el objetivo de complementar el inventario de campo tradicional. El primer objetivo fueidentificar la mejor herramienta de código abierto para estimar los atributos de los árboles utilizando datos HLS entre Forest Structural Complexity Tool (FSCT) y Cloud Compare (CC). El segundo objetivo fuedeterminar el método óptimo de superposición de imágenes en los vuelos para lograr mejorar la estimación del volumen maderable individual. Se eligió como área de estudio una masa forestal mixta dominada por pinares, quejigos y cipreses en Palencia. Los datos se adquirieron a partir del inventario forestal tradicional, HLS, y dos patrones de vuelo de drones diferentes; vuelo con solapamiento frontal y lateral del 80% y vuelos cruzados con solapamiento frontal del 80% y lateral del 60%. FSCT obtuvo buenos resultados en la estimación de los atributos de los árboles, mientras que el mejor modelo se obtuvo para el patrón de vuelo con solapamiento frontal y lateral del 80%.

**Palabras clave:** *Handheld Laser Scanner (HLS), Structure from Motion (SfM),* Teledetección de corto alcance, Inventario forestal, *Remotely Piloted Aircraft (RPA).* 

# 1. Introducción

La medición precisa de los bosques es un paso crucial en el proceso de toma de decisiones en la gestión forestal (ÁLVAREZ-GONZÁLEZ et al., 2014). En los métodos tradicionales de inventariación forestal es común medir las alturas de los árboles (h) y los diámetros normales (d) con el fin de estimar el volumen de los árboles (v), la biomasa, el área basimétrica y el número de pies en la masa (HUSCH et al., 2002; VATANDAŞLAR & ZEYBEK, 2020). Aunque estas técnicas pueden ser precisas, también pueden resultar laboriosas, presentan complejidad en la adquisición de datos y, con frecuencia, se limitan a áreas pequeñas de estudio. Además, las mediciones manuales son propensas a errores humanos y pueden no capturar eficazmente la variabilidad espacial de las masas forestales (KERSHAW JR et al., 2016).

La aparición de tecnologías de teledetección como el *Light Detection and Ranging* (*LiDAR*) y la fotogrametría ha revolucionado la medición y la gestión forestal. La tecnología LiDAR utiliza pulsos láser para crear mapas tridimensionales detallados de la estructura forestal, proporcionando mediciones precisas de las alturas de los árboles, la densidad del dosel y el volumen (BAUWENS et al., 2016; VATANDAŞLAR & ZEYBEK, 2020). El escáner láser portátil (*Handheld Laser Scanner, HLS*) es una



variación de los dispositivos LiDAR que permite registrar un número ilimitado de posiciones de escaneo mientras se recorre la parcela (BAUWENS et al., 2016; BOSSE et al., 2012).

En 2015, el HLS se utilizó por primera vez en el inventario forestal, lo que permitió a los investigadores extraer con éxito los diámetros y las posiciones de los fustes tras el posprocesamiento de los datos (RYDING et al., 2015). Posteriormente, en 2018, los algoritmos de *Simultaneous Localization and Mapping (SLAM)* surgieron como una solución eficaz y eficiente para los estudios de inventario forestal, ya que pudieron sustituir la necesidad de un receptor de *Global Navigation Satellite System (GNSS)*. Esto permite la creación de escenas tridimensionales digitales incluso bajo el dosel (CHEN et al., 2019; TUPINAMBÁ-SIMÕES et al., 2023).

Existen dos enfoques principales para procesar estas nubes de puntos y extraer datos del inventario forestal: el enfoque basado en áreas (*Area-Based Approach, ABA*) y la detección individual de árboles (*Individual Tree Detection, ITD*) (HYYPPA et al., 2001; NÆSSET, 2002). El enfoque ABA calcula indicadores estadísticos basados en los puntos localizados dentro de un área específica, mientras que el ITD requiere un método preciso y adaptable para segmentar las nubes de puntos en árboles individuales, siendo una metodología más desafiante (XIANG et al., 2024). En este estudio, se utilizó el enfoque ITD para extraer atributos de los árboles a partir de la nube de puntos generada por HLS.

Aunque el HLS desempeña un papel significativo en las mediciones de inventarios forestales, tiene algunas limitaciones al escanear grandes áreas forestales, ya que solo puede cubrir pequeñas áreas cada vez. Además, el HLS tiende a carecer de datos sobre el dosel y la estructura forestal debido a que su operación se realiza a nivel terrestre (GIANNETTI et al., 2018). Sin embargo, con el rápido avance de la tecnología, los vehículos aéreos no tripulados (*Unmanned Aerial Vehicles, UAV*) han alcanzado un grado de madurez técnica que permite capturar imágenes de alta resolución espacial y temporal incluso en grandes áreas cuando están equipados con cámaras digitales (GOODBODY et al., 2017).

La técnica de *Structure from Motion (SfM)* permite la creación de nubes de puntos tridimensionales continuas a partir de estas imágenes aéreas mediante el uso de técnicas de procesamiento fotogramétrico. Este enfoque puede reducir significativamente los costes de inventariación, además de acortar el tiempo necesario para realizar inventarios en grandes áreas de estudio (DANDOIS et al., 2015; KOH & WICH, 2012; PULITI et al., 2017). Algunos estudios han demostrado que los datos tridimensionales generados a partir de imágenes de drones (*Remotely Piloted Aircraft, RPA*) utilizando SfM y algoritmos fotogramétricos asociados son una fuente de datos confiable para respaldar los inventarios forestales (LISEIN et al., 2013; PULITI et al., 2017).

Las actualizaciones regulares de los inventarios forestales son esenciales para una gestión, conservación, formulación de políticas efectivas y relativas a los sistemas forestales. Entre otras variables, los cálculos del volumen de los fustes desempeñan un papel fundamental en diversos aspectos, como las estimaciones de carbono, biomasa y producción de madera. En los bosques mediterráneos españoles, las estimaciones del volumen de madera constituyen información clave para las directrices silvícolas, ya que algunas de ellas se desarrollan para promover la obtención de productos de madera de alta calidad y mayor volumen maderable (RÍO GAZTELURRUTIA, 2006).



Actualmente, el Inventario Forestal Nacional de España (IFN) proporciona ecuaciones para calcular el volumen de los fustes utilizando el diámetro normal y la altura del árbol. Sin embargo, medir el diámetro y la altura de los árboles a nivel individual en grandes áreas forestales mediante el enfoque tradicional resulta laborioso, requiere mucho tiempo y es costoso debido a la naturaleza de estas mediciones. Avanzando más allá de los enfoques tradicionales hacia una silvicultura precisión, exploramos alternativas al método convencional de inventario forestal para la estimación automatizada del volumen maderable de árbol individual utilizando datos de HLS y RPA-SfM.

# 2. Objetivos

El objetivo principal de este trabajo es desarrollar un modelo empírico para estimar el volumen de los fustes a nivel de árbol individual en un bosque mixto mediterráneo utilizando datos de HLS y RPA-SfM.

Este objetivo principal se ha descompuesto en dos objetivos secundarios:

- 1. Identificar la mejor herramienta de código abierto entre *Forest Structural Complexity Tool (FSCT)* y *CloudCompare (CC)* para estimar los atributos de los árboles utilizando datos de HLS
- 2.

Determinar el método de vuelo con solapamiento óptimo de imágenes RPA para lograr un mejor funcionamiento del modelo

3. Metodología

Área de estudio

El área de estudio se encuentra en Ampudia (41°54'50.44" N, 4°46'48.69" O), en la provincia de Palencia (Castilla y León). La masa forestal tiene una superficie de 30 ha y está compuesta por *Pinus halepensis, Pinus pinea* y *Cupressus sempervirens,* junto con regenerado natural de *Quercus faginea*. Para la recolección de datos, se establecieron nueve parcelas circulares con un radio de 12 m cada una dentro de la masa forestal, utilizando tanto métodos tradicionales de inventario forestal como tecnología de escáner láser portátil (HLS) (Figura 1). Recolección de datos

En este estudio, la recolección de datos se realizó mediante tres métodos diferentes: inventario forestal tradicional, datos LiDAR adquiridos con un escáner láser portátil (HLS) y datos SfM obtenidos con un dron.

Se midieron las especies arbóreas, el diámetro normal (d) y la altura (h) de los árboles en 9 parcelas utilizando métodos tradicionales. En total, se registraron 157 árboles en las 9 parcelas. Se utilizó una forcípula para medir el diámetro y un Vertex Laser Geo para medir la altura de los árboles, siendo los árboles con un d inferior a 7 cm excluídos. Para capturar datos de nubes de puntos 3D en cada parcela se utilizó un escáner láser portátil ZEB-HORIZON GeoSLAM (GeoSLAM Ltd., Nottingham, Reino Unido), y se utilizó un jalón con un sensor GNSS RTK separado junto con el HLS para registrar las coordenadas de los datos adquiridos. El escaneo se realizó en un día soleado y sin viento para evitar factores que afectaran la toma de puntos durante el escaneo.



Figura 1. Mapa de área de estudio y parcelas de estudio

El *Remotely Piloted Aircraft (RPA)* utilizado fue un dron DJI Mavic 3E equipado con una cámara digital, el cual capturó imágenes de toda la masa forestal. Se realizaron dos vuelos distintos, variando el ángulo de vuelo, la cámara y el solapamiento de las imágenes. Todos los vuelos se realizaron a una altitud de 70 m, a una velocidad de 10 ms<sup>-1</sup> y con una resolucion de 1,88 cm/píxel.

El primer vuelo capturó imágenes RGB con un solapamiento lateral y frontal del 80% (80x80F) y un ángulo de vuelo de 245<sup>°</sup>, con la cámara orientada hacia abajo. El segundo vuelo consistió en un vuelo cruzado dividido en dos vuelos, donde las imágenes se capturaron con un solapamiento frontal del 80% y lateral del 60% (80x60CF) y con la cámara inclinada a 45<sup>°</sup>. El primero de ellos (80x60CF) se realizó con un ángulo de 245<sup>°</sup>, mientras que el segundo tuvo un ángulo de 225<sup>°</sup>. El solapamiento frontal y lateral se presenta en la Figura 2.

Las imágenes se capturaron bajo condiciones de cielo despejado. Se establecieron cuatro puntos de control terrestre (puntos de georreferenciación) en áreas abiertas con claros en el dosel de copas. Se recopilaron aproximadamente 1.059 imágenes del vuelo 80x80F, mientras que del 80x60CF se recopilaron un total de 1.113 imágenes.







Procesamiento de datos

El procesamiento de datos se realizó en tres etapas diferentes: procesamiento de datos del inventario de campo, procesamiento de datos de HLS y procesamiento de imágenes del dron.

Cálculos del volumen de los fustes a partir de datos del inventario de campo

Se emplearon las ecuaciones del Inventario Forestal Nacional de España (IFN) para los cálculos del volumen de los fustes, utilizando los datos de diámetro a la diámetro normal y altura total de los árboles obtenidos del inventario de campo. Los coeficientes de dichas ecuaciones dependen de las especies y de otros factores como el área de estudio, el uso del suelo, la estructura forestal y el tipo de suelo. Considerando todos los factores, se seleccionaron los coeficientes más adecuados para nuestro caso de estudio (Tabla 1). En estos, los coeficientes para *P. halepensis* mostraron un error en las predicciones de árboles de gran tamaño, por lo que se decidió tomar los valores de los coeficientes del área más cercana (Burgos) para los cálculos de esta especie.

# VCC=p(Dn<sup>q</sup>)(Ht<sup>r</sup>)

- Dn = diámetro normal (mm)
- Ht = altura total (m)
- VCC = volumen (dm<sup>3</sup>)Tabla 1. Coeficientes para las ecuaciones del IFN según las especies arbóreas

$\sum$		Especie		
ONGRESO AL ESPAÑOL	P.halepensis	0,0010414	1,85853	0,8476
5   <b>16-20</b> N   JUNIO	P.pinea	0,0014257	0	9,98882
	Q.faginea	0,0952676	1,23399	0,11901
	C.sempervirens	0,0014257	1,76673	0,98882

# Procesamiento de datos HLS

202

Los datos HLS obtenidos del escáner estaban en un formato de archivo comercial (.geoslam). Para convertir este archivo a un formato de datos LiDAR común, la nube de puntos en bruto se procesó utilizando el algoritmo 3D de GEOSLAM para generar una nube de puntos 3D homogénea de la masa forestal y convertir los datos en formatos de archivo .las, lo que facilita su manejo en etapas posteriores. Este paso se realizó con el software 6.0 de procesamiento *GeoSLAM Hub* (GeoSLAM Hub, 2020).

Los puntos de control en el terreno (*Ground Control Points, GCP*), que fueron georreferenciados utilizando el software *Magnet Tools* (MAGNET Tools, 2023), se emplearon para georreferenciar las nubes de puntos mencionadas. Luego, estas se recortaron en función del tamaño de cada parcela para análisis posteriores. Las nubes de puntos resultantes se procesaron mediante dos métodos diferentes para extraer atributos de los árboles, como d y h de los árboles individuales en el área de estudio: *Forest Structural Complexity Tool (FSCT) y CloudCompare (CC)*.

El FSCT es una herramienta que permite extraer automáticamente las mediciones a escala de parcela y de árbol (KRISANSKI et al., 2021), mientras que CC es un software para la edición y procesamiento de nubes de puntos 3D (CloudCompare, 2023). Después de extraer los atributos de los árboles con las dos herramientas mencionadas, los resultados se compararon con los datos obtenidos en el inventario de campo con el objetivo de seleccionar la mejor herramienta para el desarrollo del modelo.

Procesamiento de datos de dron

Las imágenes de dron de los diferentes vuelos se procesaron por separado utilizando el software para SfM DJITerra que genera nubes de puntos 3D de toda la masa forestal a partir de imágenes RGB aéreas y de los objetivos utilizados en el dron. Las imágenes de los objetivos se utilizaron como puntos de georeferenciación. Posteriormente, las nubes de puntos principales se recortaron según las nueve parcelas experimentales.

El paquete lidR de R (ROUSSEL & AUTY, 2016) se utilizó para clasificar los puntos del suelo. Se realizaron las siguientes tareas de manera secuencial: normalización de altura, creación de un modelo de altura del dosel (*Canopy Height Model, CHM*) y detección individual de árboles. La segmentación individual de los árboles se realizó utilizando el Voronoi tessellation algorithm (SILVA et al., 2016). Una vez segmentados los árboles, se llevó a cabo la segmentación de las copas utilizando el paquete lidR de R.

El paquete LidRmetrics de R se utilizó para extraer métricas de las copas a partir de las nubes de puntos relacionadas con cada árbol segmentado. Este análisis incluyó más de 70 métricas de copas.



# Modelización

El desarrollo del modelo para estimar los volúmenes de fuste a nivel de árbol individual se realizó por separado para los datos de 80x80F y 80x60CF. Los volúmenes de árboles individuales se tomaron como variable dependiente, calculados utilizando d y h de los árboles extraídos mediante FSCT y las ecuaciones del IFN. Las métricas de las copas derivadas de las nubes de puntos RPA-SfM se utilizaron como variables independientes.

Para el proceso de desarrollo del modelo, se utilizó el algoritmo *Random Forest (RF)*. El conjunto de datos se dividió en un conjunto de entrenamiento (70%) y un conjunto de prueba (30%) para entrenar y validar el modelo.

El rendimiento de los modelos desarrollados se evaluó utilizando el error medio cuadrático (RMSE) y el coeficiente de determinación (R<sup>2</sup>). Posteriormente, se comparó el rendimiento de los diferentes modelos, seleccionándose el que mostró el mejor rendimiento.



Figura 3. Diagrama de flujo de la metodología

# 4. Resultados

Mediciones básicas

Los resultados del inventario de campo incluyen el diámetro normal (d), la altura (h) de los árboles y las especies arbóreas para un total de 157 árboles en 9 parcelas del área de estudio. El resumen de las especies arbóreas se presenta en la Tabla 2.

Tabla 2. Resumen de las especies arbóreas y sus principales características



Número total de árboles		h (m)					
P. halepensis	55	31,37	44,95	18,1	12,8	16,3	9,5
P. pinea	38	26,92	40,85	15,85	9,2	12,4	6,9
Q. faginea	34	10,77	19,45	7,00	5,8	8,9	3,4
C. sempervirens	30	16,05	30,60	6,95	8,3	11,4	5,1

#### Procesamiento de datos HLS

El procesamiento de datos HLS incluye la detección de árboles, así como la medición de d, h y el volumen de los fustes. La Tabla 3 resume el número de árboles detectados y los resultados de precisión obtenidos utilizando dos herramientas de procesamiento diferentes, FSCT y CC, a partir de las nubes de puntos LiDAR HLS. Los datos del inventario de campo se han utilizado como referencia para comparar los resultados. (Tabla 4)

Inventario de campo		FSCT		СС	
Número de árboles detectados	Porcentaje de acierto	Número de árboles detectados		Porcentaje de acierto	
Pinos	93	89	95,6%	90	96,7%
Robles	34	08	23,5%	18	64,1%
Ciprés	30	27	90%	25	83,3%
Total	157	124	79,0%	133	84,7%

Tabla 4. Resultados de la comparación de atributos de árboles entre FSCT y CC con el inventario de campo

Comparación con el inventario de campo	h		·	d	
FSCT	СС	FSCT		сс	
R <sup>2</sup>		0,87	0,67	0,86	0,84
RMSE	0,98	1,61	3,21	3,6	4

La comparación entre las mediciones del inventario de campo y las estimaciones de d y h obtenidas mediante FSCT se presentan en las Figuras 4 y 5. Los datos indican que Quercus faginea tiende a tener alturas sobre estimadas, mientras que las estimaciones para otras especies son más precisas. Las estimaciones de diámetro normal realizadas con FSCT muestran un buen rendimiento para todas las especies arbóreas, con solo unas pocas presentando desviaciones (Figura 5).

FSCT ofrece estimaciones más precisas y fiables de d y h en comparación con CC. Por lo tanto, los valores derivados de FSCT se utilizaron para calcular los volúmenes de los árboles mediante la ecuación del IFN.



Figura 4. Comparación entre las mediciones de altura de los árboles de IFN y FSCT



Figura 5. Comparación entre los diámetros de IFN y FSCT

Modelización

Las métricas de copa obtenidas a partir de dos configuraciones de vuelo de drones (80x80F y 80x60CF) se procesaron utilizando el algoritmo *Random Forest (RF)* para ajustar el modelo predictivo. La Tabla 5 destaca las métricas de rendimiento de los



modelos desarrollados para predecir volumen de fuste individual a partir de las variables de copa.

			,	
		80x60CF		
R	2	0,76	0	,73
RMSE (dm	3	)	90,96	88,90

Tabla 5. Resultados de los n	nodelos ajustados
------------------------------	-------------------

# 5. Discusión

Los resultados del inventario de campo proporcionan una visión general de las especies arbóreas y sus principales características en el área de estudio. El inventario incluye un total de 157 árboles distribuidos en 9 parcelas, cubriendo un total de cuatro especies: *P. halepensis, P. pinea, Q. faginea y C. sempervirens.* 

La Tabla 1 resume variaciones en d y h de los árboles entre las distintas especies. *P. halepensis* presenta los valores medios más altos de d (31,37 cm) y h (12,8 m), mientras que *Q. faginea* muestra los valores medios más bajos (d: 10,77 cm; h: 5,8 m). Estas diferencias reflejan las diversas características estructurales de las especies arbóreas presentes en el área de estudio. Cabe destacar que *Q. faginea* proviene de regeneración natural y crece de manera agrupada en la zona de estudio.

Tras procesar las nubes de puntos HLS con FSCT y CC, los resultados mostraron que ambas herramientas pudieron detectar pinos y cipreses mejor que los robles. FSCT presentó una tasa de acierto del 95,6% para los pinos, 90,0% para los cipreses y 23,5% para los robles, mientras que CC tuvo un desempeño ligeramente superior con una tasa de acierto del 96,7% para los pinos, 83,3% para los cipreses y 64,1% para los robles. Esta discrepancia entre especies arbóreas podría atribuirse a la estructura del rodal. Los pinos y cipreses fueron plantados en nuestra área de estudio, y se llevaron a cabo diferentes intervenciones de poda y clara para gestionarlos. Esta gestión creó claros en el bosque donde la luz puede penetrar, lo que favorece la regeneración natural de los robles, resultando en su crecimiento en forma de grupos en una segunda capa forestal formada por los robles. Esta situación generó dificultades para identificar árboles individuales, ya que los troncos no fueron podados y los árboles están demasiado próximos y conectados por sus ramas. Esto demuestra que en rodales forestales mixtos e irregulares, FSCT y CC enfrentan dificultades para detectar árboles individuales cuando estas especies crecen en grupos. Diversos estudios han reportado resultados similares, demostrando que la detección de árboles individuales y la segmentación de árboles pequeños pueden verse afectadas por un dosel alto en un rodal forestal mixto (DEL PERUGIA et al., 2019; KRISANSKI et al., 2021; RYDING et al., 2015). Además, cuando los árboles tienen un d < 10 cm, los datos HLS proporcionan estimaciones de detección de árboles menos precisas (BAUWENS et al., 2016; GIANNETTI et al., 2018).

Otro estudio realizado en un rodal forestal mixto mediterráneo en España reportó dificultades en la detección de árboles utilizando datos HLS procesados por FSCT. Los resultados mostraron una tasa de acierto en la detección de árboles del 88%. Sin embargo, los autores indicaron que la detección de árboles podría depender de la trayectoria del escaneo y del modo de transformación (rígido o no rígido)



(TUPINAMBÁ-SIMÕES et al., 2023). Otra investigación realizada en el sur de Bélgica exploró la capacidad de detección de árboles mediante HLS en diferentes tipos de bosques (frondosas, coníferas y mixtos). Este estudio reportó que se detectaron el 90%  $\pm$  12% de los árboles (d > 10 cm), mientras que hubo un promedio del 31%  $\pm$  24% de árboles "falsos" debido a errores en el procesado (BAUWENS et al., 2016). Además, considerando un bosque de plantación de *Eucalyptus globulus*, otro estudio reportó una tasa de detección exitosa del 90,98% por FSCT para 588 árboles de referencia (KRISANSKI et al., 2021).

Comparación de las estimaciones de altura de los árboles

Después de la identificación de árboles individuales, también se compararon las estimaciones de atributos arbóreos con los datos del IFN. La comparación entre las mediciones de inventario forestal y las estimaciones de altura de los árboles realizadas por FSCT reveló un valor de R<sup>2</sup> de 0,87, indicando una fuerte correlación, mientras que el RMSE fue de 0,98 m. Sin embargo, los datos mostraron que FSCT tendía a sobreestimar la altura de los robles, mientras que las estimaciones para los pinos eran más precisas. Según su publicación original , FSCT parece subestimar ligeramente la altura de los árboles, con errores de -0,139 m, -0,327 m y 3,524 m en la media, mediana y RMSE, respectivamente (KRISANSKI et al., 2021). Los autores señalaron que la subestimación de la altura de los árboles es común al utilizar nubes de puntos de escáner láser terrestre (TLS), ya que las copas de los árboles no son completamente capturadas.

De manera similar, para las estimaciones de altura de los árboles, CC presentó un valor de R<sup>2</sup> menor, de 0,67, y un RMSE de 1,61 m. En el caso de los robles se observó una sobreestimación de estos valores, mientras que las estimaciones para los pinos y cipreses fueron más precisas. Sin embargo, un estudio realizado en un rodal forestal mediterráneo de múltiples capas de arbolado mostró un bajo rendimiento en las estimaciones de altura de los árboles (RMSE = 2,15) utilizando el software CC, destacando que HLS es menos preciso debido al rango limitado del láser (GIANNETTI et al., 2018).

Además, numerosos estudios concluyen que HLS no sería la mejor opción para las mediciones de altura de los árboles debido a la falta de información sobre el dosel superior (BAUWENS et al., 2016; VATANDAŞLAR & ZEYBEK, 2020). Como solución, las nubes de puntos terrestres pueden fusionarse con nubes de puntos aéreas (ALS), obteniendo mejores resultados como reportan algunos estudios (GIANNETTI et al., 2018; PARIS et al., 2015).

De acuerdo con nuestros resultados, la estructura forestal puede desempeñar un papel significativo en la estimación del volumen. Además, mientras que variables como las especies arbóreas y d se miden directamente en campo en inventarios tradicionales, h no puede medirse directamente y generalmente se estima mediante un hipsómetro. Por lo tanto, debe considerarse el sesgo en los valores de altura "medidos" al discutir su comparación con las alturas estimadas por HLS. Comparación de las estimaciones del diámetro normal (d)

Numerosos estudios revelan que la tecnología HLS tiende a estimar d con un alto grado de precisión (BAUWENS et al., 2016; GIANNETTI et al., 2018; HYYPPÄ et al., 2020; KRISANSKI et al., 2021; VATANDAŞLAR & ZEYBEK, 2020). En nuestro estudio, tanto FSCT como CC mostraron un rendimiento sólido en las estimaciones de d a nivel de árbol individual para todas las especies arbóreas, aunque se observaron algunas desviaciones. FSCT presentó un valor de  $R^2$  de 0,86 para las estimaciones de d, mientras que CC también tuvo un buen rendimiento con un  $R^2$  de 0,84. La



precisión de las estimaciones de d podría estar influenciada por el tamaño del árbol, donde los árboles grandes producen estimaciones más precisas que los árboles pequeños (BAUWENS et al., 2016; RYDING et al., 2015).

El estudio mencionado anteriormente en Australia, que involucró 588 árboles de *Eucalyptus globulus*, evaluó el rendimiento de FSCT en las estimaciones de d. Los resultados mostraron errores medios, medianos y RMSE de -0,007 m, 0,008 m y 0,072 m, respectivamente. Esta investigación utilizó nubes de puntos generadas por un TLS (KRISANSKI et al., 2021). Comparados con nuestros hallazgos, estos resultados indican que en una plantación monocultivo FSCT tiene un mejor rendimiento que en bosques mixtos (VATANDAŞLAR & ZEYBEK, 2020).

Respecto a CC, trabajos previos han mostrado resultados similares. Un estudio realizado en una masa compleja y mixta en la región mediterránea mostró un valor de RMSE más bajo (RMSE = 1,28 cm) (GIANNETTI et al., 2018) en comparación con nuestro estudio (RMSE = 3,21 cm). Llevado a cabo en Florencia (Italia Central), dominada por coníferas (*Cupressus sempervirens L. y Pinus pinaster Aiton*) y frondosas (*Quercus ilex L.*). La mayoría de los estudios han considerado árboles con un d mayor a 10 cm, lo que podría ser una razón para los valores de RMSE más bajos en sus estudios (BAUWENS et al., 2016; GIANNETTI et al., 2018; RYDING et al., 2015) en comparación con los nuestros.

# Procesamiento de imágenes de drones

Las imágenes de drones se procesaron con SfM para crear nubes de puntos, las cuales desempeñaron un papel principal en la detección de árboles y la extracción de métricas de copas. El redimiento en la detección de árboles fue algo menor en el caso de las nubes de puntos generadas por drones. Se detectó solo el 63,13% del número total de árboles en las parcelas experimentales. Un estudio de caso realizado en rodales mixtos en el interior de Columbia Británica indicó que el 70% de los árboles fueron detectados a partir de nubes de puntos fotogramétricas obtenidas con drones, lo cual es ligeramente superior a los resultados de nuestro estudio (GOODBODY et al., 2017).

El aumento de los solapes en la captura de imágenes puede mejorar la calidad de las nubes de puntos, lo que conduce a mejores estimaciones (GOODBODY et al., 2017; NURMINEN et al., 2013). Mientras que el aumento del solape en la dirección de vuelo no requiere líneas de vuelo adicionales, el solape transversal sí lo requiere, lo que consecuentemente incrementa los costes. Además, un mayor solape implica tiempos de procesamiento más prolongados, independientemente del equipo computacional utilizado (DANDOIS et al., 2015). Por lo tanto, el solape de vuelo debe equilibrarse con los requisitos de los parámetros de las imágenes (GOODBODY et al., 2019).

# Modelización

Como paso final de este estudio, se desarrolló un modelo para estimar el volumen individual de los árboles basado en datos de nubes de puntos. Las ligeras diferencias encontradas en los  $R^2$  y RMSE entre las configuraciones 80x80F (0,76 y 90,96, respectivamente) y 80x60CF (0,73 y 88,90, respectivamente) sugieren que, si bien ambas configuraciones de drones muestran capacidades predictivas similares, la configuración 80x80F es ligeramente más precisa.

La reducción del error del modelo RF puede lograrse aumentando el tamaño de la muestra de la segunda fase o seleccionando deliberadamente las parcelas de



campo (GRAFSTRÖM & RINGVALL, 2013; SAARELA et al., 2015). Por lo tanto, en este estudio, aumentar el tamaño de la muestra sería una buena recomendación para mitigar el impacto significativo de los parámetros del modelo, lo que llevaría a estimaciones más precisas.

PULITI et al., (2017) examinaron el inventario forestal en el sur de Noruega y las mediciones de volumen utilizando imágenes de dron con un 90% y 80% de solape frontal y lateral. Concluyó que incorporar datos auxiliares de dron a los datos de campo en la estimación de volumen aumentó la precisión en comparación con las estimaciones basadas únicamente en datos de campo. Además, mostró que cuando se dispone de un modelo robusto de predicción de volumen, las estimaciones de dron pueden lograr una precisión comparable. El estudio también reveló que la precisión del modelo mejoró con el número de parcelas, mostrando valores de  $R^2$  de 0,74 y 0,78 para los modelos desarrollados con 26 y 33 parcelas, respectivamente.

# 6. Conclusiones

El HLS puede utilizarse para escanear las parcelas experimentales, mientras que el RPA se emplea para capturar imágenes de todo el rodal con un solapamiento del 80% tanto frontal como lateral. En el proceso de extracción de métricas de árbol a partir de nubes de puntos HLS, FSCT proporciona mejores estimaciones en comparación con CC. Así, FSCT se utilizó para estimar el volumen del fuste a partir de las métricas de árbol. Las métricas seleccionadas del dosel derivadas de nubes de puntos RPA-SfM se usaron como variables independientes en este estudio. El mejor modelo para estimar el volumen del fuste a nivel de árbol individual se desarrolló utilizando los datos de 80x80F. Este modelo alcanzó un coeficiente de determinación (R<sup>2</sup>) de 0,76 y un RMSE de 90,96 dm<sup>3</sup>. No obstante, se podrían lograr mejoras adicionales en el modelo incorporando más datos de árboles y explorando diferentes algoritmos de segmentación de árboles. El estudio revela que la integración de escaneos terrestres (HLS) con tecnología RPA-SfM permite realizar estimaciones más precisas de manera rentable y eficiente en términos de tiempo. Como conclusión, resulta factible lograr un inventario forestal utilizando exclusivamente estas tecnologías cuando el objetivo es la estimación del volumen a nivel de árbol individual. Sin embargo, futuros trabajos podrían aportar mejoras a esta metodología incrementando la calidad de los resultados.

# 7. Agradecimientos

Esta investigación fue financiada por:

- El programa de maestría MEDFOR sobre Gestión Forestal Mediterránea y Recursos Naturales (Erasmus+: Erasmus Mundus Joint Master Degrees, Referencia del Proyecto 619801-EPP-1-2020-1-PT-EPPKA1-JMD-MOB).
- Fondos adicionales para este estudio fueron proporcionados por:
  - El proyecto ETN Skill-For.Action del programa de investigación e innovación Horizonte 2020 de la Unión Europea, bajo la acción Marie Skłodowska-Curie, Acuerdo de Subvención #956355.
  - La subvención IMFLEX PID2021-126275OB-C22 Gestión Forestal Integrada a lo largo de gradientes de complejidad, financiada por el Ministerio de Ciencia de España MCIN/AEI/10.13039/501100011033.
  - El proyecto "CLU-2019-01-iuFOR Instituto Unidad de Excelencia" y su refuerzo internacional (CL-EI-2021-05) en la Universidad de Valladolid, financiado por la Junta de Castilla y León y cofinanciado por la Unión Europea (FEDER "Europa impulsa nuestro crecimiento").



 La Unión Europea y el Consejo de Educación de la Junta de Castilla y León (ORDEN EDU/842/2022).

# 8. 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 modeling. Forest Ecology and Management, 316, 54–64. https://doi.org/10.1016/j.foreco.2013.09.007 BAUWENS S: BARTHOLOMEUS H: CALDERS K: LEIEUNE P: 2016 Forest

BAUWENS, S.; BARTHOLOMEUS, H.; CALDERS, K.; LEJEUNE, P.; 2016. Forest Inventory with Terrestrial LiDAR: A Comparison of Static and Hand-Held Mobile Laser Scanning. Forests, 7(12), 127. https://doi.org/10.3390/f7060127 BOSSE, M.; ZLOT, R.; FLICK, P.; 2012. Zebedee: Design of a Spring-Mounted 3-D Range Sensor with Application to Mobile Mapping. IEEE Transactions on Robotics, 28(5), 1104–1119. https://doi.org/10.1109/TRO.2012.2200990 CHEN, S.; LIU, H.; FENG, Z.; SHEN, C.; CHEN, P.; 2019. Applicability of personal laser scanning in forestry inventory. PLOS ONE, 14(2), e0211392. https://doi.org/10.1371/journal.pone.0211392 CloudCompare (Version 2.13).; 2023. [Computer software]. DANDOIS, J.; OLANO, M.; ELLIS, E.; 2015. Optimal Altitude, Overlap, and Weather Conditions for Computer Vision UAV Estimates of Forest Structure. Remote Sensing, 7(10), 13895–13920. https://doi.org/10.3390/rs71013895 DEL PERUGIA, B.; GIANNETTI, F.; CHIRICI, G.; TRAVAGLINI, D.; 2019. Influence of Scan Density on the Estimation of Single-Tree Attributes by Hand-Held Mobile Laser Scanning. Forests, 10(3), 277. https://doi.org/10.3390/f10030277 GeoSLAM Hub (Version 6.0).; 2020. [Computer software]. FARO. GIANNETTI, F.; PULETTI, N.; QUATRINI, V.; TRAVAGLINI, D.; BOTTALICO, F.; CORONA, P.; CHIRICI, G.; 2018. Integrating terrestrial and airborne laser scanning for the assessment of single-tree attributes in Mediterranean forest stands. European Journal of Remote Sensing, 51(1), 795–807. https://doi.org/10.1080/22797254.2018.1482733 GOODBODY, T. R. H.; COOPS, N. C.; MARSHALL, P. L.; TOMPALSKI, P.; CRAWFORD, P.; 2017. Unmanned aerial systems for precision forest inventory purposes: A review and case study. The Forestry Chronicle, 93(01), 71-81. https://doi.org/10.5558/tfc2017-012 GOODBODY, T. R. H.; COOPS, N. C.; WHITE, J. C.; 2019. Digital Aerial Photogrammetry for Updating Area-Based Forest Inventories: A Review of Opportunities, Challenges, and Future Directions. Current Forestry Reports, 5(2), 55-75. https://doi.org/10.1007/s40725-019-00087-2 GRAFSTRÖM, A.; RINGVALL, A. H.; 2013. Improving forest field inventories by using remote sensing data in novel sampling designs. Canadian Journal of Forest Research, 43(11), 1015–1022. https://doi.org/10.1139/cjfr-2013-0123 HUSCH, B.; BEERS, T. W.; KERSHAW JR, J. A.; 2002. Forest mensuration. John Wiley & Sons. HYYPPÄ, E.; YU, X.; KAARTINEN, H.; HAKALA, T.; KUKKO, A.; VASTARANTA, M.; HYYPPÄ, J.; 2020. Comparison of Backpack, Handheld, Under-Canopy UAV, and

Above-Canopy UAV Laser Scanning for Field Reference Data Collection in Boreal Forests. Remote Sensing, 12(20), 3327. https://doi.org/10.3390/rs12203327 HYYPPA, J.; KELLE, O.; LEHIKOINEN, M.; INKINEN, M.; 2001. A segmentation-based method to retrieve stem volume estimates from 3-D tree height models produced by laser scanners. IEEE Transactions on Geoscience and Remote Sensing, 39(5),

969-975. https://doi.org/10.1109/36.921414 KERSHAW JR, J. A.; DUCEY, M. J.; BEERS, T. W.; HUSCH, B.; 2016. Forest mensuration. John Wiley & Sons. FORESTAL ESPAÑO KOH, L. P.; WICH, S. A.; 2012. Dawn of Drone Ecology: Low-Cost Autonomous Aerial 2025 | 16-20 Vehicles for Conservation. Tropical Conservation Science, 5(2), 121–132. GIJÓN JUNIC https://doi.org/10.1177/194008291200500202 KRISANSKI, S.; TASKHIRI, M. S.; GONZALEZ ARACIL, S.; HERRIES, D.; MUNERI, A.; GURUNG, M. B.; MONTGOMERY, J.; TURNER, P.; 2021. Forest Structural Complexity Tool—An Open Source, Fully-Automated Tool for Measuring Forest Point Clouds. Remote Sensing, 13(22), 4677. https://doi.org/10.3390/rs13224677 LISEIN, J.; PIERROT-DESEILLIGNY, M.; BONNET, S.; LEJEUNE, P.; 2013. A Photogrammetric Workflow for the Creation of a Forest Canopy Height Model from Small Unmanned Aerial System Imagery. Forests, 4(4), 922–944. https://doi.org/10.3390/f4040922 MAGNET Tools (Version 8.0).; 2023. [Computer software]. NÆSSET, E.; 2002. Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data. Remote Sensing of Environment, 80(1), 88-99. https://doi.org/10.1016/S0034-4257(01)00290-5 NURMINEN, K.; KARJALAINEN, M.; YU, X.; HYYPPÄ, J.; HONKAVAARA, E.; 2013. Performance of dense digital surface models based on image matching in the estimation of plot-level forest variables. ISPRS Journal of Photogrammetry and Remote Sensing, 83, 104–115. https://doi.org/10.1016/j.isprsjprs.2013.06.005 PARIS, C.; KELBE, D.; VAN AARDT, J.; BRUZZONE, L.; 2015. A precise estimation of the 3D structure of the forest based on the fusion of airborne and terrestrial lidar data. 2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 49-52. https://doi.org/10.1109/IGARSS.2015.7325694 PULITI, S.; ENE, L. T.; GOBAKKEN, T.; NÆSSET, E.; 2017. Use of partial-coverage UAV data in sampling for large scale forest inventories. Remote Sensing of Environment, 194, 115-126. https://doi.org/10.1016/j.rse.2017.03.019 RÍO GAZTELURRUTIA, M. del (with E. LÓPEZ SENESPLEDA & G. MONTERO GONZÁLEZ).; 2006. Manual de gestión para masas procedentes de repoblación de Pinus pinaster Ait., Pinus sylvestris L. y Pinus nigra Arn. en Castilla y León. Junta de Castilla y León, Consejería de Medio Ambiente. ROUSSEL, J.-R.; AUTY, D.; 2016. lidR: Airborne LiDAR Data Manipulation and Visualization for Forestry Applications (p. 4.1.1) [Dataset]. https://doi.org/10.32614/CRAN.package.lidR RYDING, J.; WILLIAMS, E.; SMITH, M.; EICHHORN, M.; 2015. Assessing Handheld Mobile Laser Scanners for Forest Surveys. Remote Sensing, 7(1), 1095–1111. https://doi.org/10.3390/rs70101095 SAARELA, S.; SCHNELL, S.; GRAFSTRÖM, A.; TUOMINEN, S.; NORDKVIST, K.; HYYPPÄ, J.; KANGAS, A.; STÅHL, G.; 2015. Effects of sample size and model form on the accuracy of model-based estimators of growing stock volume. Canadian Journal of Forest Research, 45(11), 1524–1534. https://doi.org/10.1139/cjfr-2015-0077 SILVA, C. A.; HUDAK, A. T.; VIERLING, L. A.; LOUDERMILK, E. L.; O'BRIEN, J. J.; HIERS, J. K.; JACK, S. B.; GONZALEZ-BENECKE, C.; LEE, H.; FALKOWSKI, M. J.; KHOSRAVIPOUR, A.; 2016. Imputation of Individual Longleaf Pine (Pinus palustris Mill.) Tree Attributes from Field and LiDAR Data. Canadian Journal of Remote Sensing, 42(5), 554-573. https://doi.org/10.1080/07038992.2016.1196582 TUPINAMBÁ-SIMÕES, F.; PASCUAL, A.; GUERRA-HERNÁNDEZ, J.; ORDÓÑEZ, C.; DE CONTO, T.; BRAVO, F.; 2023. Assessing the Performance of a Handheld Laser Scanning System for Individual Tree Mapping—A Mixed Forests Showcase in



Spain. Remote Sensing, 15(5), 1169. https://doi.org/10.3390/rs15051169 VATANDAŞLAR, C.; ZEYBEK, M.; 2020. Application of handheld laser scanning technology for forest inventory purposes in the NE Turkey. TURKISH JOURNAL OF AGRICULTURE AND FORESTRY, 44(3), 229–242. https://doi.org/10.3906/tar-1903-40 XIANG, B.; WIELGOSZ, M.; KONTOGIANNI, T.; PETERS, T.; PULITI, S.; ASTRUP, R.; SCHINDLER, K.; 2024. Automated forest inventory: Analysis of high-density airborne LiDAR point clouds with 3D deep learning. Remote Sensing of Environment, 305, 114078. https://doi.org/10.1016/j.rse.2024.114078