



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

**9º CONGRESO FORESTAL ESPAÑOL**

**9CFE-1468**

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

Organiza





## Análisis de técnicas para la detección de árboles individuales mediante LiDAR aerotransportado (ALS)

RODRÍGUEZ VIVANCOS, A. (1, 2), MANZANERA DE LA VEGA, J. (2) y MARTÍNEZ SANZ, F. (1)

(1) Grupo Sylvestris SL

(2) Grupo de investigación SILVANET: Tecnologías y Métodos para la Gestión Sostenible. ETS de Ingeniería de Montes, Forestal y del Medio Natural. Universidad Politécnica de Madrid.

### Resumen

Este estudio evalúa distintas técnicas de Detección de Árbol Individual (ITD) a partir de datos LiDAR aerotransportado (ALS) para mejorar la precisión en la identificación de árboles a escala de rodal.

Por un lado, se evalúa la segmentación de cuencas en modelos digitales de altura de vegetación (CHM), primero desarrollando un proceso con el programa de información geográfica ESRI ArcMAP y después empleando el algoritmo “TreeSeg” del software FUSION/LDV. Además, se examina la influencia de parámetros clave como el suavizado (diferentes radios de kernel) y la resolución de los rásteres (0,2 m y 0,5 m). A continuación, se realiza la detección de árboles directamente en la nube de puntos LiDAR utilizando el paquete de herramientas “lidR” en RStudio.

Los resultados muestran que la segmentación por cuencas en ArcMAP superó al método en FUSION, aunque ambos fallan en la detección de árboles dominados. Sin embargo, la clasificación en la nube de puntos identificó algunos de estos árboles y produjo estimaciones tan precisas como las técnicas de CHM. En cuanto a la resolución, los CHM de 0,5 m combinados con un suavizado de radio 3 (K3) proporcionaron mejores resultados, mientras que los CHM de 0,2 m requirieron un mayor suavizado (K7).

### Palabras clave

Inventario forestal, teledetección, sensores remotos, segmentación de cuencas, modelo digital de elevaciones, kernel.

### 1. Introducción

La superficie forestal mundial ocupa 4,06 billones de hectáreas, lo que representa un tercio de la superficie total de la tierra (FAO & UNEP, 2020). Estos ecosistemas producen multitud de recursos naturales, tanto maderables como no maderables (resina, piñones, corcho, etc). Además, almacenan carbono, reducen la erosión, regulan los ciclos hidrológicos, son el hogar de numerosas especies de flora y fauna y ofrecen recreo a la sociedad. Asegurar el desarrollo sostenible de los bosques es una tarea esencial, que comienza con conocer la situación actual de los mismos, sus características y su estructura, así como su evolución y desarrollo (Rodrigues de Souza et al., 2014).

La medición de las masas forestales se ha realizado de manera histórica mediante inventarios de campo, en los que, generalmente, se toma una muestra representativa de toda la superficie. En cada una de las unidades de muestreo, también conocidas como parcelas de muestreo, se toman mediciones individuales,



como altura de los árboles y diámetros normales (o a la altura del pecho; DAP – 1,3 metros sobre el suelo). Finalmente, se calculan las variables dasométricas representativas de la masa forestal, como el volumen maderable, la biomasa total o el área basimétrica, necesarias para planificar las actuaciones de gestión forestal.

Este tipo de inventarios asume un error de muestreo, que es mayor o menor en función de la confianza que se quiere asumir. En ciertas ocasiones, se requiere una precisión muy elevada, lo que demanda un trabajo de campo muy exigente o incluso inabordable. Por ello, es necesario encontrar nuevas alternativas a los inventarios de campo clásicos, y es aquí donde la tecnología juega un papel muy importante.

Los sensores pasivos, como imágenes aéreas o satelitales, fueron pioneros en la teledetección aplicada al sector forestal (McRoberts & Tomppo, 2007). Sin embargo, estos tenían importantes limitaciones, especialmente a la hora de cuantificar variables dasométricas, debido a su escala bidimensional. Además, dependen de las condiciones atmosféricas, lo que dificulta la captura de información en condiciones adversas (baja luminosidad, nubes, etc.).

El LiDAR (Light Detection and Ranging) forma parte de los sensores activos. Es decir, son emisores de su propia energía para el desempeño de su función, lo que reduce la dependencia de factores externos. Esta tecnología está basada en la emisión de pulsos láser que alcanzan la superficie y retornan, siendo detectados por el sensor. Si el sensor LiDAR es de tipo discreto, se genera una nube de puntos espacial que representa a los objetos escaneados (vegetación, construcciones, terreno, etc). Las coordenadas de cada punto se calculan a partir de: (1) las coordenadas del emisor LiDAR en cada momento; (2) el ángulo de emisión gracias a la unidad inercial del emisor (INS); (3) el tiempo que cada láser tarda en alcanzar un objeto y retornar al sensor. Por otro lado, los LiDAR de onda continua recolectan la variación de la energía a lo largo del viaje del láser.

Uno de los parámetros más característicos de los productos LiDAR es la densidad de retornos. Esta densidad será mayor o menor en función de diferentes parámetros, como la frecuencia de la emisión de pulsos láser. Por otro lado, la cercanía al objeto de escaneo repercute en la fuerza del láser para penetrar en los objetos (por ejemplo la vegetación) y con ello en la intersección con más o menos objetos, como ramas, arbustos, etc.

En la actualidad, existen dos metodologías contrastadas para la evaluación de parámetros forestales mediante LiDAR (Hyypä et al., 2008). En primer lugar, los métodos de masa (Area Based Approach; ABA) se basan en el estudio de pequeñas porciones del terreno en las que se relacionan estadísticas de la nube de puntos (percentiles, densidades o dispersiones) con variables dasométricas medidas in-situ (volumen, altura media, área basimétrica, entre otras) mediante regresiones estadísticas. Por otro lado, la detección de árboles individuales (Individual Tree Detection; ITD) consiste en la localización y delimitación de cada uno de los árboles y el cálculo directo de sus parámetros biofísicos, como la altura total o el tamaño de copa. A partir de estas mediciones, se puede inferir otras variables con ecuaciones alométricas o modelos de regresión, como el DAP, el área basimétrica o el volumen. La agregación de los parámetros individuales genera la información a nivel de masa. En contraste con los primeros, ITD requiere una densidad de retornos mayor, al menos 4-5 retornos·m<sup>-2</sup> (Reutebuch & Andersen, 2005; Wulder et al., 2008).



Se ha demostrado que el método ABA es un método fiable para evaluar ecosistemas (Hinsley et al., 2006) y cuantificar el riesgo de incendios (Andersen et al., 2005). Por otro lado, se han conseguido buenas estimaciones de variables dasométricas con LiDAR. Por ejemplo, la fracción de cubierta, el volumen y la biomasa a nivel de rodal (Means et al., 2000, Naesset 2002). Sin embargo, otras variables de la estructura forestal no están bien correlacionadas con LiDAR, como la densidad de arbolado o el área basimétrica (Treitz et al., 2012; Mauro et al., 2013). Una posible razón de este fenómeno radica en los árboles más pequeños, que llegan a representar un porcentaje elevado en algunas parcelas de muestreo. La extracción de árboles individuales es una solución para estos casos, ya que los parámetros de árbol se calculan directamente sobre la nube de puntos, y las que no, es posible estimarlas gracias a la buena relación entre las variables morfológicas del árbol (Kalliovirta & Tokola, 2005).

Los inventarios forestales ITD han sido desarrollados atendiendo a dos clasificaciones principales. En primer lugar, empleando el método de segmentación de cuencas transformando la nube de puntos LiDAR en un modelo de copas (CHM). Este es un producto ráster que representa la diferencia en altura entre la capa superficial de los objetos (en este caso la cubierta vegetal) y el suelo. De este modo, la copa de cada árbol individual puede considerarse como una pequeña “cuenca hidrográfica” empleando la capa invertida (Hyypä & Inkinen, 1999; Chen et al., 2006). La dificultad radica en la irregularidad de la copa, ya que posee múltiples puntos máximos que pueden distorsionar la delimitación de individuos, especialmente las frondosas (Panagiotidis et al., 2017). Para ello, se analiza la vecindad, a modo de distancias de influencia (o kernel), de modo que solo puede haber un punto máximo local que represente un individuo, lo que depende tanto de la especie como de la densidad de arbolado. Por otro lado, los métodos de clasificación directa aplican diferentes algoritmos para identificar cada árbol en la nube de puntos LiDAR. Algunos de ellos se basan en la segmentación de cuencas, sin necesidad de generar el CHM (Lee et al., 2010). Otros, por ejemplo, utilizan la distancia natural entre los árboles, alegando que, incluso en los árboles más cercanos, hay una separación entre sus puntos máximos (Li et al., 2012).

Históricamente ha habido resultados exitosos aplicando ITD para evaluación forestal en la bibliografía. Por ejemplo, Persson et al. (2002) emplearon ALS de alta densidad para detectar árboles individuales, validando los resultados con mediciones de campo. Detectaron el 71% de los árboles, siendo la mayoría de los no detectados árboles pequeños. Tras la extracción, estimaron el DAP modelando la altura y el diámetro de la copa, obteniendo un error cuadrático medio (RMSE) de 3,8 cm para el DAP estimado. Posteriormente, se estimó el volumen total del fuste, detectando el 91% del mismo. Por su parte, Koch et al. (2006) aplicaron una Segmentación de Cuencas Invertida (IWS) para detectar las copas de los árboles utilizando el CHM y obtuvieron mejores resultados con coníferas que con frondosas. Además, localizaron la posición de cada árbol, aunque sobreestimaron el área de las copas. Propusieron el uso de LiDAR de onda completa para mejorar los resultados. Yao et al. (2012) detectaron el 95% de los árboles utilizando ITD.

## 2. Objetivos

El principal objetivo de este estudio es comparar diferentes técnicas ITD y evaluar su potencial para extraer árboles individuales de nube de puntos ALS.



Por un lado, segmentación de cuencas a partir del CHM en ArcMAP (MET-1) y mediante el algoritmo “TreeSeg” del software FUSION (MET-2). Además, se evalúa la influencia en los resultados de la resolución de los CHM (0,2 m y 0,5 m) y del suavizado de los mismos (diferentes radios de kernel).

Después, se analiza la delimitación directamente en la nube de puntos de acuerdo con la metodología desarrollada por Li et al. (2012), utilizando el paquete de herramientas “lidR” en RStudio (MET-3).

### 3. Metodología

Se analizan dos parcelas rectangulares (40x60 metros; localizándose el lado más largo en curva de nivel) instaladas en Cercedilla, a 60 km al noroeste de Madrid. Concretamente en el valle de la Fuenfría, un entorno montañoso enclavado en la cordillera del Sistema Central, caracterizado por masas irregulares monoespecíficas de pino silvestre (*Pinus sylvestris*), con acompañamiento de otras especies como el rebollo (*Quercus pyrenaica*). El monte donde se encuentran las parcelas está catalogado como Monte de Utilidad Pública (MUP nº 32 – Pinar y Agregados), con una superficie total de 2.520 ha.

Las parcelas se encuentran a una altura media de 1.408 y 1.470 metros sobre el nivel del mar y tienen unas pendientes medias de 23 y 25 grados respectivamente. Estas fueron geoposicionadas utilizando una estación total Nikon DTM 330 a partir de una poligonal que se inició en áreas abiertas tomando las coordenadas con un receptor GPS Trimble Geoexplorer 3. A continuación, se midieron todos los diámetros normales (DAP) de los árboles inventariables (DAP > 7,5 cm) con ayuda de una forcípula Häglof Mantax y realizando dos mediciones transversales (una en línea de máxima pendiente y otra paralela a curva de nivel). Además, se midió la altura total de todos los individuos utilizando un hipsómetro Häglof Vertex III. Este inventario de campo se realizó en 2015. Por otro lado, la zona se sobrevoló con un vuelo LiDAR en 2011, con una densidad media de 24 retornos•m<sup>-2</sup>. Para ello, se empleó un sensor Leica ALS70-HP sobre un área total de 220 ha, realizando un total de 7 pasadas, dos de ellas transversales.

El procesamiento de la nube de puntos LiDAR, ya depurada y corregida se realizó utilizando el paquete de herramientas “lidR” en RStudio. En primer lugar, se extrajeron los retornos correspondientes a cada una de las parcelas de estudio utilizando la herramienta “clip”. Para ello, la capa vectorial de las parcelas, en formato shapefile (.shp) se utilizó como marco de corte de la nube de puntos. A continuación, se clasificaron los puntos del terreno con la herramienta “Classify\_ground” y el algoritmo “csf” basado en la disposición de una tela sobre la nube invertida (Zhang, et al., 2016). Posteriormente, se normalizaron las nubes de puntos con la herramienta “normalize\_height” y la función “TIN”, de modo que los puntos del terreno tenían cota cero, mientras que el resto de las cotas representaban la altura sobre el suelo de cada retorno. Finalmente, se transformaron estas nubes de puntos a CHM utilizando “grid\_canopy” y el algoritmo “dsmtin”, con resoluciones de 0,2 y 0,5 m. Este algoritmo suaviza el resultado, ya que realiza una triangulación sobre los primeros retornos, al contrario que otros algoritmos que utilizan el punto de cota máxima en cada pixel. De esta manera se eliminan algunas irregularidades de la nube de puntos. Adicionalmente, se empleó la herramienta “Filter” en ArcMAP, para rellenar aquellas celdas vacías (sin dato) que pudiera haber debido a la densidad de retornos, con mayor frecuencia a mayor resolución de CHM (0,2 m de pixel), y se



generaron dos capas nuevas. Una diferenciando el suelo (incluida la regeneración pequeña y el matorral;  $h < 3,5$  m), con valor 0, del vuelo ( $h > 3,5$  m), con valor 1 (capa suelo-vuelo). Y otra sin datos de suelo, solo con los píxeles de vegetación y su cota real (capa vuelo).

Dado que la copa de los árboles es irregular, la detección de los árboles por el método de cuencas precisa suavizar los CHM obtenidos anteriormente. En este estudio se consideraron diferentes radios de suavizado (distancias kernel), de modo que el valor de cada pixel fue sustituido por el valor promedio de sus vecinos. Para esto se utilizó de nuevo la herramienta “Filter” de ArcMAP y 4 distancias kernel (Figura 1): 0, 1, 3 y 7 celdas (o píxeles).

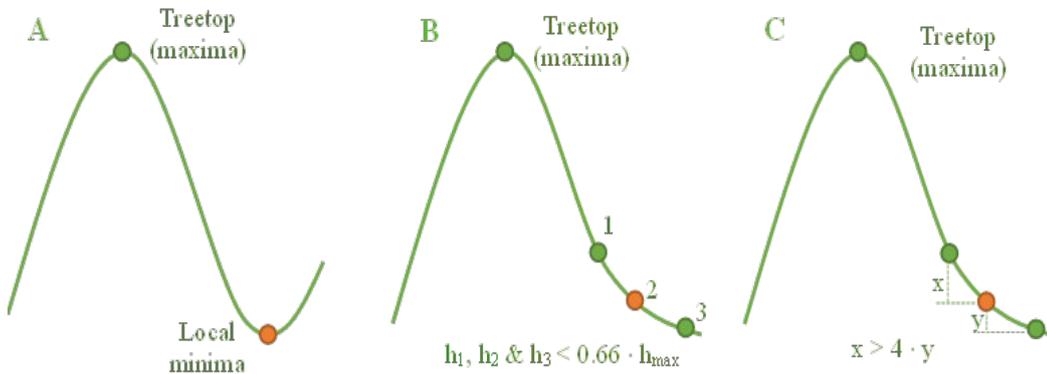
El primer método ITD analizado (MET-1) se inspiró en la metodología desarrollada por Panagiotidis et al. (2017). En esta, se localiza primero la posición de cada árbol y después se delimitan las copas. Sin embargo, haciendo eso, se producían delineaciones parciales de copa debido a su irregularidad. La metodología propuesta invirtió el orden del procesamiento, realizando primero la delimitación de las copas (paso 1) y después buscando el punto de máxima altura para cada árbol detectado (paso 2). Este proceso se automatizó parcialmente con la herramienta “Model Builder” de ArcMap.

El paso 1 desarrolló los siguiente pasos cronológicos: (1) suavizado del CHM considerando los distintos kernel definidos con la herramienta “Focal statistics”; (2) corrección de las celdas de suelo multiplicando con la herramienta “Times” los CHM suavizados (1) por la capa “suelo-vuelo”, ya que cuanto mayor fuese el suavizado (kernel) mayor sobredimensión adquirirían las copas de los árboles; (3) eliminación de las celdas de suelo seleccionando aquellas con valor superior a 0, usando la herramienta “Con”; (4) inversión de las celdas restantes de nuevo con la herramienta “Times”, esta vez multiplicando por (-1). De esta manera cada copa era una subcuenca; (5) cálculo de la dirección de flujo con “Flow direction” y después la delimitación de cuencas con “Basin”; (6) transformación de las cuencas a capa vectorial “.shp” con “Raster to polygon” y cálculo del tamaño de copa en la tabla de atributos. De manera manual se corregían ciertos errores de procesamiento. Por ejemplo, se estableció un umbral de  $2 \text{ m}^2$ , por debajo del cual, se consideraba ruido del procesamiento. Estos polígonos se juntaban con su vecino de mayor superficie si existía contacto, usando la herramienta “Eliminate polygon” de ArcMap. Por otro lado, los polígonos aislados fueron eliminados manualmente. Finalmente, para mejores resultados visuales, se suavizó el perímetro de las copas usando la herramienta “Smooth polygon” y el algoritmo “PAEK” con tolerancia de 4 metros.

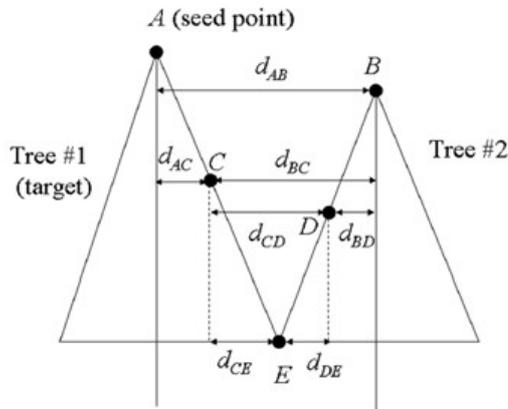
El paso 2 se desarrolló también con “Model Builder” en ArcMap. Para ello, empleando la herramienta “Zonal statistics” se busca el máximo zonal de la capa vuelo en cada uno de los polígonos delimitado en el paso 1. A continuación, se buscaban los puntos de máxima altura dividiendo (herramienta “Divide”) esta capa ráster con la capa vuelo, siendo esto los que tenían valor 1. Finalmente, se extrajeron estos puntos usando “Con” y se transformaron a vectorial con “Raster to polygon”.

La segunda metodología (MET-2) utilizó la herramienta “TreeSeg” del software “FUSION/LDV” que procesa dos veces los CHM para la delimitación de copas. En el primer procesamiento desarrolla la segmentación de cuencas, invirtiendo los CHM de igual modo que el proceso de ArcMap. Después, utiliza cada punto máximo zonal como centro de 18 radios homogéneamente espaciados. En cada uno de ellos,

analiza 3 criterios para definir el límite de la copa, tal como se muestra en la figura 2 (McGaughey, 2024).



La tercera metodología (MET-3) procesó directamente la nube de puntos LiDAR para la delimitación de árboles, utilizando la herramienta “segment\_trees” del paquete “lidR” en RStudio. El algoritmo empleado fue el desarrollado por Li et al. (2012), basado en la distancia natural entre los árboles para la clasificación de la nube de puntos (Figura 3). De este modo, la clasificación comienza en los puntos más elevados y continúa incluyendo puntos evaluando la distancia relativa entre los árboles vecinos. En estos procesos se utilizaron las nubes de puntos normalizadas sin puntos de suelo.



En las parcelas de muestreo se conocía la altura y el DAP de cada uno de los individuos, pero no su posición, por lo que no se pudo validar los análisis comparando los valores reales y estimados individualmente. De manera alternativa, se evaluó la distribución de alturas reales y estimadas en cada escenario analizado. Para ello, se clasificaron las alturas en rangos de 2 metros. Así mismo, se consideró vegetación baja aquellos árboles inferiores a 16 metros y vegetación alta al resto, para analizar la bondad de la detección en árboles dominados o de regeneración.

En primer lugar, se calcularon las raíces de los errores medios cuadráticos (RMSE) tanto en valor absoluto (Fórmula 1) como relativo (Fórmula 2). Sin embargo, había rangos con predicciones pero sin valores reales y viceversa, lo que hace sobredimensionar en exceso este error. Para ello, se ejecutó, adicionalmente, el test de “Kolmogorov-Smirnov” (KS test), que compara si hay diferencias

significativas entre dos series de datos evaluando la distancia máxima entre la función de distribución acumulativa experimental y la función de distribución acumulativa estimada (Fórmula 3; Figura 4). Se utilizó el p-valor del KS test para evaluar la similitud entre ambas distribuciones, de modo que un p-valor cercano a 1 indicaba una menor distancia entre distribuciones y, por lo tanto, una mayor similitud entre los valores observados y predichos.

$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (S_i - O_i)^2}$	[1]
$nRMSE = \frac{RMSE}{\frac{1}{n} \sum_{i=1}^n O_i^2}$	[2]
$D = \max  F_1 - F_2 $	[3]

Siendo, RMSE la raíz del Error Medio Cuadrático, nRMSE la raíz del Error Medio Cuadrático relativo, S los valores observados, O los valores estimados, n el número de observaciones, F1 la distribución experimental y F2 la distribución estimada.

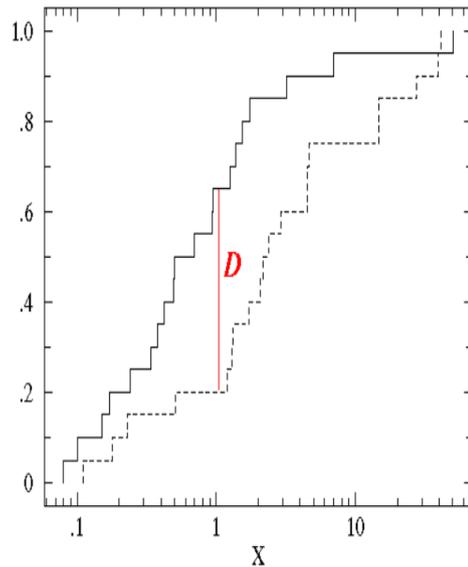
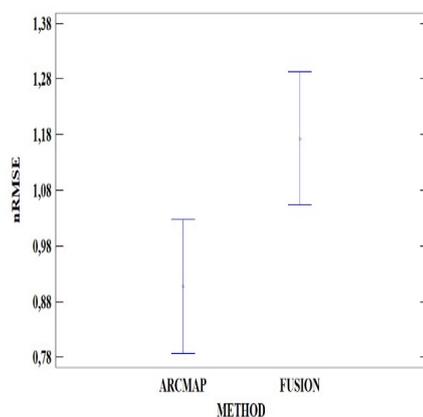


Figura 4. Fundamento del KS test. La línea roja representa la discrepancia máxima entre ambas funciones (experimental y estimada).

Finalmente se realizó una prueba de análisis de varianza (ANOVA) para evaluar el efecto de los diferentes parámetros (distancia del kernel para suavizado, resolución del CHM y metodología) en la estimación. Se consideró un nivel de confianza del 95% para determinar la significación.

#### 4. Resultados

En primer lugar, las metodologías basadas en la segmentación de cuencas (MET-1 y MET-2) fueron simples de aplicar, aunque con algunas diferencias. Por un lado, MET-1 estuvo diseñada para realizar una segmentación de cuencas, mientras que MET-2 aplicaba un segundo procesamiento para delimitar el perímetro de las copas (Figura 2). De esta manera, con un nivel de confianza del 95%, los errores (nRMSE) producidos por MET-1 fueron significativamente inferiores a los generados por MET-2 (ANOVA p-valor = 0,0298 < 0,05). En general, se apreció una mejoría aproximada de un 20% al usar MET-1 en comparación con MET-2 (Figura 5).



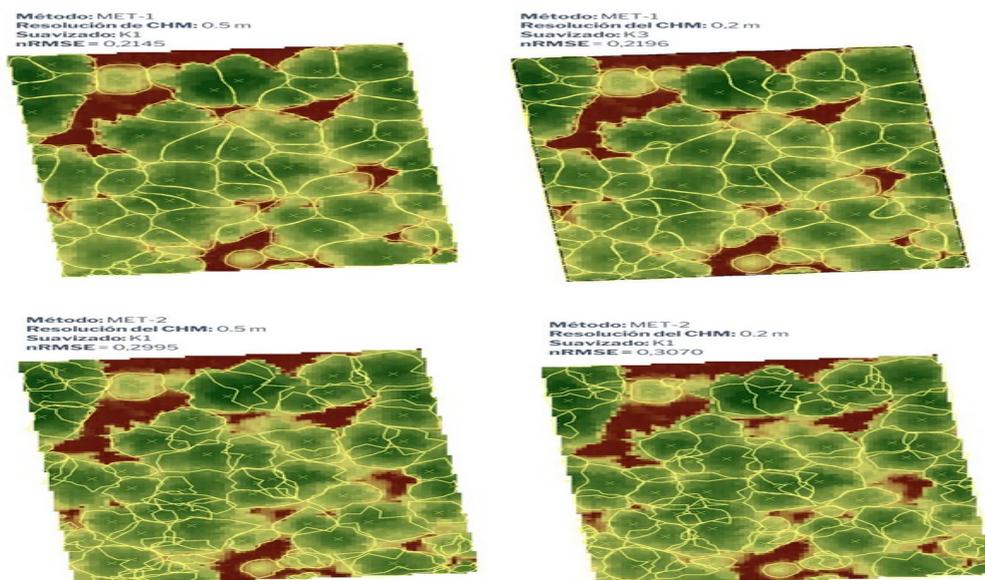
Los resultados anteriores hacen referencia a la detección de árboles, pero no a la delineación de sus copas. Además de mostrar los mejores resultados en la detección de árboles individuales, MET-1, también promovió resultados más

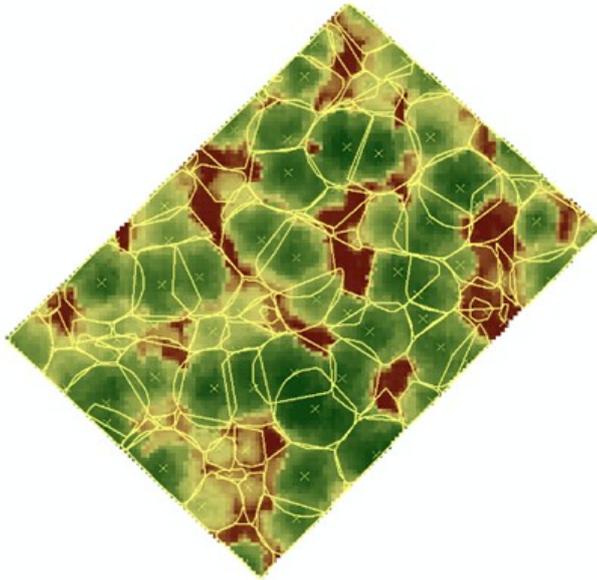
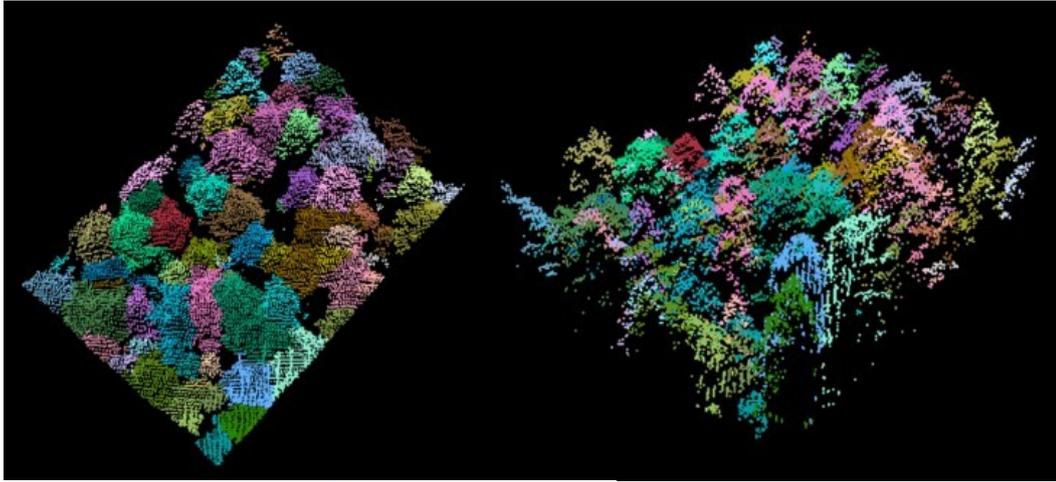
realistas en la delineación de las copas de los árboles, entendiéndose realistas como formas más naturales, sin tanto solapamiento de estas y más suavizadas, tal como se aprecia en la figura 6.

Por otro lado, el algoritmo desarrollado por Li et al. (2012), produjo una clasificación directa de los árboles directamente en la nube de puntos LiDAR (MET-3). Esta clasificación fue menos laboriosa que la aplicación de la segmentación de cuencas (MET-1 y MET-2), ya que trabaja directamente sobre la nube de puntos. Los errores (nRMSE) producidos usando MET-3 fueron similares a los generados por las otras dos metodologías, incluso mejores como en el caso de la parcela F1, en la que el nRMSE fue superior en MET-2 que en MET-3. En el resto de los casos, MET-1 produjo menos error que las otras dos metodologías (Tabla 1). Sin embargo, las diferencias entre MET-1 y MET-2 fueron inferiores al 10% de error (0,07 para F1 y 0,09 para F2). MET-3 produjo también buena delimitación de copas, tanto en la delimitación tridimensional (Figura 5), como bidimensional (Figura 6). A pesar de que se aprecia cierto solapamiento, este es inferior a los producidos mediante MET-2 (Figuras 7 y 8).

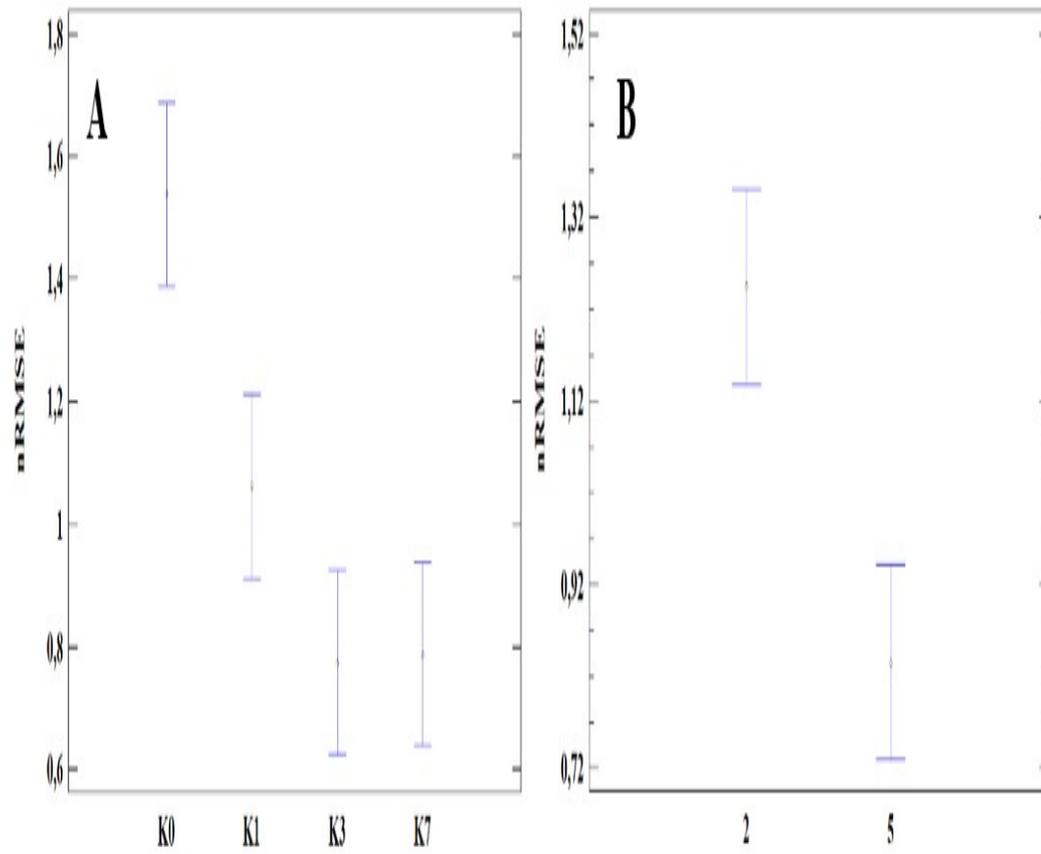
*Tabla 1. Errores (nRMSE) producidos en cada parcela de estudio considerando las tres metodologías propuestas. En MET-1 y MET-2 se ha considerado la mejor combinación kernel-resolución (entre paréntesis).*

Parámetro	F1	F2
MET-1	0,17 (k3 - 0,5m)	0,21 (k1 - 0,5m)
MET-2	0,34 (k1 - 0,5m)	0,29 (k1 - 0,5m)
MET-3	0,24	0,31

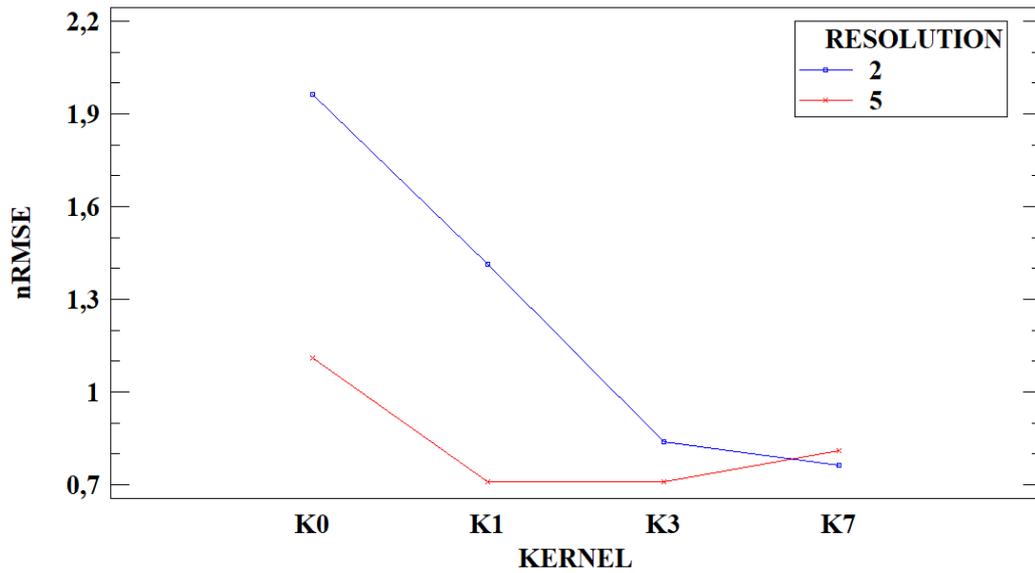




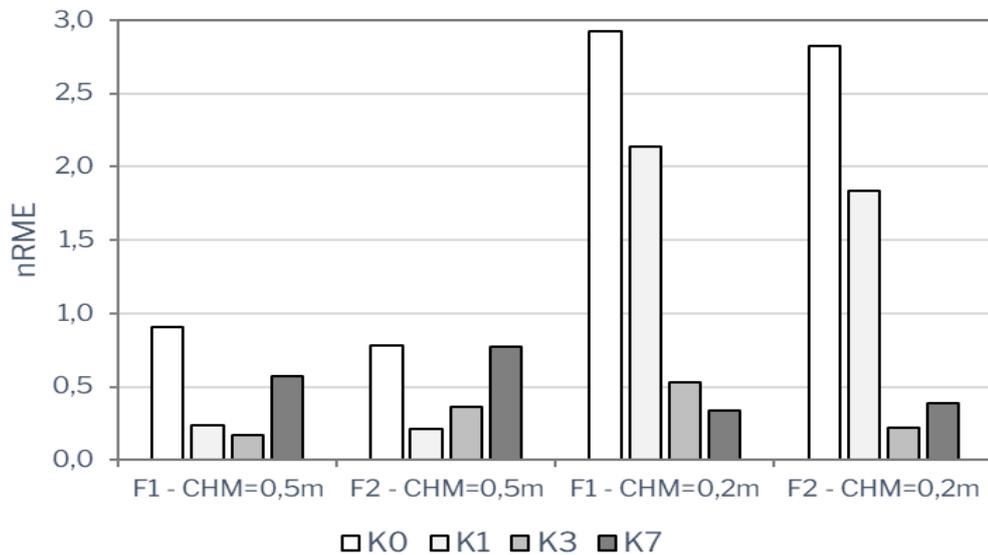
Los análisis ANOVA confirmaron que la resolución del CHM (ANOVA p-valor = 0) y el radio de suavizado (kernel) tuvieron influencia significativa. De manera general, se observó una mejoría en la detección de arbolado a medida que el suavizado del CHM era mayor (Figura 9.A), aunque no hubo diferencias significativas entre K1, K3 y K7. Sin embargo, el suavizado de las capas si mejoró significativamente los resultados (K0 vs K1, K3 y K7). Por otro lado, los CHM con 0,5 m de resolución produjeron resultados (nRMSE = 0,83) significativamente mejores que con 0,2 m (nRSME = 1,24 m). Es decir, se vio una mejoría general del 41% en la ITD disminuyendo la resolución ráster (Figura 9.B).



De manera general, no se encontraron diferencias significativas entre las parcelas de muestreo (ANOVA p-valor = 0,15), ni en las interacciones “parcelas-suavizado” (ANOVA p-valor = 0,95) y “parcelas-resolución” (ANOVA p-valor = 0,85). Sin embargo, la interacción “resolución-suavizado” sí produjo diferencias significativas en la ITD (Figura 10). En el caso de los CHM de 0,5 m de resolución, la detección de arbolado individual se obtuvo tras los suavizados K1 y K3 (nRMSE = 0,71), ligeramente mejores que con K7 (nRMSE = 0,81) y significativamente mejor que sin suavizado (nRMSE = 1,11). Por otro lado, un suavizado de 7 celdas (K7) fue el más apropiado al trabajar un CHM de 0,2 m de resolución (nRMSE = 0,76). Es destacable que, salvo en el caso del suavizado K7, el CHM de 0,5 m de resolución produjo mejores resultados que el de 0,2 m (Figura 10), en concordancia con la figura 9.B.



A modo individual, se comprobó que la parcela F2 requirió un menor radio de suavizado que la parcela F1 (Figura 11). Si comparamos los mejores resultados en MET-1 para ambas parcelas, la parcela F1 precisó un suavizado de 3 celdas de radio (K3) en el CHM de 0,5 metros (nRME = 0,17), mientras que para ese mismo CHM, la parcela F2 requirió un suavizado de 1 celda de radio (K1) (nRME = 0,21). Por otro lado, para un CHM de 0,2 metros, la parcela F1 obtuvo mejor resultado con un suavizado de 7 celdas de radio (nRME = 0,33), mientras que la parcela F2 lo consiguió con un suavizado de 3 celdas (nRME = 0,22).



La clasificación en altura de la vegetación (alta y baja) permitió evaluar la precisión de la detección tanto de la vegetación dominante como de la dominada. Por un lado, los p-valores obtenidos en ambas parcelas para la distribución de árboles dominantes fueron próximos a 1, lo que significa que la distribución estimada fue muy similar a la medida en campo. Por otro lado, los p-valores obtenidos en el caso de la vegetación baja fueron inferiores a 0,2, lo que indicó un peor ajuste entre las distribuciones. La parcela F1 tenía un total de 125 árboles dominados (vegetación baja), lo que se correspondía con un 72% del total, mientras

que la parcela F2 tenía un total de 54 árboles dominados, un 42% del total. Considerando todos los casos de estudio (suavizado y resolución), los árboles dominados detectados fueron un pequeño porcentaje de la realidad (16% en F1 y 24% en F2) (Tabla 2).

Tabla 2. Vegetación alta y baja real y detectada en cada parcela de muestreo (F1 y F2). Se ha calculado el valor medio predicho considerando todos los casos de estudio.

Tipo de vegetación	Parámetro	F1	F2
Vegetación baja	Real	125	54
	Estimado	21	13
Vegetación alta	Real	49	74
	Estimado	57	71

## 5. Discusión

Bien conocido es el éxito de la tecnología LiDAR para la medición de árboles individuales mediante técnicas de ITD (por ejemplo en Jakubowski et al., 2013; Panagiotidis et al., 2017). Aunque estos buenos resultados están relacionados con masas forestales homogéneas, con árboles bien diferenciados (sin solapamiento de copas), como plantaciones forestales (Reitberger et al., 2007). En este estudio, se analiza la potencialidad de estas técnicas en masas más complejas, con alto porcentaje de árboles dominados.

En primer lugar, la detección de árboles individuales mediante segmentación de cuencas en MET-1 fue significativamente más precisa que en MET-2 (ANOVA p-valor = 0,0298; Figura 4), detectando aproximadamente un 20% más de árboles en la primera. A pesar de que los CHM eran los mismos en ambas metodologías, se ha comprobado que los criterios definidos en el algoritmo de procesamiento de “TreeSeg” de FUSION (Figura 2) han sido ineficaces para este caso de estudio. Es posible que el suavizado de las capas realizado para el rellenado de las celdas vacías haya sido la causa de estas diferencias. Además, este algoritmo es muy sensible a la resolución y el suavizado desarrollado en la producción del CHM, funcionando mejor en masas forestales abiertas (McGaughey, 2024).

De esta manera, la interacción “resolución – suavizado” fue significativa (Figura 10). En general, una mayor resolución del CHM (0,5 m), necesitó menor radio (en número de celdas) para el suavizado de la capa (Figura 10), aunque en distancia métrica, un radio de 3 celdas en un CHM de 0,5 m de resolución es similar (1,5 m) a un radio de 7 celdas en un CHM de 0,2 m de resolución (1,4 m). Sin embargo, la parcela F2 produjo mejores resultados con menor suavizado que en el caso de la parcela F1 (Figura 11). Una posible explicación es que la densidad de retornos en F2 fue superior (22,66 retornos·m<sup>-2</sup>) a la de la parcela F1 (11,84 retornos·m<sup>-2</sup>). Una mayor densidad de puntos reduce la distancia necesaria para detectar cada árbol, expresado por puntos máximos locales en la metodología de segmentación de cuencas (Picos et al., 2020). Esta distancia de detección es comparable con los radios de suavizado analizados en este estudio, ya que la parcela F2, con la mayor



densidad de retornos generó menos celdas vacías (sin dato) en CHM de mayor resolución (0,2 m) que la parcela F1 y requirió menos radio de suavizado. Además, al haber menos celdas vacías, el suavizado de las capas redujo la subestimación de la altura de los árboles, algo que se manifestó en un menor error en la detección en la parcela F2 (nRME=0,22), con mayor densidad de puntos, en comparación con la parcela F1 (nRME = 0,34), considerando únicamente el CHM de 0,2 m de resolución.

Otro parámetro que tuvo influencia en la ITD fue el espaciamiento entre los árboles, y por tanto la densidad. En masas abiertas, es más fácil aislar cada individuo (Picos et al., 2020). En este estudio, la parcela F1 tenía mayor densidad que la parcela F2, si se contasen los árboles dominados. Aunque considerando únicamente lo dominantes, la densidad fue de 204,16 pies/ha, menor que en la parcela F2 (308,33 pies/ha). Esto resultó en una mejor detección en F1 (nRME = 0,17) en comparación con F2 (nRME = 0,21), como refleja la tabla 1.

Por otro lado, la detección de árboles dominados con MET-3 fue similar a las otras dos metodologías basadas en segmentación de CHM, a pesar de que, en este estudio, se emplearon los parámetros predefinidos para el desempeño del algoritmo. De este modo, la clasificación directa de la nube de puntos demuestra un alto potencial, especialmente en casos con alta densidad de retornos, aprovechando la naturaleza tridimensional de la capa (Li et al., 2012), en comparación con su transformación bidimensional a CHM, que puede ir acumulando varios errores de procesamiento (Guo et al., 2007).

A pesar de los buenos resultados, se ha comprobado que los árboles dominados no han sido correctamente detectados en ninguna de las metodologías propuestas, tal como demuestran estudios anteriores, en las cuales, se detectó un porcentaje muy bajo de árboles dominados (Reitberger et al., 2007; Jakubowski et al., 2013). Por un lado, la ITD mediante segmentación de CHM fue ineficaz sobre el estrato dominado. La explicación recae en la propia definición de CHM, en el que cada celda del ráster está influenciada por los puntos más elevados del LiDAR, despreciando el resto. Por otro lado, a pesar de que la densidad de puntos pertenecientes a la vegetación baja es inferior a la de las capas superiores se produjeron nRMSE similares al utilizar la clasificación ITD sobre la nube LiDAR directamente en comparación con el mejor resultado de segmentación de CHM (0,83 vs 0,82 en F1; nRMSE = 1,09 vs 1,11 en F2). La ventaja de procesar directamente la nube de puntos es que la información correspondiente a la vegetación baja se mantiene, mientras que en la transformación ráster se pierde. En contraposición, esta densidad de puntos es baja, por lo que la detección de arbolado es imprecisa.

## 6. Conclusiones

La ITD extrae información de alta resolución, a escala árbol individual, que permite realizar la medición directa de sus parámetros biofísicos, como la altura o la superficie de copa. Sin embargo, en masas irregulares, con alto porcentaje de árboles dominados los resultados son imprecisos.

La segmentación de CHM requiere capas de alta calidad, lo que está relacionado con la densidad de puntos LiDAR. Una mayor densidad de puntos permitió obtener mejores resultados en mayores resoluciones (CHM = 0,2 m), aunque la resolución ideal fue de 0,5 metros. En general, esta metodología produjo buenos resultados en



la detección de árboles individuales, especialmente en MET-1, pero no fue eficaz para detectar árboles dominados. Tampoco lo fue en este propósito la clasificación directa de la nube de puntos (MET-3), pero demostró ser una metodología con gran potencial, ya que redujo etapas de procesamiento causantes de arrastrar errores encadenados.

Además de trabajar en la detección de arbolado dominado, se cree que incrementar la densidad de puntos LiDAR mejoraría sensiblemente los resultados obtenidos. Para este fin, se está desarrollando el procesamiento de tres parcelas de estudio en Caminomorisco (Cáceres), una zona que se sobrevoló con LiDAR aéreo a baja altura (dron). En estas parcelas, se aplicarán las tres metodologías propuestas, a modo de validación de sus resultados.

## 7. Agradecimientos

Se aprovecha este apartado para agradecer a la Universidad Politécnica de Madrid, especialmente al Grupo de investigación SILVANET (Tecnologías y Métodos para la Gestión Sostenible) de la ETS de Ingeniería de Montes, Forestal y del Medio Natural, por los datos cedidos para el desarrollo de este estudio. Además, agradecer a Grupo Sylvestris por la financiación de material y recursos humanos para la ampliación de este estudio en nuevas áreas de estudio.

## 8. Bibliografía

ANDERSEN, H. E.; MCGAUGHEY, R. J.; REUTEBUCH, S. E.; 2005. Estimating forest canopy fuel parameters using LIDAR data. *Remote Sens. Environ.* 94 441-449

CHEN, Q.; BALDOCCHI, D.; GONG, P.; KELLY, M.; 2006. Isolating individual trees in a savanna woodland using small footprint LIDAR data. *Photogramm. Eng. Remote Sens.* 72 923-932

FAO; UNEP; 2020. The State of the World's Forests 2020. Forests, biodiversity and people. 214. Rome.

GUO, Q.; KELLY, M.; GONG, P.; LIU, D.; 2007. An object-based classification approach in mapping tree mortality using high spatial resolution imagery. *GISci. Remote Sens.* 44 24-47

HINSLEY, S. A.; HILL, R. A.; BELLAMY, P. E.; BALZTER, H.; 2006. The Application of Lidar in Woodland Bird Ecology. *Photogramm. Eng. Remote Sens.* 72 1399-1406

HYYPPÄ, J.; INKINEN, M.; 1999. Detecting and estimating attributes for single trees using laser scanner. *Photogramm. J. Finl.* 16 27-42

HYYPPÄ, J.; HYYPPÄ, H.; LECKIE, D.; GOUGEON, F.; YU, X.; M. M.; 2008. Review of methods of small-footprint airborne laser scanning for extracting forest inventory data in boreal forests. *Int. J. Remote Sens.* 29 1339-1366

JAKUBOWSKI, M. K.; GUO, Q.; KELLY, M.; 2013. Tradeoffs between lidar pulse density and forest measurement accuracy. *Remote Sens. Environ.* 130 245-253

KALLIOVIRTA, J.; TOKOLA, T.; 2005. Functions for estimating stem diameter and tree age using tree height, crown width and existing stand database information. *Silva Fenn.* 39 227-248

KOCH, B.; HEYDER, U.; WEINACKER, H.; 2006. Detection of individual tree crowns in airborne lidar data. *Photogramm. Eng. Remote Sens.* 72 357-363



LEE, H.; SLATTON, K.; ROTH, B.; CROPPER, W.; 2010. Adaptive clustering of airborne LiDAR data to segment individual tree crowns in managed pine forests. *Int. J. Remote Sens.* 31 117-139

LI, W.; GUO, Q.; JAKUBOWSKI, M. K.; KELLY, M.; 2012. A new method for segmenting individual trees from the lidar point cloud. *Photogramm. Eng. Remote Sens.* 78 75-84

MAURO, F.; GARCÍA, D.; GARCÍA-ABRIL, A.; MARTIN-FERNANDEZ, S.; NÚÑEZ, M.; GONZÁLEZ, C.; AYUGA, E.; 2013. Reducción del número de parcelas de muestreo al incorporar información auxiliar LiDAR en la estimación de variables dasométricas. 6º Congreso Forestal Español. Montes: Servicios y desarrollo rural. 13. Vitoria-Gasteiz

MCGAUGHEY, R. J.; 2024. FUSION/LDV: Software for LIDAR data analysis and visualization. USDA, Forest Service. 226. Seattle.

MCRBERTS, R. E.; TOMPPA, E. O.; 2007. Remote sensing support for national forest inventories. *Remote Sens. Environ.* 110 412-419

MEANS, J. E.; ACKER, S. A.; FITT, B. J.; RENSLOW, M.; EMERSON, L.; HENDRIX, C. J.; 2000. Predicting forest stand characteristics with airborne scanning lidar. *Photogramm. Eng. Remote Sens.* 66 1367-1372

NÆSSET, E.; 2002. Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data. *Remote Sens. Environ.* 80 88-99

PANAGIOTIDIS, D.; ABDOLLAHNEJAD, A.; SUROVÝ, P.; CHITECULO, V.; 2017. Determining tree height and crown diameter from high-resolution UAV imagery. *Int. J. Remote Sens.* 38 2392-2410

PERSSON, A.; HOLMGREN, J.; SODERMAN, U.; 2002. Detecting and measuring individual trees using an airborne laser scanner. *Photogramm. Eng. Remote Sens.* 68 925-932

PICOS, J.; BASTOS, G.; MÍGUEZ, D.; ALONSO, L.; ARMESTO, J.; 2020. Individual tree detection in a eucalyptus plantation using unmanned aerial vehicle (UAV)-LiDAR. *Remote Sens.* 12 885

REITBERGER, J.; HEURICH, M.; KRZYSZEK, P.; STILLA, U.; 2007. Single tree detection in forest areas with high-density LiDAR data. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* 36 139-144

REUTEBUCH, S. E.; ANDERSEN, H. E.; 2005. Light Detection and Ranging (LIDAR): An Emerging Tool for Multiple Resource Inventory. *J. For.* 103 286-292

RODRIGUES DE SOUZA, C.; DE AZEVEDO, C.; BRUM ROSSI, L.; DOS SANTOS, J.; HIGUCHI, N.; 2014. Projection of diametric distribution and carbon stock of a managed forest in Manaus/AM. *Floresta* 44 525-534

TREITZ, P.; LIM, K.; WOODS, M.; PITT, D.; NESBITT, D.; ETHERIDGE, D.; 2012. LiDAR sampling density for forest resource inventories in Ontario, Canada. *Remote Sens.* 4 830-848

WULDER, M.; BATER, C.; COOPS, N.; HILKER, T.; WHITE, J.; 2008. The role of LiDAR in sustainable forest management. *For. Chron.* 84 807-826

YAO, W.; KRZYSZEK, P.; HEURICH, M.; 2012. Tree species classification and estimation of stem volume and DBH based on single tree extraction by exploiting



airborne full-waveform LiDAR data. *Remote Sens. Environ.* 123 368-380

ZHANG, W.; QI, J.; WAN, P.; WANG, H.; XIE, D.; WANG, X.; YAN, G.; 2016. An easy-to-use airborne LiDAR data filtering method based on cloth simulation. *Remote Sens.* 8 501