



9CFE-1194

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

Organiza





Uso de dispositivos LiDAR de corto alcance y enfoques de inferencia estadística en inventarios forestales operativos a escala de monte

MOLINA-VALERO, J. A. (1, 2), MARTINS-NETO, R. P. (1), MARTÍNEZ-CALVO, A. (3) RODRÍGUEZ-RUIZ, J. (3), SUROVÝ, P. (1), SEPPELT, A. (4), PÉREZ-CRUZADO, C. (3)

(1) Faculty of Forestry and Wood Sciences, Czech University of Life Sciences Prague, 165 00 Prague, Czech Republic.

(2) Faculty of Environmental Sciences, Czech University of Life Sciences Prague, 165 00 Prague, Czech Republic.

(3) Proyectos y Planificación (PROEPLA), Departamento de Producción Vegetal y Proyectos de Ingeniería, Escuela Politécnica Superior de Ingeniería, Universidade de Santiago de Compostela, Benigno Ledo s/n, Campus Terra, 27002 Lugo, Spain.

(4) Faculty of Biology, Albert-Ludwigs-University, Freiburg im Breisgau

Resumen

Los dispositivos LiDAR de corto alcance tienen un gran potencial para mejorar las estimaciones en inventarios forestales (IF), aunque su aplicación sigue siendo objeto de estudio, especialmente a escalas relativamente grandes. En este trabajo se investigó el uso del escáner láser terrestre (TLS) y sensores LiDAR aerotransportados en drones (UAV-LiDAR) como herramientas de medición para incrementar la eficiencia en las estimaciones a escala de monte. La investigación partió de la premisa de que los dispositivos LiDAR de corto alcance pueden proporcionar datos auxiliares accesibles que mejoran la precisión y reducen los errores en las estimaciones. Se evaluaron cuatro enfoques de inferencia estadística: estimador de expansión simple (EXP), inferencia asistida por modelos de regresión en dos etapas (REG), inferencia basada en modelos convencional (CMB), e inferencia basada en modelos jerárquicos en tres fases (3pHMB). Estos métodos utilizaron datos combinados de mediciones de campo, TLS y UAV-LiDAR. El estudio se realizó en una parcela experimental de 16 ha en el noroeste de España, dominada por *Pinus radiata* y *Pinus pinaster*, utilizando el volumen de madera a nivel de masa (V , $m^3 \text{ ha}^{-1}$) como variable objetivo. Los resultados mostraron que los dispositivos LiDAR de corto alcance, como fuentes de datos auxiliares, reducen los errores en las estimaciones de V en comparación con enfoques que usan solo una fuente de datos (EXP). Estos hallazgos destacan el potencial de estos dispositivos en los IF y su posible aplicación práctica para optimizar estos procesos.

Palabras clave

Métodos de masa, teledetección próxima terrestre, gestión forestal, monitorización forestal, muestreo estadístico.

1. Introducción

Los inventarios forestales (IF) han evolucionado significativamente gracias a constantes mejoras metodológicas impulsadas por la adopción de nuevas tecnologías. Este avance ha sido especialmente notable en las últimas décadas debido al desarrollo explosivo y a la mejora sustancial de las técnicas de teledetección (FASSNACHT et al., 2023; WHITE et al., 2016). Mientras que los métodos convencionales son costosos y requieren largas jornadas de campo, la



teledetección permite ampliar tanto la escala espacial como temporal en la monitorización de los bosques sin un incremento proporcional en los costos asociados (COOPS et al., 2023; KANGAS et al., 2018). En este contexto, los sistemas LiDAR (*Light Detection and Ranging*) generan nubes de puntos tridimensionales apropiadas para estimar atributos forestales útiles en diversas aplicaciones forestales, tales como el volumen maderero (V , $m^3 \text{ ha}^{-1}$) o la biomasa aérea (AGB, $Mg \text{ ha}^{-1}$) (WHITE et al., 2016; WULDER et al., 2012).

Entre los dispositivos LiDAR de corto alcance, los escáneres láser terrestres (TLS) y móviles (MLS) destacan por su alta precisión e idónea perspectiva para observar la vegetación cercana al suelo, la cual es de visibilidad más limitada con sistemas aerotransportados. Sin embargo, estos dispositivos aún a día de hoy siguen encontrando retos para su adopción de forma operativa, entre los cuales destacan las dificultades en la automatización del procesado de los datos. Como respuesta a este reto, varios estudios han señalado que una solución clave sería desarrollar soluciones software asequibles y fáciles de usar que permitan extraer información de los datos LiDAR de manera eficiente (LIANG et al., 2016, 2018; WHITE et al., 2016). Esto está cada vez más cerca de ser una realidad, ya que múltiples soluciones han sido desarrolladas y están a día de hoy siendo utilizadas en diferentes contextos forestales (MURTIYOSO et al., 2024). Sin embargo, a pesar de que estos dispositivos ofrecen estimaciones robustas de algunas variables (p.ej. el diámetro de los árboles), estas pueden estar sesgadas en árboles pequeños o en bosques con estructuras complejas (ABEGG et al., 2023; VATANDAŞLAR et al., 2023). Por todos estos motivos, cabría preguntarse si la operativización de estos dispositivos podría pasar por el propio diseño de inventario, incluyendo las fases de diseño muestral, observacional y estimacional. Por ejemplo, en MOLINA-VALERO et al. (2023) se demostró que el diseño de parcela (u observacional) es determinante para obtener estimaciones insesgadas con dispositivos TLS.

Para dar respuesta a estas preguntas, en este estudio se evaluó el potencial de los dispositivos LiDAR de corto alcance como instrumentos operativos en inventarios forestales a escala de monte, para lo cual se utilizaron cuatro metodologías de inferencia estadística y diferentes combinaciones de datos. Las metodologías de inferencia utilizadas fueron las siguientes: (i) estimador de expansión simple (EXP), tanto para datos de campo como de TLS; (ii) inferencia asistida por modelos de regresión en dos etapas (REG), combinando datos de campo y TLS; (iii) inferencia convencional basada en modelos (CMB), combinando datos de campo y UAV-LiDAR; e (iv) inferencia basada en modelos jerárquicos en tres fases (3pHMB), combinando datos de campo, TLS y UAV-LiDAR. El caso de estudio se llevó a cabo en una parcela experimental de 16 ha ubicada en la provincia de Lugo (Galicia), y dominada por las especies *Pinus radiata* D. Don y *Pinus pinaster* ssp. *atlantica* H. de Vill. Los resultados mostraron que los métodos que integran datos auxiliares (REG, CMB y 3pHMB) reducen significativamente los errores en las estimaciones de volumen en comparación con los métodos basados exclusivamente en datos de campo o TLS (EXP). Estos hallazgos destacan el gran potencial que tienen los dispositivos LiDAR de corto alcance en IFs. No obstante, su adopción a gran escala aún requiere superar desafíos técnicos, así como validar su uso en diversos contextos operativos.

2. Objetivos

El objetivo de este trabajo fue evaluar el potencial operativo de los dispositivos

LiDAR de corto alcance (TLS y UAV-LiDAR) en inventarios forestales a escala de monte en base a la robustez de las estimaciones. Para ello se analizaron diferentes metodologías de inferencia estadística (EXP, REG, CMB y 3pHMB) susceptibles de ser utilizadas con estos dispositivos, utilizando diversas combinaciones de datos de campo, TLS y UAV-LiDAR.

3. Metodología

Área de Estudio

El área de estudio está ubicada en un monte vecinal en mano común de la provincia de Lugo (Galicia), compuesto por una masa mixta de *Pinus radiata* (63%) y *Pinus pinaster* (19%), y con un 18% restante representado por *Quercus robur*, *Quercus pyrenaica*, *Castanea sativa* y *Betula* spp. El área de estudio tiene 16 ha (400×400 m) y está dividida en 400 celdas cuadradas de 20×20 m. En cada celda se establecieron parcelas circulares de 10 m de radio (314.16 m^2), las cuales constituyen la población objetivo de 400 unidades (NU). Todas las celdas fueron muestreadas mediante mediciones convencionales de campo, escaneos únicos de TLS y un barrido LiDAR aerotransportado en dron (Figura 1).




Figura 1. Área de estudio.

Datos

En 2021 se realizó un censo total del área de estudio, geolocalizando y midiendo todos los árboles con al menos 1.3 m de altura. Las posiciones de los árboles se

obtuvieron con un GPS Trimble R2 y un dispositivo láser TruPulse 360°R con precisiones de 0.1° y 0.1 m. Se midieron los diámetros a la altura del pecho (dbh) con una forcípula (precisión de 0.1 cm) y la altura total de los árboles con un hipsómetro digital (Vertex IV, Haglöf, precisión de 0.1 m). El volumen de los fustes se estimó utilizando modelos alométricos locales específicos para cada especie (DIÉGUEZ-ARANDA et al., 2009). El volumen por unidad de superficie (V) se estimó agregando los volúmenes de los árboles individuales y expandiéndolo a hectáreas como unidad de superficie, obteniendo un valor de referencia para la media poblacional de $254.42 \text{ m}^3 \text{ ha}^{-1}$ (μ). Los datos de LiDAR terrestre (o TLS) fueron tomados con un dispositivo FARO Laser Scanner Focus3D X 130 desde el centro de cada parcela y mediante escaneos únicos. Estos fueron procesados con el paquete de R FORTLS (MOLINA-VALERO et al., 2022), estimando variables dasométricas y métricas derivadas de las coordenadas de las nubes de puntos. También se tomaron datos LiDAR con un dispositivo Phoenix Aerial Scout-16 aerotransportado en un dron hexacóptero DJI S900, obteniendo una nube de puntos con una densidad promedio de 577 puntos m^{-2} . Los datos se usaron para calcular métricas LiDAR normalizadas a nivel de parcela utilizando los paquetes lidR (ROUSSEL et al., 2020) y lidRmetrics (TOMPALSKI, P. & GOODBODY, 2021) en R (R Core Team, 2023).

Métodos de Inferencia Estadística

En el estudio se evaluaron cuatro métodos de inferencia estadística: inferencia basada en el estimador de expansión simple (EXP), inferencia asistida por modelos de regresión en dos etapas (REG), inferencia basada en modelos convencional (CMB), e inferencia basada en modelos jerárquicos en tres fases (3pHMB).

Estimador de expansión simple (EXP)

Se basa en un muestreo aleatorio simple (MAS) sin reemplazamiento, donde la media poblacional se estima mediante la fórmula de la media aritmética:

$$\mu^{\text{EXP}} = \frac{1}{n} \sum_{i \in S} y_i \quad (1)$$

donde n es el número de observaciones en la muestra S , y_i es el valor de la variable de interés (V) para cada unidad de la muestra. Los datos utilizados incluyeron estimaciones de V obtenidas mediante modelos alométricos para los datos de campo; y datos de V estimados con el paquete de R FORTLS para los datos TLS. En este último caso, se obtuvieron estimaciones de V directas, así como corregidas por el efecto de las oclusiones.

Inferencia asistida por modelos de regresión (REG)

Las metodologías asistidas por modelos utilizan modelos basados en datos auxiliares para mejorar la inferencia, pero se basan en muestras probabilísticas para garantizar su validez (MCROBERTS et al., 2024). Esta consistió en aplicar un diseño de MAS en dos etapas, donde en una primera fase se obtuvieron datos auxiliares de teledetección (datos auxiliares de TLS en este caso), y en una submuestra de esta primera fase se obtuvieron además estimaciones de V basadas en los datos de campo. La relación entre la variable respuesta (y , estimaciones de V basadas en datos de campo) y las variables explicativas (x) se modela como:

$$y_i = f(x_i; \beta) + \epsilon_i \quad (2)$$

donde $f(x_i; \beta)$ representa la relación matemática entre las variables explicativas y los parámetros del modelo (β), y ϵ_i un error aleatorio $\epsilon_i \sim N(0, \sigma^2)$. La estimación de la

media poblacional se obtuvo mediante el estimador desarrollado en MCROBERTS et al. (2024):

$$\mu^{\text{reg}} = \frac{1}{n_1} \sum_{i \in S_1} y_i + \frac{1}{n_2} \sum_{i \in S_2} (y_i - \hat{y}_i) \quad (3)$$

donde $\hat{y}_i$ es la predicción del modelo, y_i es el valor de y obtenido en la segunda etapa, n_1 y n_2 representan los tamaños de muestra en las etapas 1 y 2, respectivamente.

Inferencia basada en modelos convencional (CMB)

El enfoque basado en modelos no requiere muestreo probabilístico, ya que está basado en el modelo representativo de la superpoblación que relaciona la media de cada unidad poblacional (μ_i) con variables explicativas (x , métricas de UAV-LiDAR en este caso) mediante un modelo matemático (Ecuación 2). La estimación de la media poblacional se realiza mediante el siguiente estimador:

$$\mu^{\text{CMB}} = \frac{1}{N} \sum_{i \in U} \hat{\mu}_i \quad (4)$$

donde $\hat{\mu}_i$ es la predicción del modelo para el parámetro poblacional de interés en la unidad i .

Inferencia basada en modelos jerárquicos en tres fases (3pHMB)

El enfoque 3pHMB amplía el enfoque CMB al usar múltiples fuentes de información auxiliar en lugar de una sola. Estas fuentes incluyen una primera fase donde los datos de UAV-LiDAR están disponibles para todos los elementos de la población. Una segunda fase perteneciente a una muestra (S_1) de parcelas medidas con TLS, que tienen tanto datos de UAV-LiDAR como de TLS. Y una tercera fase perteneciente a una submuestra (S_2) de S_1 con parcelas medidas con datos de campo convencionales, que combina UAV-LiDAR, TLS y estimaciones de y basadas en datos de campo. El enfoque se basa en el ajuste de dos modelos jerárquicos. Un primer modelo que relaciona μ_i (media de las unidades poblacionales) con variables explicativas de la segunda fase (x , datos de TLS), usando el $\hat{\mu}_i$ estimado con los datos de campo como variable respuesta. Y un segundo modelo que relaciona las predicciones del primer modelo con las variables explicativas de la primera fase (x , datos de UAV-LiDAR). Este segundo modelo se aplica para predecir el parámetro de interés en todos los elementos de la población, y así obtener el estimador 3pHMB de la media poblacional (Ecuación 5) desarrollado en SAARELA et al., (2023):

$$\mu^{\text{3pHMB}} = \frac{1}{N} \sum_{i \in U} \hat{\mu}_i^Z \quad (5)$$

donde $\hat{\mu}_i^Z$ es la predicción del modelo para cada unidad poblacional i . Un resumen de las metodologías de inferencia utilizadas se encuentra en la Figura 2.




Figura 2. Metodologías de inferencia estadística utilizadas. MAS: muestreo aleatorio simple.

Análisis

Se utilizaron simulaciones de Monte Carlo para evaluar el sesgo y el error estándar cometidos en cada metodología. El proceso consistió en muestrear los datos aleatoriamente sin reemplazamiento (MAS), dando lugar a los siguientes patrones según el enfoque de inferencia considerado. En las metodologías EXP y CMB se evaluaron tamaños de muestra $n=10, 11, \dots, 50$. En las metodologías REG y 3pHMB se consideraron coberturas auxiliares parciales de TLS del 75, 50 y 25% y aumentos muestrales progresivos para la segunda fase ($n=10, 11, \dots, 50$). Se realizaron un total de 10,000 simulaciones por tamaño muestral, estimando los parámetros de interés media poblacional ($\mu^{\wedge sim}$), sesgo ($Bias^{\wedge}(\mu^{\wedge sim})$) y error estándar ($se^{\wedge}(\mu^{\wedge sim})$) de la siguiente forma:

$$\mu^{\wedge sim} = \frac{1}{nsim} \sum_{s=1}^{nsim} \mu^{\wedge s} \quad (6)$$

$$Bias^{\wedge}(\mu^{\wedge sim}) = \frac{1}{nsim} \sum_{s=1}^{nsim} (\mu^{\wedge s} - \mu) \quad (7)$$

$$se^{\wedge}(\mu^{\wedge sim}) = \frac{1}{nsim-1} \sum_{s=1}^{nsim} (\mu^{\wedge s} - \mu^{\wedge sim})^2 \quad (8)$$

donde s indica las muestras de Monte Carlo, $nsim$ es el número de simulaciones, $\mu^{\wedge s}$ es la estimación del volumen medio en la repetición de Monte Carlos, y μ el valor real poblacional.

4. Resultados

A continuación se muestran los resultados más relevantes de este trabajo. Las simulaciones de Monte Carlo mostraron que los enfoques de inferencia que incorporan datos de teledetección como información auxiliar redujeron consistentemente los errores en las estimaciones de V , en comparación con los métodos basados en diseños que utilizan una única fuente de datos, ya sean datos convencionales de campo o TLS (Figura 3). En promedio, todos los enfoques presentaron un sesgo casi nulo, mostrando un comportamiento asintótico donde el sesgo disminuyó al aumentar el tamaño muestral (Figura 4). También cabe

destacar que el único estimador que no redujo su sesgo a medida que el tamaño de muestra aumentó fue el basado en los datos TLS con corrección de las oclusiones (V.hn.cov) (Figura 4a). Solo se muestra esta estimación del V(V.hn.cov) en base a los datos TLS por haber sido la que menor sesgo ha mostrado.




Figura 3. Error estándar de los estimadores para las diferentes metodologías de inferencia.




Figura 4. Sesgo de los estimadores para las diferentes metodologías de inferencia.

5. Discusión

El uso de datos auxiliares de teledetección obtenidos de sensores remotos como son el TLS y el UAV-LiDAR, permitió reducir errores en las estimaciones de Ven la mayoría de los casos evaluados, lo cual está en línea con el estado del arte en estas metodologías de inferencia. Ejemplos de estas metodologías incluyen estudios que utilizaron datos de ALS en bandas (ENE et al., 2012; NÆSSET et al., 2013) o combinaciones jerárquicas con fuentes de datos como UAV-LiDAR y Sentinel-2 (PULITI et al., 2018).

Mientras que todas las metodologías de inferencia mostraron estimaciones asintóticamente insesgadas (Figura 4), el enfoque de expansión simple (EXP) utilizado con datos de TLS procesados con el paquete de R FORTLS, mostró un sesgo negativo constante de -0.55% (aproximadamente $-1.40 \text{ m}^3 \text{ ha}^{-1}$). Este está posiblemente asociado a problemas de oclusiones y detección incompleta de árboles, tal y como se ha visto en trabajos previos (ASTRUP et al., 2014). Incluso teniendo en cuenta que el estimador utilizado (V.hn.cov) implementa una corrección de las oclusiones. Sin embargo, es menor que el 3% encontrado en KURONEN et al., (2019) en la estimación de la densidad y el área basimétrica. También cabe destacar que el TLS como único dato en las estimaciones incrementó

los errores respecto a las estimaciones basadas en los datos de campo. Esto es debido a la mayor variabilidad en las estimaciones de Va nivel de parcela causadas por oclusiones (i.e. árboles no detectados), falsos árboles detectados y sesgos cometidos en las estimaciones de V (ABEGG et al., 2023; VATANDAŞLAR et al., 2023). En los enfoques basados en modelos (CMB), los errores fueron mayores que en los enfoques EXP para intensidades de muestreo bajas (<4%, equivalente a menos de 16 parcelas), debido a un ajuste deficiente del modelo con tamaños de muestra pequeños. Este hallazgo es consistente con los de un estudio previo realizado en condiciones relativamente similares (40 ha de plantación de *Pinus radiata*), en el cual la mejora en la precisión con el enfoque CMB utilizando datos auxiliares de UAV-LiDAR y 30 parcelas de campo (4.5% de intensidad de muestreo de campo) fue relativamente pequeña en comparación con la del enfoque EXP basado en datos de campo (PULITI et al., 2020). Sin embargo, al aumentar el número de parcelas, los errores disminuyeron significativamente en todas las metodologías de inferencia, y especialmente en el caso de CMB empleando el UAV-LiDAR como fuente auxiliar de datos. En cualquier caso, las conclusiones extraídas de este caso de estudio deben considerarse con cautela, ya que, la modelización es una parte fundamental de la inferencia basada en modelos, y aquí solo se consideraron modelos lineales de hasta 3 variables independientes.

En los métodos de inferencia asistida por modelos (REG) y basada en modelos jerárquicos en tres fases (3pHMB), los errores fueron menores que en EXP, incluso con intensidades de muestreo de campo bajas. En particular, el método REG demostró ser más eficiente al aumentar el tamaño de muestra con TLS. Estos enfoques también indicaron que el tamaño de la muestra en la primera fase es más determinante en la precisión que el de las fases subsiguientes.

Estudios futuros podrían centrarse en reemplazar la fase de medición de datos de campo con enfoques de escaneos múltiples de TLS o MLS para reducir los problemas causado por las oclusiones (LIANG et al., 2018). Sin embargo, se ha demostrado que los errores de muestreo serían similares o mayores que en el enfoque EXP convencional basado solo en datos de campo. Por un lado, otras fuentes de error como podrían ser el sesgo cometido por los modelos alométricos, pueden reducirse mediante el uso del TLS, tal y como se ha demostrado para estimaciones de biomasa (Stovall et al., 2023). Por otro lado, la detección de árboles jóvenes sigue siendo limitada (LIANG et al., 2018), generando estimaciones sesgadas con los algoritmos y dispositivos actuales (ABEGG et al., 2023), por lo que los dispositivos LiDAR de corto alcance como fuentes auxiliares de información podrían abordar este problema, permitiendo estimar atributos en etapas tempranas de los rodales y mejorando así la gestión forestal.

6. Conclusiones

Los enfoques de inferencia basados en datos auxiliares generalmente redujeron los errores en las estimaciones de volumen (V) en comparación con los enfoques que utilizan una única fuente de información (EXP), tanto para datos de campo como de TLS. El uso novedoso de datos auxiliares de TLS en los enfoques de inferencia REG y 3pHMB mejoró las estimaciones de V, reduciendo significativamente los errores. Por un lado, el enfoque CMB utilizando datos de UAV-LiDAR requirió una mayor intensidad de muestreo de campo para aumentar la eficiencia en comparación con los enfoques EXP. Por otro lado, los enfoques de inferencia REG y 3pHMB fueron más eficientes que los enfoques EXP, incluso con



bajas intensidades de muestreo de campo. Estos hallazgos destacan el potencial de los dispositivos LiDAR de corto alcance como herramientas de medición a nivel de rodal, especialmente en términos de reducción de errores. Sin embargo, los resultados no pueden generalizarse a poblaciones muy diferentes de las analizadas en este estudio. La aplicación de estas técnicas en situaciones reales será clave para operacionalizar el uso de dispositivos LiDAR de corto alcance en IFs. Como en otros métodos de teledetección, el próximo paso debe centrarse en evaluar la universalidad de estas técnicas mediante su replicación en otros contextos.

7. Agradecimientos

Este trabajo fue financiado por el Gobierno Regional de Galicia [ED431F 2020/02] y el Ministerio de Ciencia e Innovación de España [PID2020-119204RB-C22]. JAMV contó con el apoyo de la beca posdoctoral “Becas Fundación Ramón Areces para Estudios Posdoctorales” [BEVP35A7109] y de la beca MSCA-COFUND dentro del marco del proyecto “Central Bohemian Mobility Programme for Excellence in Research, Innovation and Technology” [MERIT - Grant AgreementNo. 101081195]; AMC recibió apoyo del Gobierno Regional de Galicia en el marco del convenio “Desarrollo del Inventario Forestal Continuo de Galicia” [2020-CP031]; JRR fue financiado por el contrato predoctoral Campus Terra-USC 2022; y CPC contó con el apoyo del Ministerio de Ciencia e Innovación de España [RYC2018-024939-I].

Los autores agradecen a Diego Lombardero Barrera, Eduardo Seijo De Bernardo, Mario López Fernández y Óscar López Álvarez por su ayuda en el trabajo de campo.

8. Bibliografía

- ABEGG, M.; BÖSCH, R.; KÜKENBRINK, D.; MORSDORF, F.; 2023. Tree volume estimation with terrestrial laser scanning-Testing for bias in a 3D virtual environment.*Agricultural and Forest Meteorology*,331, 109348.
- ASTRUP, R.; DUCEY, M. J.; GRANHUS, A.; RITTER, T.; VON LÜPKE, N.; 2014. Approaches for estimating stand-level volume using terrestrial laser scanning in a single-scan mode.*Canadian Journal of Forest Research*,44(6), 666-676
- COOPS, N. C.; TOMPALSKI, P.; GOODBODY, T. R. H.; ACHIM, A.; MULVERHILL, C.; 2023. Framework for near real-time forest inventory using multi source remote sensing data. *Forestry: An International Journal of Forest Research*, 96(1), 1–19.
- DIÉGUEZ-ARANDA, U.; ALBORECA, A. R.; CASTEDO-DORADO, F.; GONZÁLEZ, J. Á.; BARRIO-ANTA, M.; CRECENTE-CAMPO, F.; ... GÓMEZ-GARCÍA, E.; 2009. Herramientas selvícolas para la gestión forestal sostenible en Galicia.Dirección Xeral de Montes, Consellería do Medio Rural, Xunta de Galicia. 259. Lugo
- ENE, L. T.; NÆSSET, E.; GOBAKKEN, T.; GREGOIRE, T. G.; STÅHL, G.; NELSON, R.; 2012. Assessing the accuracy of regional LiDAR-based biomass estimation using a simulation approach. *Remote Sensing of Environment*, 123, 579–592.
- FASSNACH, F. E.; WHITE, J. C.; WULDER, M. A., NÆSSET, E.; 2023. Remote sensing in forestry: current challenges, considerations and directions. *Forestry: An International Journal of Forest Reserach*, 97(1), 11-37.
- KANGAS, A.; ASTRUP, R.; BREIDENBACH, J.; FRIDMAN, J.; GOBAKKEN, T.; KORHONEN, K. T.; ... OLSSON, H.; 2018. Remote sensing and forest inventories in Nordic countries–roadmap for the future.*Scandinavian Journal of Forest*



Research,33(4), 397-412.

KURONEN, M.; HENTTONEN, H. M.; MYLLYMÄKI, M.; 2019. Correcting for nondetection in estimating forest characteristics from single-scan terrestrial laser measurements.*Canadian Journal of Forest Research*,49(1), 96-103

LIANG, X.; HYYPPÄ, J.; KAARTINEN, H.; LEHTOMÄKI, M.; PYÖRÄLÄ, J.; PFEIFER, N.; HOLOPAINEN, M.; BROLLY, G.; FRANCESCO, P.; HACKENBERG, J.; HUANG, H.; JO, H. W.; KATOH, M.; LIU, L.; MOKROŠ, M.; MOREL, J.; OLOFSSON, K.; POVEDA-LOPEZ, J.; TROCHTA, J.; ... WANG, Y.; 2018. International benchmarking of terrestrial laser scanning approaches for forest inventories. *ISPRS Journal of Photogrammetry and Remote Sensing*, 144, 137–179.

LIANG, X.; KANKARE, V.; HYYPPÄ, J.; WANG, Y.; KUKKO, A.; HAGGRÉN, H.; YU, X.; KAARTINEN, H.; JAAKKOLA, A.; GUAN, F.; HOLOPAINEN, M.; VASTARANTA, M.; 2016. Terrestrial laser scanning in forest inventories. *ISPRS Journal of Photogrammetry and Remote Sensing*, 115, 63–77.

MCROBERTS, R. E.; NÆSSET, E.; HEIKKINEN, J.; STRIMBU, V.; 2024. Two-stage, model-assisted estimation using remotely sensed auxiliary data.*Remote Sensing of Environment*,307, 114125.

MOLINA-VALERO, J. A.; ORDÓÑEZ-PRADO, C.; MARTÍNEZ-CALVO, A.; RODRÍGUEZ-RUIZ, J.; PÉREZ-CRUZADO, C.; 2023. Muestreo operativo con escáner láser terrestre (TLS) en inventario forestal.*Foresta*, (87), 54-62.

MOLINA-VALERO, J. A.; MARTÍNEZ-CALVO, A.; GINZO VILLAMAYOR, M. J.; NOVO PÉREZ, M. A.; ÁLVAREZ-GONZÁLEZ, J. G.; MONTES, F.; PÉREZ-CRUZADO, C.; 2022. Operationalizing the use of TLS in forest inventories: The R package FORTLS. *Environmental Modelling & Software*, 150, 105337.

MURTIYOSO, A.; CABO, C.; SINGH, A.; OBAYA, D. P.; CHERLET, W.; STODDART, J.; ... MOKROŠ, M.; 2024. A review of software solutions to process ground-based point clouds in forest applications.*Current Forestry Reports*,10(6), 401-419.

NÆSSET, E.; GOBAKKEN, T.; BOLLANDSÅS, O. M.; GREGOIRE, T. G.; NELSON, R.; STÅHL, G.; 2013. Comparison of precision of biomass estimates in regional field sample surveys and airborne LiDAR-assisted surveys in Hedmark County, Norway. *Remote Sensing of Environment*, 130, 108–120.

PULITI, S.; DASH, J. P.; WATT, M. S.; BREIDENBACH, J.; PEARSE, G. D.; 2020. A comparison of UAV laser scanning, photogrammetry and airborne laser scanning for precision inventory of small-forest properties.*Forestry: An International Journal of Forest Research*,93(1), 150-162.

PULITI, S.; SAARELA, S.; GOBAKKEN, T.; STÅHL, G.; NÆSSET, E.; 2018. Combining UAV and Sentinel-2 auxiliary data for forest growing stock volume estimation through hierarchical model-based inference. *Remote Sensing of Environment*, 204, 485–497.

R Core Team. (2023). R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing, Vienna, Austria. <https://www.R-project.org/>

ROUSSEL, J. R.; AUTY, D.; COOPS, N. C.; TOMPALSKI, P.; GOODBODY, T. R. H.; MEADOR, A. S.; BOURDON, J. F.; DE BOISSIEU, F.; ACHIM, A.; 2020. lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. *Remote Sensing of Environment*, 251, 112061.

SAARELA, S.; VARVIA, P.; KORHONEN, L.; YANG, Z.; PATTERSON, P. L.; GOBAKKEN,



T.; ... STÅHL, G.; 2023. Three-phase hierarchical model-based and hybrid inference. *MethodsX*, 11, 102321

STOVALL, A. E. L.; VORSTER, A.; ANDERSON, R.; EVANGELISTA, P.; 2023. Developing nondestructive species-specific tree allometry with terrestrial laser scanning. *Methods in Ecology and Evolution*, 14(1), 280–290.

TOMPALSKI, P.; GOODBODY, T.; (2021). Additional point cloud metrics to use with *_metric functions in lidR. <https://github.com/ptompalski/lidRmetrics>

WHITE, J. C.; COOPS, N. C.; WULDER, M. A.; VASTARANTA, M.; HILKER, T.; TOMPALSKI, P.; 2016. Remote Sensing Technologies for Enhancing Forest Inventories: A Review. *Canadian Journal of Remote Sensing*, 42(5), 619–641.

WULDER, M. A.; WHITE, J. C.; NELSON, R. F.; NÆSSET, E.; ØRKA, H. O.; COOPS, N. C.; HILKER, T.; BATER, C. W.; GOBAKKEN, T.; 2012. Lidar sampling for large-area forest characterization: A review. *Remote Sensing of Environment*, 121, 196–209.

VATANDAŞLAR, C.; SEKI, M.; ZEYBEK, M.; 2023. Assessing the potential of mobile laser scanning for stand-level forest inventories in near-natural forests. *Forestry: An International Journal of Forest Research*, 96(4), 448-464