



**2025** | **16-20**  
GIJÓN | JUNIO

9º CONGRESO **FORESTAL** ESPAÑOL

**9CFE-1365**

---

Organiza





## Uso combinado de información auxiliar GEDI y ALS en modelos Fay-Herriot para mejorar la estimación de biomasa forestal

GONZÁLEZ MESQUIDA, J.B. (1), PASCUAL, A. (2), RODRÍGUEZ PUERTA, F. (1), GUERRA HERNANDEZ, J. (3), PERROY, R. (4), GARCÍA-GOMEZ, R. (1), MAURO-GUTIÉRREZ, F. (1)

(1) iuFOR, EiFAB, Universidad de Valladolid, 42004 Soria, España

(2) University of Maryland, Department of Geographical Sciences. Maryland, USA.

(3) Universidade de Lisboa, DRAT-ISA. Lisboa, Portugal.

(4) University of Hawai'i at Hilo, Department of Geography & Environmental Science. Hawai'i, USA.

### Resumen

La estimación precisa de la Densidad de Biomasa Aérea (AGBD, por sus siglas en inglés) es esencial para comprender el ciclo del carbono e informar estrategias de manejo forestal. Este estudio examina la aplicación de modelos Fay-Herriot (FH) para la estimación de biomasa forestal utilizando métricas de LiDAR espacial, datos de LiDAR aerotransportado y su combinación. Evaluamos el desempeño de los datos de la misión GEDI y los datos de ALS en dos entornos forestales contrastantes: plantaciones de eucalipto en Hawai'i y bosques mediterráneos de pino en España. Se compararon cuatro métodos de estimación en ambos sitios de estudio: modelos FH utilizando solo datos de ALS, modelos FH utilizando solo datos de GEDI, modelos FH que integran ambas fuentes de datos, y estimación directa. Se empleó un proceso de selección de modelos para identificar predictores candidatos, y todos los modelos fueron evaluados rigurosamente. Para evaluar el desempeño de cada estimador, se utilizaron el Error Cuadrático Medio (RMSE) y la eficiencia relativa, en comparación con la estimación directa, como indicadores. Los resultados demuestran que los modelos FH, independientemente de las variables auxiliares utilizadas, superaron consistentemente a los métodos de estimación directa, como lo evidencian los menores valores de RMSE. Las mejoras relativas sobre las estimaciones directas fueron del 21%, 20% y 22% para ALS, GEDI y su combinación en Hawai'i; y del 52%, 35% y 52% para los respectivos conjuntos de datos auxiliares en España. El estudio destaca que, si bien la combinación de ambos conjuntos de datos no redujo sustancialmente la incertidumbre de las estimaciones, tanto los datos de ALS como los de GEDI pueden mejorar significativamente la estimación de AGBD cuando se incorporan en modelos FH.

### Palabras clave

Estimación de áreas pequeñas, biomasa, modelos a nivel de área, lidar.

### 1. Introducción

La Densidad de Biomasa Aérea (AGBD) es una propiedad clave del bosque que ofrece valiosas perspectivas sobre el ciclo del carbono y otros servicios



ecosistémicos, ayudando a evaluar el papel de los bosques en la mitigación del cambio climático (PAN et al., 2011). Estimar la AGBD utilizando observaciones de Teledetección (RS, por sus siglas en inglés), calibradas con datos de referencia de campo, es un enfoque escalable y efectivo (HUNKA et al., 2023). Entre las tecnologías de RS, el LiDAR, particularmente el Escaneo Láser Aerotransportado (ALS), ha sido utilizada en inventarios forestales operativos durante varios años (NÆSSET, 2002). Sin embargo, la resolución espacial y temporal de los datos de ALS es limitado y frecuentemente hay desajustes con los datos de campo disponibles necesarios para la calibración.

Más allá de las mediciones tradicionales de ALS, el lanzamiento de la misión de Investigación de la Dinámica del Ecosistema Global (GEDI, por sus siglas en inglés) de la NASA a bordo de la Estación Espacial Internacional en 2019 marcó un avance significativo en el mapeo global de bosques (DUBAYAH et al., 2020, 2022). Los productos de datos de la misión GEDI ofrecen estimaciones consistentes e insesgadas a escala global de los atributos de altura del dosel forestal para áreas entre las latitudes 51.6° N y S (DUBAYAH et al., 2022). Esta disponibilidad temporal y extensión geográfica presentan una aplicabilidad más amplia y ofrecen un medio rentable para informar los sistemas de monitoreo del carbono, particularmente en países sin misiones ALS, en regiones donde los datos de ALS están desactualizados o se recolectan con una baja resolución temporal, y en áreas remotas o de difícil acceso (ADRAH et al., 2021; LIANG et al., 2023; MILENKOVIĆ et al., 2022; STEREŃCZAK et al., 2020).

Mejorar la precisión en la cuantificación de la biomasa forestal usando ALS se ha convertido en un área importante de investigación (BREIDENBACH et al., 2010; BREIDENBACH & ASTRUP, 2012; NÆSSET, 2002), y prevalecen las metodologías que utilizan el enfoque *area based approach* (ABA). Sin embargo, el método ABA es inviable en dos casos: (i) cuando las parcelas tienen baja precisión posicional y no pueden vincularse a los datos de RS (MAURO et al., 2010; PASCUAL et al., 2021) y (ii) cuando los propios datos de RS no pueden vincularse a las observaciones de las parcelas, independientemente de la precisión posicional de estas últimas, debido a que la disposición de la recolección de datos espacio-temporales y la incertidumbre posicional de los datos de RS impiden coordinar y emparejar las observaciones terrestres y de RS (McROBERTS et al., 2018; TANG et al., 2023).

Las parcelas con precisiones posicionales de cinco metros o más siguen siendo comunes en los repositorios de datos de inventario forestal. Muchas agencias, empresas y propietarios forestales tienen protocolos de inventario en los que solo se registran las coordenadas aproximadas de las parcelas. Esta valiosa información sobre parcelas de referencia de campo a menudo se descarta para calibrar modelos de AGBD u otros atributos biofísicos del bosque, ya que estas parcelas no cumplen con las condiciones para una inferencia robusta basada en ABA, debilitando los modelos debido a desajustes temporales, disparidades e inconsistencias en los tamaños de muestra, pero principalmente a desviaciones de geolocalización entre las ubicaciones nominales y reales (MAGNUSSEN et al., 2017; PASCUAL et al., 2021). A pesar de la abundancia de programas nacionales de inventario forestal, los datos de referencia local en campo son escasos y valiosos (HUDAK et al., 2020). Por lo tanto, son críticas las metodologías capaces de producir estimaciones robustas utilizando datos de inventario a nivel de parcela y de masa con geolocalización menos precisa para apoyar los esfuerzos de mapeo y monitoreo forestal.



Estudios previos han demostrado que los modelos Fay-Harriot (FH) ofrecen una solución para usar esta valiosa información de campo vinculando las medias de muestra por área de AGBD con información auxiliar de ALS (MAURO et al., 2017; TEMESGEN et al., 2021). Ejemplos recientes también han mostrado la capacidad de mejorar las estimaciones existentes de AGBD al incorporar métricas de GEDI sobre la altura y estructura del dosel, así como estimaciones globales modeladas de AGBD, en modelos FH calibrados localmente (BRUENING et al., 2023; ZHANG et al., 2022). Cabe señalar que, aunque el producto AGBD L4A de GEDI puede potencialmente usarse para obtener estimaciones de biomasa a nivel de masa, estos modelos frecuentemente están sesgados y requieren calibración local (LI et al., 2024). La extensión de la misión GEDI más allá de 2024 ampliará significativamente su cobertura de datos y mejorará sustancialmente el apoyo a la planificación operativa y la conservación (NASA, 2023). Dada la flexibilidad de los modelos FH, es importante destacar que pueden integrarse con datos de diferentes resoluciones y tipos (e.g., LiDAR, RADAR, sensores ópticos). Esta versatilidad permite que los modelos FH converjan espacialmente una amplia variedad de conjuntos de datos diferentes.

Los datos de ALS tienen una historia de uso más larga en comparación con los datos de GEDI. A escalas locales, los datos de ALS proporcionan información significativamente más densa, lo que generalmente permite una mejor correlación con atributos forestales como la AGBD. Sin embargo, no existen estudios sobre cómo se desempeñan los modelos FH al combinar métricas de GEDI y ALS. Además, la combinación de varios productos de GEDI no es comúnmente encontrada en la literatura para la estimación de AGBD, particularmente los productos L4C, que han sido puestos a disposición pública recientemente.

## 2. Objetivos

Nuestro objetivo fue medir la mejora marginal en la inferencia estadística basada en los modelos FH al combinar datos de GEDI y ALS temporalmente correlacionados. Para ello, presentamos una comparación realizada en dos geografías contrastantes: una plantación comercial de eucaliptos de alta densidad y de crecimiento uniforme en la isla de Hawai'i, y un bosque mediterráneo de pinos relativamente disperso en España. A pesar de sus diferencias ecológicas, estas dos especies son particularmente efectivas para capturar carbono atmosférico debido a sus altas tasas de crecimiento y acumulación de biomasa (DEL RÍO et al., 2008; STAPE et al., 2004). Además, la reducción de incertidumbre en las estimaciones de AGBD lograda por los modelos FH promete mejorar las estimaciones de masa forestal a nivel mundial, ofreciendo un enfoque rentable con alta resolución temporal que puede aplicarse a diversas escalas para apoyar la toma de decisiones de los gestores forestales.

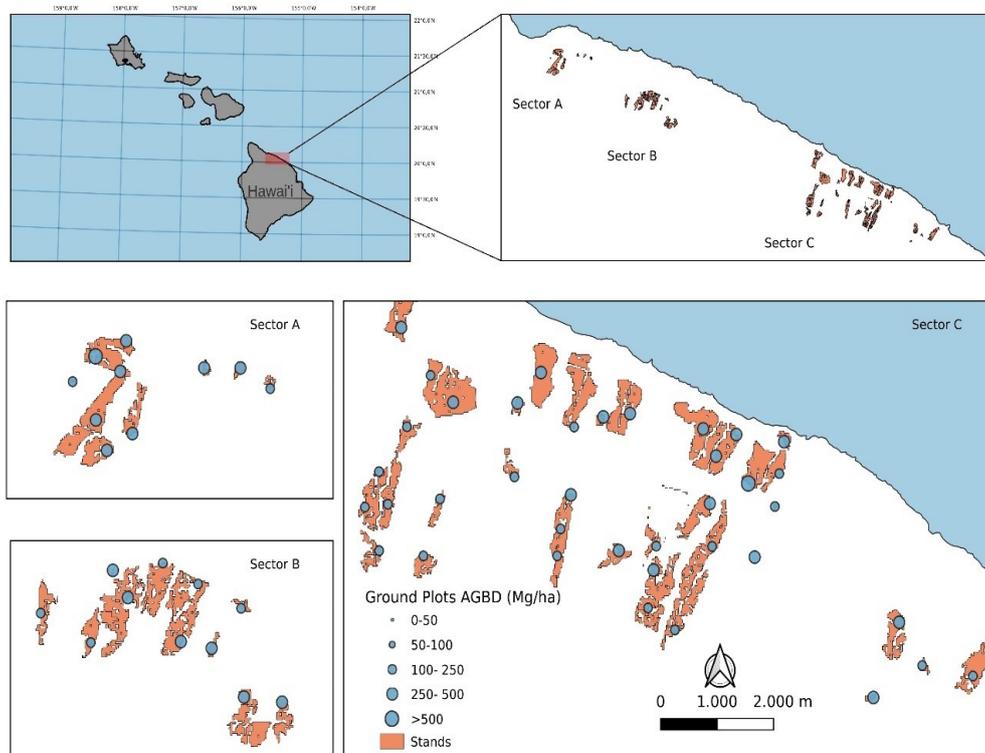
## 3. Metodología

### Áreas de estudio

El estudio se centró en dos áreas donde la plantación de árboles tuvo como objetivo aumentar las reservas de carbono y generar ingresos a través de la tala y tratamientos silvícolas: un conjunto de plantaciones de eucalipto de 35 a 65 años en la isla de Hawa'i, EE.UU., y un conjunto de plantaciones de pino de 65 a 75 años en Soria, España. La composición de especies, el contexto ecológico y la historia de manejo de ambas áreas son sustancialmente diferentes.

### Distritos de North Hilo y Hāmākua (Isla de Hawai'i, EE.UU.)

La primera área de estudio se encuentra en los distritos de North Hilo y Hāmākua (NHHD) de la isla de Hawai'i (Figura 1), donde se plantaron árboles de eucalipto no nativos en la década de 1960 en elevaciones altas como parte de los esfuerzos de protección de cuencas hidrográficas, y en la década de 1990 en áreas costeras bajas ubicadas en dominios privados. El área de estudio NHHD abarca 2,683 hectáreas, con un 93% cubierto por *Eucalyptus grandis* y un 7% por *Eucalyptus urophylla*. Las condiciones climáticas en NHHD son adecuadas para las plantaciones de eucalipto de rápido crecimiento: la precipitación anual típicamente varía de 1,250 a 3,125 mm, excepto en las áreas de Akaka Falls y la cuenca hidrográfica de Hilo, donde la precipitación anual puede exceder los 6,000 mm (LONGMAN et al., 2024; CONSTANTINIDES et al., 2000). El área NHHD se dividió en unidades de manejo de gran tamaño, que a su vez se subdividieron en rodales basados en la proximidad espacial y la homogeneidad de altura. Nuestros análisis se limitaron a un subconjunto de 17 rodales que fueron muestreados, cubriendo 755 hectáreas (Figura 1).

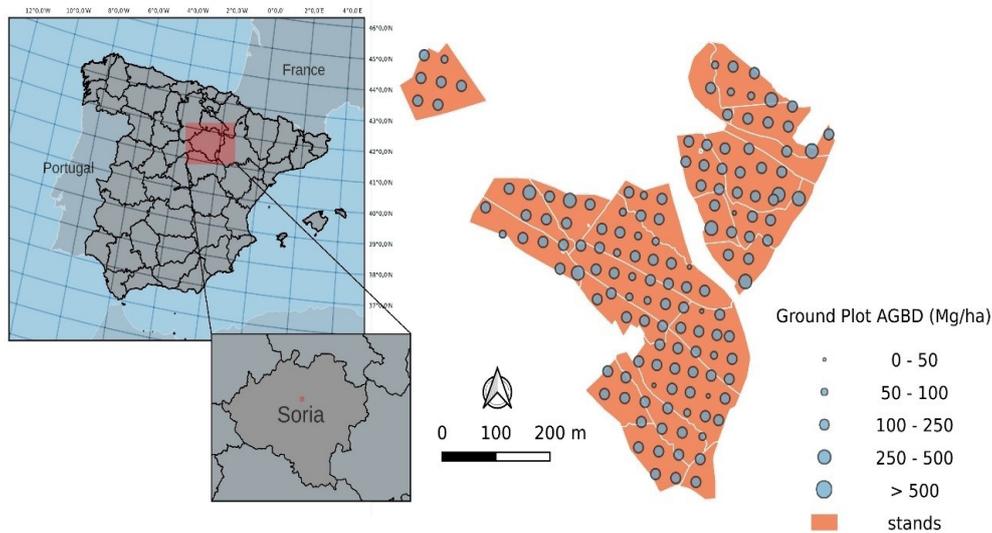


**Figura 1.** Área de estudio NHHD en Hawai'i, EE.UU. Las parcelas de campo están representadas con puntos de tamaños variables, proporcionales a la densidad de biomasa aérea (AGBD). Para mejorar la visualización, en la figura los rodales se dividieron en sectores (A, B y C) debido a su gran tamaño.

### Villaciervos (Soria, España)

La segunda área de estudio se encuentra en el municipio de Villaciervos (Figura 2), en la provincia de Soria, Castilla y León, España. Cubre 511 hectáreas de plantaciones de pino, establecidas entre 1953 y 1960. Tres especies diferentes son dominantes en el área: pino marítimo (*Pinus pinaster* Aiton, 66% de abundancia), pino silvestre (*Pinus sylvestris* L, 19%), y pino negro (*Pinus nigra* J. F. Arnold, 7.8%). La precipitación sigue un régimen mediterráneo moderado, con aproximadamente

600 mm al año, distribuidos de manera irregular a lo largo del año. Los datos de 23 rodales muestreados en Villaciervos fueron proporcionados por la agencia de gestión forestal de la región.



**Figura 2** Área de estudio de Villaciervos en Soria, España. Las parcelas de campo están representadas con puntos de tamaños variables, proporcionales a la densidad de biomasa aérea (AGBD).

### Parcelas de campo

#### NHHD

El inventario de datos de campo de 2020 de las plantaciones NHHD en la Isla de Hawai'i (Figura 1) incluyó 61 parcelas de radio variable con coordenadas de baja precisión, dispuestas sistemáticamente en 17 rodales. El factor de área basal (BAF, por sus siglas en inglés) para las parcelas se estableció en  $6.88 \text{ m}^2/\text{ha}$ , es decir,  $30 \text{ ft}^2/\text{acre}$  en el sistema imperial. Solo se utilizaron parcelas en rodales de eucalipto no perturbados, excluyendo áreas parcialmente cosechadas, lo que resultó en un conjunto de datos de 544 árboles con mediciones de diámetro a la altura del pecho (DBH), de los cuales un subconjunto de 287 tenía mediciones de altura total (H). La biomasa aérea a nivel de árbol se calculó utilizando el modelo alométrico propuesto por (GIARDINA et al., 2003). Este modelo fue desarrollado para *E. saligna* (estrechamente relacionado con *E. grandis*; (CAMPOE et al., 2012) con muestras recolectadas en los años 2000 de árboles de diferentes edades que crecían en plantaciones a lo largo de NHHD.

#### Villaciervos

El inventario forestal de Villaciervos incluyó 140 parcelas de radio fijo de  $11 \text{ m}$  ( $380.27 \text{ m}^2$ ), dispuestas sistemáticamente en rodales de bosque de pino. Las parcelas se midieron en 2020 y tenían coordenadas con precisión submétrica, pero para los propósitos de este estudio, solo se utilizó la información sobre el rodal en el que se encontraba cada parcela. Se midieron un total de 2.166 árboles, registrándose el DBH para todos ellos, y un subconjunto de 560 tuvo medición de H. Los árboles con mediciones de H se usaron para desarrollar relaciones locales H-DBH. Estas relaciones se utilizaron para predecir H en los árboles en los que esta variable no fue medida. La biomasa aérea a nivel de árbol se calculó luego utilizando el modelo alométrico específico por especie propuesto por (RUIZ-PEINADO et al., 2011). La Tabla 1 presenta los valores de AGBD por rodal, así como

las estadísticas de tamaño de rodal y el número de parcelas para cada área de estudio.

**Tabla 1.** Tabla comparativa de las áreas de estudio.

Caso de estudio	Tamaño del rodal (ha)			AGBD (Mg ha <sup>-1</sup> )			desviación estándar	parcelas
	min	medio	max	min	medio	max		
Villaciervos / Pino	12	22.21	45.24	106.3	166.0	241.3	41.9	140
NHHD / Eucaliptus	18.9	47.45	122.6	206.0	352.7	555.4	46.9	61

### Adquisición y procesamiento de datos auxiliares de GEDI

Utilizamos la versión 002 para todos los productos de GEDI. Esta versión tiene una precisión de geolocalización mejorada (10-12 m) en comparación con la Versión 001 (> 20 m) (TANG et al., 2023). Se promediaron tres años de datos de GEDI para cada rodal: el año de medición de la parcela de campo, el año anterior y el año siguiente (es decir, 2019, 2020 y 2021) para aumentar el número de *shots* que se superponen a cada rodal. Las variables de GEDI utilizadas para modelar la AGBD incluyeron la altura del dosel (L2A), la cobertura del dosel (L2B), estimaciones de AGBD (L4A) de modelos globales, y el nuevo índice de complejidad estructural de GEDI L4C (L4C) (DE CONTO et al., 2024; DUBAYAH et al., 2020, 2022; KELLNER et al., 2023).

Se llevó a cabo un proceso de filtrado de calidad de datos para asegurar la alta calidad de los datos de GEDI. Solo se seleccionaron *footprints* con una fidelidad de forma de onda superior a 0.95. Además, la selección del algoritmo en el producto GEDI L2A se optimizó para cada *footprint* individual, y se consideraron las banderas de calidad de los productos L2A y L4A. Para refinar aún más los datos, se permitió una diferencia máxima de 50 metros, proporcionada en el producto L2A, entre el modo de elevación más bajo de GEDI y la elevación del terreno de TanDEM-X (KRIEGER et al., 2007). Después de aplicar estos filtros, 366 huellas para el sitio de pino y 296 para el sitio de eucalipto pasaron los criterios de calidad para el período 2019-2021 (Tabla 2).

Posteriormente, las *footprints* seleccionadas se agregaron dentro de los límites de los rodales, y todos los productos se resumieron utilizando los valores promedio y la desviación estándar para cada rodal. En total, se incluyeron 36 predictores derivados de GEDI en el proceso de selección del modelo.

**Tabla 2.** Número mínimo, medio y máximo de *shots* de GEDI filtrados por hectárea (por rodal) y *shots* por rodal para cada caso de estudio.

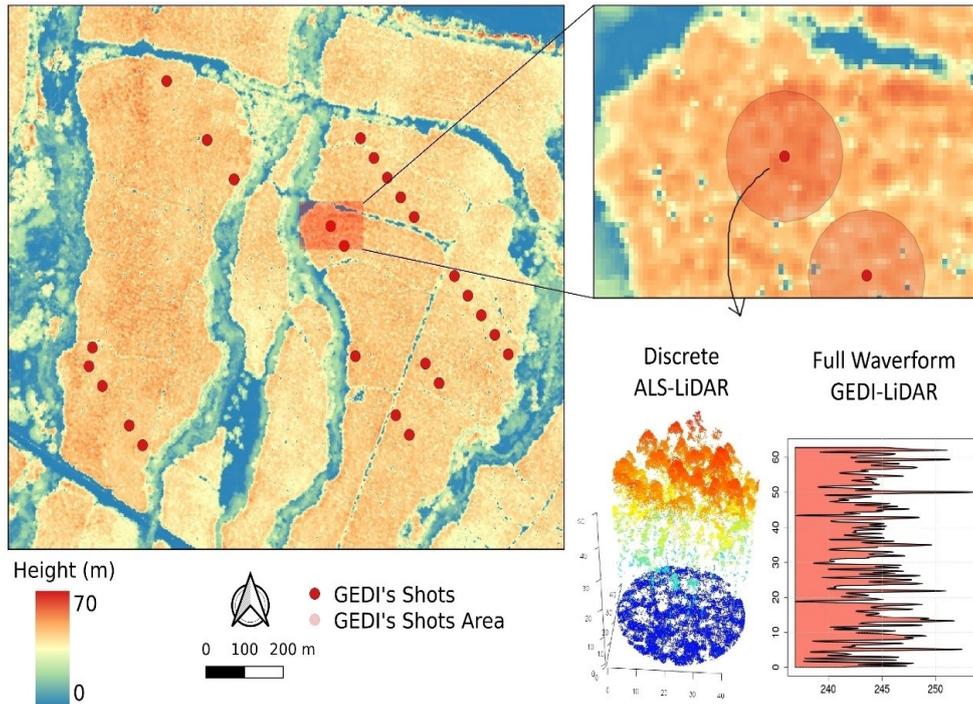
Caso de estudio	Footprints filtrados						parcelas	
	shots/ha	shots/rodal			Shots totales			
	min	medio	max	min	medio	max		
Villaciervos / Pino		0.31	0.79	1.51	5	17.4	48	366
NHHD / Eucaliptus		0.03	0.35	0.49	1	17.4	60	296

### Procesamiento de conjuntos de datos LiDAR aerotransportados

En ambas áreas de estudio, utilizamos datos ALS de acceso abierto publicada por agencias públicas. Para las plantaciones de eucalipto en Hawai'i, los datos ALS se obtuvieron de los archivos de la Administración Nacional Oceánica y Atmosférica (NOAA) (2018 - 2020 NOAA USGS Lidar: Hawaii, HI | InPort) de vuelos realizados entre 2018 y 2020. Las nubes de puntos proporcionadas por NOAA estaban todas en coordenadas geográficas utilizando el Datum Norteamericano de 1983 (es decir, código EPSG 4269) y fueron proyectadas a la zona 5 del Mercator Transversal Universal (UTM) (código EPSG 6635) utilizando la biblioteca de abstracción de datos de puntos (PDAL) (BUTLER et al., 2024). El sensor LiDAR utilizado para los vuelos en Hawai'i fue el sensor LEICA SPL100 LiDAR de fotón único. Los datos españoles fueron descargados de la base de datos del Plan Nacional de Ortofotografía Aérea (PNOA). La mayor parte de los datos ALS de las plantaciones de pino fueron recolectados en 2019, sin embargo, los datos de una pequeña porción del bosque (10,9% del área total) fueron adquiridos en 2017. El sensor LiDAR utilizado para ambas recopilaciones de datos fue un RIEGL LMS-Q1560.

Los datos ALS en bruto tenían una densidad promedio de 8 y 4 pulsos por metro cuadrado en NHHD y Villaciervos, respectivamente, y los puntos de suelo de ambos conjuntos de datos ALS fueron clasificados por los proveedores. En el caso de la Isla de Hawai'i, los datos ALS recopilados en 2018 tuvieron que ser reclasificados utilizando el software LASTools (ISENBURG, 2014). La reclasificación afectó solo a los puntos no clasificados (es decir, las clase 1), que fueron reasignados a vegetación (las clase 5). La densidad promedio de puntos de suelo (las clase 2) fue de 1,14 puntos/m<sup>2</sup> de un total de 12,13 puntos/m<sup>2</sup> para NHHD, y de 1,62 puntos/m<sup>2</sup> de un total de 2,6 puntos/m<sup>2</sup> para Villaciervos. Posteriormente, se generó un modelo de altura de copas (CHM, por sus siglas en inglés) con una resolución de 1 metro utilizando las nubes de puntos normalizadas (Figura 3) (GUERRA-HERNANDEZ & PASCUAL, 2024).

Las nubes de puntos normalizadas también se utilizaron para calcular métricas en cuadrícula con una resolución de 30 metros para ambos sitios de estudio, utilizando la función *pixel\_metrics()* en el paquete lidR (ROUSSEL et al., 2020). Las 54 métricas estándar proporcionadas por el paquete incluyen estadísticas comunes (por ejemplo, medias, desviación estándar) de la elevación y la intensidad de las devoluciones y percentiles de la distribución de elevaciones e intensidades. Para cada parcela, se calcularon la media zonal y la desviación estándar de estas métricas, lo que resultó en un conjunto de 108 predictores candidatos de ALS para los modelos FH.



**Figura 3.** Modelo de Altura de Copas (CHM) con una resolución de 1 metro para el Bosque NHHH (izquierda). El CHM, derivado de las devoluciones discretas del escaneo láser aerotransportado, proporciona información detallada sobre la estructura vertical del dosel forestal. La subfigura ampliada en la parte superior derecha muestra la ubicación de los disparos de GEDI y su área relacionada, representando la extensión espacial cubierta por cada disparo. La subfigura inferior derecha muestra las devoluciones de la nube de puntos discreta de ALS junto con la forma de onda completa de GEDI para el mismo punto, con el eje y representando la altura en metros y el eje x representando la amplitud de la forma de onda.

**Parámetro de interés**

Para cada parcela, el parámetro desconocido de interés fue AGBD:

Donde

$$AGB_{it} = \sum_{i=1}^{N_i} A_i$$

**Estimadores directos de AGBD y RMSE**

Los estimadores directos (es decir, el enfoque tradicional) nos permiten obtener estimaciones insesgadas, pero con una elevada variabilidad (es decir, alta incertidumbre) del AGBD de la parcela. Para cada parcela, estimamos la AGBD



para cada una de las

$$j = 1 \dots n_i$$

Donde

$$w_{ijt} = \frac{T_{ij}}{j^{\text{ésima}} \cdot i^{\text{ésimo}}} = \frac{10000}{380.27} = 26.29$$

Luego promediamos las estimaciones de las

$$n_i$$

$$\hat{\mu}_i$$

La incertidumbre de las estimaciones directas

$$\hat{\mu}_i$$

$$\hat{\mu}_i$$

$$\sigma_{e_i}^2$$

$$\sigma_{e_i}^2$$

Debido a que

$$\hat{\mu}_i$$

### Estimadores Fay-Herriot

A diferencia de los estimadores directos, el marco del modelo de FH se basa en el siguiente modelo de regresión, que relaciona el parámetro verdadero pero desconocido de interés con la información auxiliar (RAO & MOLINA, 2015):

En la ecuación (5),

$$\mu_i$$

$i$   
ésimo



$$\beta$$

$$x_i$$

$$v_i$$

$$v_i \sim N(0, \sigma_v^2)$$

Dado que el estimador directo de cada rodal puede ser expresado como el parámetro real desconocido más un error de muestreo

$$e_i$$

En este modelo, todos los

$$v_k$$

$$e_l$$

$$k$$

$$l$$

$$\hat{\mu}_i$$

$$\hat{\sigma}_{e_i}^2$$

$$x_i^f$$

$$\beta$$

$$\sigma_v^2$$

$$e_i \sim N\left(0, \frac{\sigma_{e_i}^2}{n_i}\right)$$

Todas las estimaciones de los rodales basados en el modelo

$$\hat{\mu}_{FHI}$$

El EBLUP se forma combinando el estimador directo

$$\hat{\mu}_i$$

$$x_i^f \hat{\beta}$$

$$Y_i$$

$$\hat{\mu}_{FHI}$$

...

Si

$$Y_i$$

$$\hat{\sigma}_v^2 > \hat{\sigma}_{e_i}^2$$

$$\hat{\mu}_{FHI,i}$$

$$\hat{\mu}_i$$

$$\hat{\mu}_i$$

$$\hat{\mu}_{FHI} \cong \hat{\mu}_i$$

$$Y_i$$

$$\hat{\sigma}_V^2 < \hat{\sigma}_{\hat{\mu}_i}^2$$

$$\hat{\mu}_i$$

$$\hat{\mu}_{FHI} \cong x_i^T \hat{\beta}$$

La incertidumbre de los EBLUPs fue estimada usando un estimador aproximadamente insesgado del Error Medio Cuadrático (MSE, por sus siglas en inglés) for

$$\hat{\mu}_{FHI}$$

Las 3 componentes del estimador,

$$g_1(\hat{\sigma}_V^2)$$

$$g_2(\hat{\sigma}_V^2)$$

$$2g_3(\hat{\sigma}_V^2).$$

Finalmente, para comparar las mejoras en la reducción de la incertidumbre de los EBLUPs con las estimaciones directas, la eficiencia relativa fue calculada como (Temesgen et al., 2021):

#### 4. Resultados

Los modelos seleccionados para cada conjunto de predictores y ubicación se presentan en la Tabla 3. Todos los modelos cumplieron con los supuestos de la regresión lineal y mantuvieron los valores de VIF dentro de los rangos aceptables, lo que indica una mínima multicolinealidad entre los predictores. Los modelos elegidos incluyeron como máximo dos predictores debido a: (i) el número limitado de parcelas (es decir, instancias de ajuste del modelo), lo que restringió los grados de libertad, y (ii) la alta correlación típicamente encontrada entre las métricas de LiDAR, lo que a menudo resulta en valores elevados de VIF. Los coeficientes de efectos fijos para cada modelo, junto con sus errores estándar, valores t y niveles de significancia, también se detallan en la Tabla 3. El componente de varianza

$$\hat{\sigma}_V^2$$

**Tabla 3.** Resultados del modelo Fay-Herriot para los conjuntos de predictores ALS y GEDI para ambos sitios de estudio.  $n$  representa el número de observaciones utilizadas para ajustar el modelo, que también se corresponde con el número de

## parcelas en cada sitio.

Caso de estudio	Set de predictores	Variable auxiliar	Error estándar	t-valor	p-valor		
Villaciervos/ Pino	n = 23	ALS	Intercept	110.34	11.19	9.86	0.00
sd_zmax	54.99	5.86	9.38			0.00	
sd_pground	-7.85	1.55	-5.05			0.00	
GEDI	Intercept	20.39	24.30	0.84	0.40		120.93
sd_fhd_norm al	867.96	165.28	5.25			0.00	
sd_xvar_001	11.03	2.60	4.24			0.00	
ALS + GEDI	Intercept	110.34	11.19	9.86	0.00		15.76
sd_zmax	54.99	5.86	9.38			0.00	
sd_pground	-7.85	1.55	-5.05			0.00	
NHHD/ Eucaliptus	n = 17	ALS	Intercept	1054.51	340.28	3.10	0.00
mean_ikurt	-160.72	76.51	-2.10			0.04	
sd_zq60	-22.83	5.58	-4.09			0.00	
GEDI	Intercept	-2155.31	678.34	-3.18	0.00		1234.96
mean_fhd_n ormal	758.51	209.40	3.62			0.00	
sd_fhd_norm al	378.54	191.29	1.98			0.05	
ALS + GEDI	Intercept	-994.80	335.31	-2.97	0.00		1039.36
mean_iskew	-418.79	168.71	-2.48			0.01	
mean_fhd_n ormal	497.39	112.61	4.42			0.00	

Es importante señalar que todos los predictores seleccionados por los modelos para el sitio de Villaciervos estuvieron en su forma de desviación estándar. Por otra parte, para el sitio de NHHD, se eligieron en proporciones casi iguales las formas de la media y la desviación estándar. En Villaciervos, los modelos para la combinación de ALS y GEDI incluían solo métricas de ALS, mientras que en NHHD, el modelo seleccionado incluía un predictor de ALS y uno de GEDI. Entre las métricas de GEDI, destaca la presencia del índice de diversidad de altura del follaje (fhd\_normal), que se incluyó en todos los modelos que usaban métricas de GEDI.



En cuanto a las métricas de ALS, las variables más relevantes para Villaciervos fueron la desviación estándar de la altura máxima ( $sd\_zmax$ ) y la desviación estándar del porcentaje de retornos del suelo ( $sd\_pground$ ). En el sitio de NHHD, los predictores elegidos incluyeron la desviación estándar del percentil 60 de la altura ( $sd\_zq60$ ) y la media del índice de curtosis de la intensidad ( $mean\_ikurt$ ). El modelo combinado ALS + GEDI en NHHD incluyó el índice de asimetría de la intensidad como predictor significativo.

Para evaluar qué estimador tuvo un mejor desempeño, en este estudio se evaluaron cuatro factores clave: (i) la varianza estimada de los modelos FH, como se muestra en la Tabla 3, (ii) el RMSE promedio de los EBLUPs a través de todas las parcelas (Tabla 4), (iii) la reducción en la incertidumbre del modelo de cada modelo FH en comparación con la incertidumbre de los estimadores directos (es decir, eficiencia relativa) (Tabla 4) y (iv) la relación entre el RMSE de cada método y el tamaño de la muestra de cada parcela (Figura 5).

La Tabla 4 compara las estimaciones promedio de AGBD y sus incertidumbres (expresadas como RMSE) entre la estimación directa y el modelo FH a través de todas las parcelas. Los resultados muestran consistentemente que las estimaciones directas de campo exhiben valores de RMSE más altos en comparación con los EBLUPs a nivel de parcela, independientemente de la ubicación o del conjunto de variables auxiliares de LiDAR utilizadas. En consecuencia, los EBLUPs a nivel de parcela siempre mejoraron la precisión respecto a las estimaciones directas. Entre los diferentes conjuntos de predictores, ALS superó a GEDI en Villaciervos, mientras que en NHHD, el desempeño de todos los conjuntos de predictores fue prácticamente idéntico, con diferencias insignificantes entre ellos. La combinación de los conjuntos de predictores de ALS y GEDI no mejoró las estimaciones en Villaciervos, ya que los predictores seleccionados fueron todas métricas de ALS. En NHHD, la combinación de ALS y GEDI resultó en un RMSE promedio de 25.80, ligeramente por debajo del RMSE obtenido cuando se usó solo ALS, 25.86, o GEDI, 26.05.

**Tabla 4.** Comparación de los valores promedio de los métodos de estimación, el error medio cuadrático, y el error medio cuadrático relativo para todas las parcelas utilizando los conjuntos de predictores de ALS y GEDI para ambos sitios de estudio. Las estimaciones del modelo Fay-Herriot se expresaron como los mejores predictores lineales insesgados (EBLUPs). *representa la mejora en la incertidumbre de los EBLUPs en porcentaje con respecto a las estimaciones directas.*



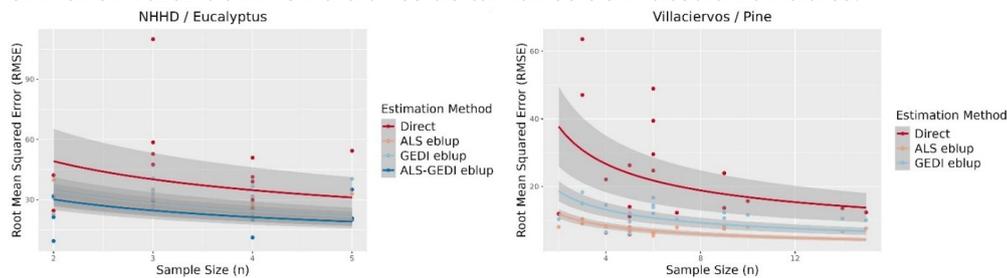
Caso de estudio      Set de predictores      Media de los estimadores directos      Media de los EBLUPs



Villaciervos / Pino	ALS	168.94	23.89	13.7%	167.12	7.63	4.7%	52%
	GEDI	163.58	11.97	7.5%			35%	
	ALS + GEDI	167.12	7.63	4.7%			52%	
NHHD /								

Las mejoras en la calibración de la biomasa con respecto a los estimadores directos también se presentan en la Tabla 4. El conjunto de predictores ALS mostró una mejora relativa del 52% para los bosques de pino y del 21% para los bosques de eucalipto. El conjunto de variables auxiliares de GEDI redujo la incertidumbre en un 35% en los bosques de pino y un 20% en los bosques de eucalipto, lo que indica una mejora sustancial en la estimación de la biomasa. Estos resultados confirman la efectividad general del modelo FH para mejorar la precisión de las estimaciones. La combinación de predictores ALS y GEDI superó a los conjuntos individuales de predictores solo en el caso del estudio NHHD y la mejora fue marginal. La Tabla 4 también indica que, en promedio, los predictores de GEDI resultaron en el mayor RMSE relativo en los bosques de pino, con un valor del 7.5% frente al 4.7% alcanzado por los predictores de ALS. Para eucalipto, por otro lado, el error relativo fue casi igual para todos los conjuntos de predictores, oscilando entre el 9.7% y el 9.8%. Estos hallazgos destacan que tanto las métricas de ALS como las de GEDI juegan un papel importante en la mejora de las estimaciones de biomasa a nivel de parcela.

Finalmente, la Figura 5 ilustra la relación entre el RMSE y el tamaño de la muestra (es decir, el número de parcelas por parcela) para cada sitio de estudio y conjunto de predictores. Como era de esperar, el RMSE disminuyó consistentemente a medida que aumentaba el tamaño de la muestra, independientemente del sitio y el método. Sin embargo, el efecto fue más pronunciado en Villaciervos debido al mayor número de parcelas. Es notable que los modelos FH (para ambos conjuntos de variables auxiliares ALS y GEDI) superaron consistentemente al método de estimación directa, como lo demuestra el menor valor de RMSE a través de tamaños de muestra variables.



**Figura 5.** RMSE vs Tamaño de la muestra: Evolución de la incertidumbre según el tamaño de la muestra (es decir, el número de parcelas de campo por parcela) para ambos sitios de estudio.

## 5. Discusión

Este estudio evaluó el uso combinado de datos ALS y GEDI en modelos FH para estimar AGBD, revelando importantes ideas y desafíos en la cuantificación de biomasa forestal. Nuestro enfoque permitió combinar datos LiDAR discretos y locales (ALS) con *footprints* de onda completa y globales (GEDI), cumpliendo con los requisitos de escala operacional para la planificación forestal. En Villaciervos, los datos ALS tuvieron un mejor desempeño que los de GEDI, consistente con investigaciones previas que muestran que ALS, con su mayor resolución espacial y cobertura completa, es adecuado para estimar atributos estructurales del bosque. Sin embargo, en las plantaciones de eucalipto de NHHD, la diferencia entre el rendimiento de ALS y GEDI fue mínima. A continuación, se discuten varios factores



que podrían explicar este rendimiento similar en NHHD.

### **Propiedades de los Datos ALS de Fotón Único**

Los datos ALS en NHHD requirieron una reclasificación de los puntos de suelo debido a problemas en áreas densamente vegetadas. Inconsistencias similares fueron observadas por BROWN (2019) usando el mismo tipo de datos ALS de fotón único. Aunque se realizó una reclasificación para aumentar el número de puntos de suelo, la mejora fue mínima. Las incertidumbres y errores en la determinación de los puntos de suelo podrían introducir ruido en las métricas ALS, degradando las estimaciones de AGBD.

### **Influencia de las Características de los Bosques**

Las características del bosque, especialmente la variabilidad interna y el tamaño del rodal, pueden explicar las diferencias entre los sitios de estudio. La variabilidad intra-rodal en ambos sitios fue diferente. A pesar de que el AGBD fue mayor en NHHD, la variabilidad interna del rodal es casi idéntica en ambos sitios. Esto probablemente redujo las posibles mejoras en el rendimiento del uso de datos ALS más precisos. Además, estudios previos han demostrado que la precisión de los modelos FH que utilizan predictores de ALS disminuye a medida que aumenta el tamaño del bosque.

### **Modelos Basados en Área y Métricas GEDI**

Los datos GEDI demostraron ser valiosos para mejorar las estimaciones de AGBD. Los modelos FH basados solo en datos GEDI mejoraron significativamente la eficiencia en la estimación de AGBD en ambos sitios, con reducciones en el RMSE del 35% en bosques de pino y del 20% en plantaciones de eucalipto. Las diferencias entre los sitios probablemente están influenciadas por las relaciones complejas entre los atributos forestales y las formas de onda GEDI. Estos resultados confirman que GEDI puede ser una fuente rentable y globalmente aplicable de información auxiliar para la estimación de biomasa, especialmente en áreas sin acceso a datos ALS. Con la extensión de la misión GEDI más allá de 2024, sus datos serán aún más valiosos para el análisis global de la estructura forestal, permitiendo análisis multitemporales que son costosos de realizar con datos ALS.

### **Desafíos en la Selección y Validación de Modelos**

La selección y validación de modelos son componentes críticos de la implementación de modelos FH. Si no se especifican y validan adecuadamente, pueden generar resultados poco confiables. En comparación con los métodos tradicionales basados en ABA, los modelos FH se desarrollan con menos datos de entrenamiento porque la modelización ocurre a nivel de rodal y con un elevado número de predictores. En nuestro caso, tuvimos un promedio de 3.5 y 6.5 parcelas por rodal (NHHD y Villaciervos, respectivamente) y consideramos medias zonales y desviaciones estándar de las variables auxiliares de LiDAR, lo que multiplicó el número de predictores por dos. Estos factores resaltan la importancia del método de selección de variables utilizado, siendo probablemente más importantes en el desarrollo de modelos FH que en los modelos ABA. Reducir el tamaño de los datos de entrenamiento mediante agregación obliga al modelador a mantener el número de predictores bajo, equilibrando la complejidad del modelo con los grados de libertad; y un mayor número de predictores aumenta las probabilidades de problemas de colinealidad que pueden conducir a cálculos inapropiados de las varianzas de EBLUP, posibles sesgos y valores grandes de VIF que reducen la confianza en el modelo.



## Predictores Seleccionados

Independientemente del conjunto de predictores utilizado, la mayoría de las variables seleccionadas incluyeron su forma agregada de desviación estándar, que parecieron tener mayor poder predictivo que los valores medios al agregar los datos a nivel de área. Esto se alinea con los hallazgos de MAURO et al. (2017). En este estudio, las métricas relevantes de ALS para predecir AGBD incluyeron la altura máxima, consistente con estudios previos. Sin embargo, también se seleccionaron predictores menos comunes, como el porcentaje de retornos de puntos de suelo y parámetros de forma de la distribución de la intensidad. Estudios previos no han operado simultáneamente múltiples conjuntos de métricas GEDI para predecir biomasa aérea; en cambio, han utilizado métricas de los productos L2A, L2A y L2B, o L4 por separado. Este estudio combinó variables de múltiples niveles de productos GEDI, incluyendo el producto L4C recientemente lanzado. Esta estrategia resultó ser efectiva para predecir AGBD, ya que las métricas de complejidad estructural L2B fueron seleccionadas en todos los modelos GEDI. En nuestro estudio, el índice de diversidad de altura del follaje (L2B) fue consistentemente seleccionado en ambos sitios de estudio y emergió como el predictor más correlacionado con AGBD. Esto indica que las métricas de complejidad vertical proporcionan información útil para predecir AGBD, y sugiere que, en bosques complejos y multinivel, las métricas que describen la complejidad vertical podrían proporcionar más información sobre AGBD que las métricas basadas en alturas relativas.

## 6. Conclusiones

Este estudio demuestra que tanto los datos ALS como los de GEDI pueden mejorar significativamente la estimación de AGBD cuando se incorporan en modelos FH. Sin embargo, la combinación de estos conjuntos de datos no redujo sustancialmente la incertidumbre de las estimaciones. Mientras que ALS generalmente supera a GEDI debido a su mayor resolución, GEDI sigue siendo una valiosa fuente de datos auxiliares, especialmente en áreas sin cobertura de datos ALS, o donde aquellos son de calidad subóptima. Esto fue particularmente evidente en el sitio de NHHD, donde GEDI tuvo un rendimiento comparable al de ALS en las estimaciones a nivel de área. Nuestros hallazgos subrayan la importancia de procedimientos estandarizados para la selección y validación de modelos FH, y enfatizan que incluso los datos de parcelas de campo con baja precisión posicional pueden integrarse eficazmente con datos de teledetección para lograr estimaciones confiables de biomasa.

## 7. Agradecimientos

José Bernardo González Mesquida ha sido financiado dentro de la convocatoria de contratos predoctorales 2022 de la Universidad de Valladolid, cofinanciada por el Banco Santander.

Francisco Mauro fue apoyado por el Programa de Excelencia María Zambrano (#E-42-2022-0000233) del Ministerio de Ciencia e Innovación y financiado por la Universidad de Valladolid y la Unión Europea-NextGeneration EU y el proyecto TLM PROJECT (PID2022-140104OA-I00).



## 8. Bibliografía

ADRAH, E.; MOHD JAAFAR, W. S. W.; BAJAJ, S.; OMAR, H.; LEITE, R. V.; SILVA, C. A.; CARDIL, A.; MOHAN, M.; 2021. Analyzing canopy height variations in secondary tropical forests of Malaysia using NASA GEDI. IOP Conf. Ser.: Earth Environ. Sci. 880 012031.

ASNER, G. P.; SOUSAN, S.; KNAPP, D. E.; SELMANTS, P. C.; MARTIN, R. E.; HUGHES, R. F.; GIARDINA, C. P.; 2016. Rapid forest carbon assessments of oceanic islands: a case study of the Hawaiian archipelago. *Carbon Balance Manag.* 11 1.

BREIDENBACH, J.; ASTRUP, R.; 2012. Small area estimation of forest attributes in the Norwegian National Forest Inventory. *Eur. J. For. Res.* 131 1255–1267.

BREIDENBACH, J.; NÆSSET, E.; LIEN, V.; GOBAKKEN, T.; SOLBERG, S.; 2010. Prediction of species specific forest inventory attributes using a nonparametric semi-individual tree crown approach based on fused airborne laser scanning and multispectral data. *Remote Sens. Environ.* 114 911–924.

BRUENING, J.; MAY, P.; ARMSTON, J.; DUBAYAH, R.; 2023. Precise and unbiased biomass estimation from GEDI data and the US Forest Inventory. *Front. For. Glob. Change* 6.

CAMPOE, O. C.; STAPE, J. L.; LACLAU, J.-P.; MARSDEN, C.; NOUVELLON, Y.; 2012. Stand-level patterns of carbon fluxes and partitioning in a *Eucalyptus grandis* plantation across a gradient of productivity, in São Paulo State, Brazil. *Tree Physiol.* 32 696–706.

DE CONTO, T.; ARMSTON, J.; DUBAYAH, R.; 2024. Characterizing the structural complexity of the Earth's forests with spaceborne lidar. *Nat. Commun.* 15 8116.

DEL RÍO, M.; BARBEITO, I.; BRAVO-OVIEDO, A.; CALAMA, R.; CAÑELLAS, I.; HERRERO, C.; BRAVO, F.; 2008. Carbon Sequestration in Mediterranean Pine Forests. In F. Bravo, R. Jandl, V. LeMay, & K. von Gadow (Eds.), *Managing Forest Ecosystems: The Challenge of Climate Change* (pp. 221–245). Springer Netherlands.

DUBAYAH, R.; ARMSTON, J.; HEALEY, S. P.; BRUENING, J. M.; PATTERSON, P. L.; KELLNER, J. R.; DUNCANSON, L.; SAARELA, S.; STÅHL, G.; YANG, Z.; TANG, H.; BLAIR, J. B.; FATOYINBO, L.; GOETZ, S.; HANCOCK, S.; HANSEN, M.; HOFTON, M.; HURTT, G.; LUTHCKE, S.; 2022. GEDI launches a new era of biomass inference from space. *Environ. Res. Lett.* 17 95001.

DUBAYAH, R.; BLAIR, J. B.; GOETZ, S.; FATOYINBO, L.; HANSEN, M.; HEALEY, S.; HOFTON, M.; HURTT, G.; KELLNER, J.; LUTHCKE, S.; ARMSTON, J.; TANG, H.; DUNCANSON, L.; HANCOCK, S.; JANTZ, P.; MARSELIS, S.; PATTERSON, P. L.; QI, W.; SILVA, C.; 2020. The Global Ecosystem Dynamics Investigation: High-resolution laser ranging of the Earth's forests and topography. *Sci. Remote Sens.* 1 100002.

DUNCANSON, L.; KELLNER, J. R.; ARMSTON, J.; DUBAYAH, R.; MINOR, D. M.; HANCOCK, S.; HEALEY, S. P.; PATTERSON, P. L.; SAARELA, S.; MARSELIS, S.; SILVA, C. E.; BRUENING, J.; GOETZ, S. J.; TANG, H.; HOFTON, M.; BLAIR, B.; LUTHCKE, S.; FATOYINBO, L.; ABERNETHY, K.; ZGRAGGEN, C.; 2022. Aboveground biomass density models for NASA's Global Ecosystem Dynamics Investigation (GEDI) lidar mission. *Remote Sens. Environ.* 270 112845.

GIARDINA, C. P.; RYAN, M. G.; BINKLEY, D.; FOWNES, J. H.; 2003. Primary production and carbon allocation in relation to nutrient supply in a tropical experimental forest. *Glob. Change Biol.* 9 1438–1450.



GUERRA-HERNÁNDEZ, J.; GÖRGENS, E. B.; GARCÍA-GUTIÉRREZ, J.; RODRIGUEZ, L. C. E.; TOMÉ, M.; GONZÁLEZ-FERREIRO, E.; 2016. Comparison of ALS based models for estimating aboveground biomass in three types of Mediterranean forest. *Eur. J. Remote Sens.* 49 185–204.

GUO, Q.; DU, S.; JIANG, J.; GUO, W.; ZHAO, H.; YAN, X.; ZHAO, Y.; XIAO, W.; 2023. Combining GEDI and sentinel data to estimate forest canopy mean height and aboveground biomass. *Ecol. Inform.* 78 102348.

HUDAK, A. T.; FEKETY, P. A.; KANE, V. R.; KENNEDY, R. E.; FILIPPELLI, S. K.; FALKOWSKI, M. J.; TINKHAM, W. T.; SMITH, A. M. S.; CROOKSTON, N. L.; DOMKE, G. M.; CORRAO, M. V.; BRIGHT, B. C.; CHURCHILL, D. J.; GOULD, P. J.; MCGAUGHEY, R. J.; KANE, J. T.; DONG, J.; 2020. A carbon monitoring system for mapping regional, annual aboveground biomass across the northwestern USA. *Environ. Res. Lett.* 15 095003.

HUNKA, N.; SANTORO, M.; ARMSTON, J.; DUBAYAH, R.; MCROBERTS, R. E.; NÆSSET, E.; QUEGAN, S.; URBAZAEV, M.; PASCUAL, A.; MAY, P. B.; MINOR, D.; LEITOLD, V.; BASAK, P.; LIANG, M.; MELO, J.; HEROLD, M.; MÁLAGA, N.; WILSON, S.; MONTESINOS, P. D.; DUNCANSON, L.; 2023. On the NASA GEDI and ESA CCI biomass maps: aligning for uptake in the UNFCCC global stocktake. *Environ. Res. Lett.* 18 124042.

KELLNER, J. R.; ARMSTON, J.; DUNCANSON, L.; 2023. Algorithm theoretical basis document for GEDI footprint aboveground biomass density. *Earth Space Sci.* 10 e2022EA002516.

KRIEGER, G.; MOREIRA, A.; FIEDLER, H.; HAJNSEK, I.; WERNER, M.; YOUNIS, M.; ZINK, M.; 2007. TanDEM-X: A Satellite Formation for High-Resolution SAR Interferometry. *IEEE Trans. Geosci. Remote Sens.* 45 3317–3341.

LI, X.; WESSELS, K.; ARMSTON, J.; DUNCANSON, L.; URBAZAEV, M.; NAIDOO, L.; MATHIEU, R.; MAIN, R.; 2024. Evaluation of GEDI footprint level biomass models in Southern African Savannas using airborne LiDAR and field measurements. *Sci. Remote Sens.* 10 100161.

LIANG, M.; GONZÁLEZ-ROGLICH, M.; ROEHRDANZ, P.; TABOR, K.; ZVOLEFF, A.; LEITOLD, V.; SILVA, J.; FATOYINBO, T.; HANSEN, M.; DUNCANSON, L.; 2023. Assessing protected area's carbon stocks and ecological structure at regional-scale using GEDI lidar. *Glob. Environ. Change* 78 102621.

LUMLEY, T.; 2020. leaps: Regression Subset Selection. <https://CRAN.R-project.org/package=leaps>.

MAGNUSSEN, S.; MAURO, F.; BREIDENBACH, J.; LANZ, A.; KÄNDLER, G.; 2017. Area-level analysis of forest inventory variables. *Eur. J. For. Res.* 136 839–855.

MAURO, F.; MONLEON, V. J.; TEMESGEN, H.; FORD, K. R.; 2017. Analysis of area level and unit level models for small area estimation in forest inventories assisted with LiDAR auxiliary information. *PLoS ONE* 12.

MAURO, F.; VALBUENA, R.; MANZANERA, J. A.; GARCÍA-ABRIL, A.; 2010. Influence of Global Navigation Satellite System errors in positioning inventory plots for tree-height distribution studies. *Can. J. For. Res.* 41 11–23.

MCROBERTS, R. E.; CHEN, Q.; GORMANSON, D. D.; WALTERS, B. F.; 2018. The shelf-life of airborne laser scanning data for enhancing forest inventory inferences. *Remote Sens. Environ.* 206 254–259.



MILENKOVIĆ, M.; REICHE, J.; ARMSTON, J.; NEUENSCHWANDER, A.; DE KEERSMAECKER, W.; HEROLD, M.; VERBESSELT, J.; 2022. Assessing Amazon rainforest regrowth with GEDI and ICESat-2 data. *Sci. Remote Sens.* 5 100051.

MOLINA, I.; MARHUENDA, Y.; 2015. sae: An R Package for Small Area Estimation. *R J.* 7 81–98.

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.

PAN, Y.; BIRDSEY, R. A.; FANG, J.; HOUGHTON, R.; KAUPPI, P. E.; KURZ, W. A.; PHILLIPS, O. L.; SHVIDENKO, A.; LEWIS, S. L.; CANADELL, J. G.; CIAIS, P.; JACKSON, R. B.; PACALA, S. W.; MCGUIRE, A. D.; PIAO, S.; RAUTIAINEN, A.; SITCH, S.; HAYES, D.; 2011. A Large and Persistent Carbon Sink in the World's Forests. *Science* 333 988–993.

PASCUAL, A.; GUERRA-HERNÁNDEZ, J.; COSENZA, D. N.; SANDOVAL-ALTELARREA, V.; 2021. Using enhanced data co-registration to update Spanish National Forest Inventories (NFI) and to reduce training data under LiDAR-assisted inference. *Int. J. Remote Sens.* 42 126–147.

R CORE TEAM; 2022. R: A Language and Environment for Statistical Computing. <https://www.R-project.org/>.

RAJAB POURRAHMATI, M.; LE MAIRE, G.; BAGHDADI, N.; FERRACO SCOLFORO, H.; ALCARDE ALVARES, C.; STAPE, J. L.; FAYAD, I.; 2024. Effects of Eucalyptus plantation characteristics and environmental factors on GEDI waveform metrics. *Int. J. Remote Sens.* 45 3737–3763.

RAO, J. N. K.; MOLINA, I.; 2015. *Small area estimation*. John Wiley & Sons.

RÄTY, M.; KANKARE, V.; YU, X.; HOLOPAINEN, M.; VASTARANTA, M.; KANTOLA, T.; HYYPPÄ, J.; VIITALA, R.; 2011. Tree biomass estimation using ALS features. *Proceedings of Silvilaser, the 11th International Conference on ALS Applications for Assessing Forest Ecosystems*, Hobart, Australia, 16–20.

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 Sens. Environ.* 251 112061.

RUIZ-PEINADO, R.; DEL RIO, M.; MONTERO, G.; 2011. New models for estimating the carbon sink capacity of Spanish softwood species. *For. Syst.* 20 176–188.

SHENDRYK, Y.; 2022. Fusing GEDI with earth observation data for large area aboveground biomass mapping. *Int. J. Appl. Earth Obs. Geoinf.* 115 103108.

STAPE, J. L.; BINKLEY, D.; RYAN, M. G.; 2004. Eucalyptus production and the supply, use and efficiency of use of water, light and nitrogen across a geographic gradient in Brazil. *For. Ecol. Manag.* 193 17–31.

STEREŃCZAK, K.; LAURIN, G. V.; CHIRICI, G.; COOMES, D. A.; DALPONTE, M.; LATIFI, H.; PULETTI, N.; 2020. Global Airborne Laser Scanning Data Providers Database (GlobALS)—A New Tool for Monitoring Ecosystems and Biodiversity. *Remote Sens.* 12.

TANG, H.; STOKER, J.; LUTHCKE, S.; ARMSTON, J.; LEE, K.; BLAIR, B.; HOFTON, M.; 2023a. Evaluating and mitigating the impact of systematic geolocation error on canopy height measurement performance of GEDI. *Remote Sens. Environ.* 291



113571.

TANG, H.; STOKER, J.; LUTHCKE, S.; ARMSTON, J.; LEE, K.; BLAIR, B.; HOFTON, M.; 2023b. Evaluating and mitigating the impact of systematic geolocation error on canopy height measurement performance of GEDI. *Remote Sens. Environ.* 291 113571.

TEMESGEN, H.; MAURO, F.; HUDAK, A. T.; FRANK, B.; MONLEON, V.; FEKETY, P.; PALMER, M.; BRYANT, T.; 2021. Using Fay–Herriot Models and Variable Radius Plot Data to Develop a Stand-Level Inventory and Update a Prior Inventory in the Western Cascades, OR, United States. *Front. For. Glob. Change* 4.

ZHANG, S.; VEGA, C.; DELEUZE, C.; DURRIEU, S.; BARBILLON, P.; BOURIAUD, O.; RENAUD, J.-P.; 2022. Modelling forest volume with small area estimation of forest inventory using GEDI footprints as auxiliary information. *Int. J. Appl. Earth Obs. Geoinf.* 114 103072.