



2025 | 16-20
GIJÓN | JUNIO

9º CONGRESO FORESTAL ESPAÑOL

9CFE-1291

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

Organiza





El LiDAR aerotransportado de baja densidad PNOA proporciona estimaciones fiables de la altura de la base de la copa de diferentes especies del bosque Mediterráneo

VIEDMA, O (1); ALONSO PONCE, R. (2,3) Y MORENO, JM (4)

1. Departamento de Ciencias Ambientales. Facultad de Ciencias Ambientales y Bioquímica. Campus de Toledo. Universidad de Castilla-La Mancha
2. Fora Forest Technologies SLL.
3. Instituto Universitario de Investigación Gestión Forestal Sostenible iuFOR.
4. Real Academia Española de las Ciencias

Resumen

La altura de la base de la copa (CBH, por sus siglas en inglés) es un parámetro biofísico esencial en la gestión forestal y en la predicción del riesgo de incendio de copas. Sin embargo, medir la CBH sigue siendo un desafío. En este estudio, utilizamos el paquete LadderFuelsR en R para estimar la CBH con datos LiDAR de baja densidad. Nuestro objetivo fue predecir los CBH medidos en campo a partir de los CBH derivados de LiDAR en varias especies de la península Ibérica, incluidas especies de coníferas (*Pinus pinea*, *P. halepensis* y *P. pinaster*) y especies caducifolias (*Quercus petraea*, *Q. pyrenaica* y *Fagus sylvatica*).

Se realizaron regresiones lineales univariadas entre las medidas en campo y los parámetros de CBH derivados de LiDAR, así como regresiones con combinaciones emparejadas de las variables de LiDAR. Para garantizar modelos de regresión lineal robustos, aplicamos varias pruebas y comprobamos hipótesis sobre la pendiente y la intersección de los modelos de regresión, así como las distribuciones de las CBH medidas en campo y las derivadas de LiDAR. En general, los CBH de las coníferas se predijeron mejor que los de las caducifolias. Los mejores modelos explicaron la variabilidad de CBH con un R^2 ajustado que osciló entre 0,93 y 0,68.

Palabras clave

Gestión del riesgo de incendio, biodiversidad forestal, estructura forestal, variables dendrométricas

1. Introducción

La estructura vertical de los combustibles, como la altura de la base de la copa de los árboles (CBH: canopy base height) y la presencia de estratos de combustible sub-dosel influye en el riesgo de inicio de incendios de copas (Menning & Stephens, 2007). Los incendios de copas se propagan mucho más rápido que los incendios de superficie, arden con mayor severidad, producen llamas más altas y, por lo tanto, son más destructivos y difíciles de controlar (Mitsopoulos & Dimitrakopoulos, 2014). Consecuentemente, se requiere de datos espacialmente explícitos sobre la CBH y la presencia de combustibles en escalera, entre otros parámetros para



minimizar los efectos del fuego (Fernandes, 2013; Forbes et al., 2022).

La tecnología LiDAR (Light Detection and Ranging) ha transformado el estudio de las estructuras forestales debido a su capacidad para penetrar los doseles forestales y evaluar estructuras sub-dosel, convirtiéndose en una herramienta fundamental para mejorar el modelado de incendios y la gestión de combustibles (Popescu & Zhao, 2008). Sin embargo, la estimación precisa y automática de la CBH desde LiDAR sigue siendo una tarea complicada.

Existen dos grandes aproximaciones para derivar la CBH a partir de LiDAR: los métodos indirectos y directos. Los primeros consisten en aproximaciones, a escala de parcela o de pixel, basadas en modelos de regresión empíricos entre las medidas de campo y las métricas LiDAR derivadas de estadísticos de frecuencia de la distribución de la altura (percentiles, kurtosis, entre otros) y de densidad de puntos a diferente rango de altura (Botequim et al., 2019; Erdody & Moskal, 2010; Moran et al., 2020; Olszewski & Bailey, 2022). Por el contrario, los métodos directos estiman la CBH de árboles individuales directamente a partir de la nube de puntos LiDAR, sin necesidad de mediciones de campo, lo que los hace más flexibles para estimar la CBH en bosques con diferentes especies (Luo et al., 2018). Los métodos directos se basan en perfiles que representan la distribución vertical de las alturas LiDAR de árboles individuales o rodales (Zhao et al., 2011), y que se voxelizan de manera que los rangos de altura LiDAR (height bins) se convierten en píxeles volumétricos que contienen la frecuencia de retornos de láser dentro de un espacio tridimensional (XYZ). A partir de estos perfiles verticales voxelizados, la CBH se corresponde con la altura donde la frecuencia de retornos disminuye abruptamente en comparación con un mayor número de retornos en rangos de altura superiores (Popescu and Zhao, 2008). Para ello, se han desarrollado diferentes aproximaciones. Uno de los enfoques más utilizado consiste en ajustar diferentes funciones matemáticas a los perfiles verticales y calcular la primera y la segunda derivada para estimar máximos o mínimos locales (Luo et al., 2018; Muss et al., 2011; Stefanidou et al., 2020; Sumnall et al., 2016; Zhao and Popescu, 2009). Otras aproximaciones más simplificadas utilizan el método de los vóxeles ocupados/no ocupados y estiman la CBH detectando huecos o estratos de combustible si el número de puntos en el vóxel es menor/mayor o igual al umbral establecido (García et al., 2011; Maguya et al., 2015) o basándose en las diferencias de percentiles entre rangos de altura del perfil vertical, utilizan la mayor diferencia de cuantiles para determinar la CBH (Chamberlain et al., 2021; Solberg et al., 2006). Recientemente, otra aproximación basada en las diferencias de los percentiles de LAD (densidad de área foliar) entre rangos de altura del perfil, permite identificar los vacíos y estratos de combustible, así como la CBH utilizando diferentes criterios (paquete LadderFuelsR) (Viedma et al., 2024).

2. Objetivos

El principal objetivo de este trabajo consiste en predecir los CBHs de diferentes especies del género *Pinus* y fagáceas medidas en campo mediante modelos de regresión lineales sencillos y robustos a partir de datos LiDAR de baja densidad (LiDAR PNOA). Para ello, utilizaremos el método que ofrece el paquete

LadderFuelsR (Viedma et al. 2024), basado en la voxelización del perfil vertical de árboles individuales, y que permite derivar la CBH directamente de los datos LiDAR usando diferentes criterios.

3. Metodología Zona de estudio

Se analizaron varias parcelas circulares (de 625 m² de superficie) con diferentes especies ubicadas en la España peninsular: coníferas (*Pinus pinea* [n=29, 1116 árboles], *Pinus halepensis* [n=58, 1678 árboles] y *Pinus pinaster* [n=31, 1124 árboles]) y fagáceas (*Quercus petraea* [n=47, 1182 árboles], *Q. pyrenaica* [n=35, 1601 árboles] y *Fagus sylvatica* [n=41, 1373 árboles]). Las masas de *P. pinea* y *P. pinaster* se localizaron en la Comunidad de Madrid, las de *P. halepensis* en Aragón y las de *Quercus* y *Fagus sylvatica* en Palencia (Fig. 1).

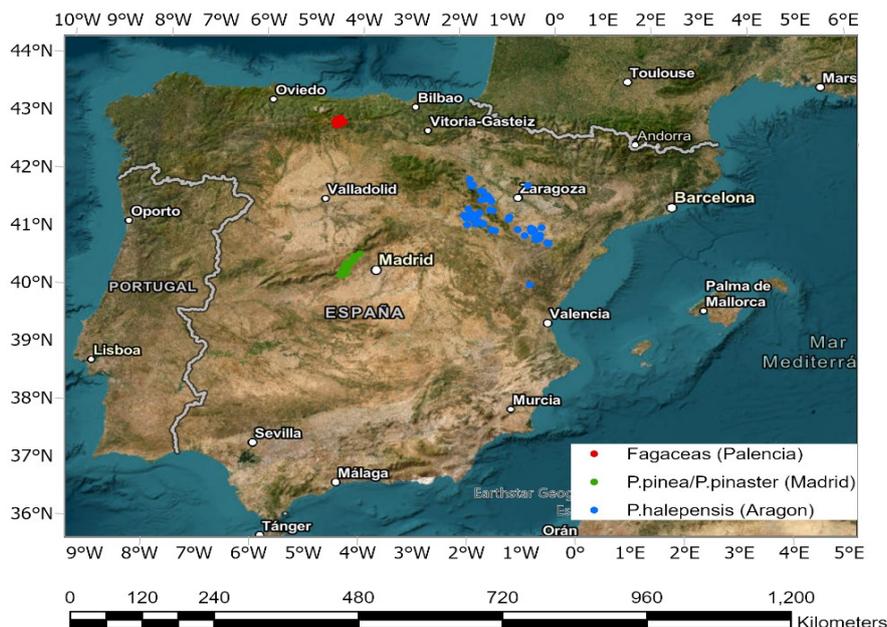


Figura 1. Localización de las parcelas de diversas especies de *Pinus* y fagáceas en las que se tomaron medidas de la base de la copa de los árboles (CBH). En rojo, las parcelas de fagáceas: *Quercus petraea*, *Q. pyrenaica* y *Fagus sylvatica*. En verde, las parcelas de *Pinus pinea* y *P. pinaster*; y en azul las parcelas de *Pinus halepensis*.

En cada parcela se anotaron los diámetros normales (dn, cm) de todos los árboles con $dn \geq 7.5$ cm mediante dos mediciones en cruz con forcípula, se registró su especie, y se midieron las alturas totales y las alturas de la base de la copa de los 6 árboles dominantes, mediante Vertex IV Haglöf. Con esas seis alturas totales se calculó la altura dominante mediante el criterio de Assmann. Las alturas totales y de la base de la copa del resto de árboles fueron calculadas posteriormente

mediante ecuaciones altura-diámetro generalizadas, y con ecuaciones alométricas con asíntota en la altura total, respectivamente, para cada especie y zona de estudio. Por último, se tomaron con precisión submétrica las coordenadas del centro de cada parcela.

La caracterización general de estas masas indicó que los árboles de *P. pinaster* mostraron la mayor altura (15.2 m) y la CBH más alta (9.0 m) según sus valores de mediana (Tabla 1). Por el contrario, los árboles de *P. halepensis* tuvieron la menor altura mediana (8.2 m) y una CBH relativamente baja (4.2 m); aunque en algunos casos pueden no tener un dosel bien definido o un dosel muy cerca del suelo (CBH min: 0). En una situación intermedia se encontraron los árboles de *P. pinea* con una altura mediana de casi 12 m y una CBH de casi 5 m (Tabla 1). Finalmente, los árboles de fagáceas mostraron una altura entre 12-14 m, y una CBH alrededor de 6 m, aunque *F. sylvatica* y *Q. petraea* presentaron unas CBH mínimas muy bajas lo que sugiere que estas especies puede mantener doseles más cercanos al suelo en comparación con otras especies de similar altura (Tabla 1).

Tabla 1. Estadísticas básicas de la altura de los árboles y de la altura de la base de la copa medidas en campo. Se muestran los valores medianos y desviación estándar, así como los valores mínimos y máximos. En paréntesis se muestra el código numérico que le corresponde a cada especie en el Inventario Nacional forestal (IFN).

P. pinea
P. halepensis
P. pinaster
Q. petraea
Q. pyrenaica
F. sylvatica

Procesamiento de los datos LiDAR



Las imágenes LiDAR se obtuvieron del 2.º Vuelo Nacional LiDAR de España (2015-2021) en secciones de 2 x 2 km y se descargaron del Instituto Geográfico Nacional (IGN) (<https://centrodedescargas.cnig.es/CentroDescargas/catalogo>). Cada pulso tiene hasta 4 retornos, y la densidad promedio de puntos por metro cuadrado es entre 0.5 y 2 puntos/m² (disponible en: <https://pnoa.ign.es/web/portal/pnoa-lidar/especificaciones-tecnicas>).

Los datos LiDAR fueron preprocesados utilizando el software LasTools: (i) eliminación de pulsos duplicados; (ii) filtrado de los pulsos para eliminar ruido (iii) clasificación de los últimos retornos en clases de suelo y no-suelo desnudo utilizando el filtro de densificación propuesto por Axelsson (Axelsson, 2000); y (iv) normalización de la altura original de los pulsos LiDAR en relación con el nivel del suelo. A continuación, se calculó el Modelo de Altura del Dosel (CHM: canopy height model) utilizando el método “*pit-free*”, a una resolución de 2 m (Khosravipour et al., 2016). Este algoritmo fue implementado utilizando el paquete LidR (Roussel et al., 2018).

Posteriormente, se segmentaron las copas individuales de los árboles a partir del CHM y de los datos de altura normalizada del LiDAR utilizando el algoritmo de cuencas hidrográficas (*watershed*) implementado en el paquete LidR (Roussel et al., 2018). La altura mínima para que un árbol fuera considerado en la segmentación se estableció en 4 metros. A continuación, se recortaron los retornos LiDAR normalizados dentro de los polígonos de las copas (utilizando LidR), creando un archivo único para cada árbol. Luego, se generaron vóxeles (2x2x1 m) para cada árbol utilizando el paquete leafR (de Almeida et al., 2019). A partir de estos vóxeles, se calculó un perfil de densidad de Área Foliar (LAD: *leaf area density*) en intervalos de 1 m para cada árbol (de Almeida et al., 2019). Estos perfiles fueron depurados para retener solo árboles con al menos 10 puntos y 5 rangos de altura (intervalos de 1 m). A partir del perfil LAD, se calculó el Índice de Área Foliar Total (LAI: *leaf area index*), que mide el área foliar total en relación con el área del suelo, junto con el LAI del sotobosque, enfocado específicamente en la capa de vegetación baja (0.3–2.5 m).

Finalmente, se aplicó la metodología desarrollada en LadderFuelsR para obtener las métricas de CBH (Viedma et al., 2024), siguiendo un flujo de trabajo secuencial disponible en <https://github.com/olgaviedma/LadderFuelsR> (consultado el 9 de enero de 2025) (Tabla 2). El paquete requiere como entrada una base de datos con tres columnas: un identificador único del árbol (*treeID*), la variable a medir (*LAD*) y los rangos de altura donde se registran dichas mediciones. En este análisis, se emplearon todos los valores predeterminados de los parámetros que ofrece el paquete (Viedma et al., 2024). Se utilizaron 3 de los 5 métodos que LadderFuelsR proporciona para identificar la CBH: i) la capa de combustible que posee el porcentaje máximo de LAD en el perfil del árbol (MAXLAD_cbh), ii) la capa de combustible identificada por el método de puntos de corte y que posee un % LAD (BP_cbh) y (iii) la capa de combustible ubicada por encima del punto de corte sin considerar el % LAD (BR_cbh) (Tabla 2).

Tabla 2. Métricas derivadas de LadderFuelsR para estimar la altura de la base de

distintos estratos de combustible (F1 y F2: primero y segundo estrato); así como de la copa de los árboles utilizando diferentes métodos: máximo % LAD [MXLAD_cbh], puntos de corte + % LAD [BP_cbh] y solo puntos de corte [BR_cbh].

Variable	Definición
F1_cbh	F1_cbh Altura de la base de la primera capa de combustible (m).
F2_cbh	F2_cbh Altura de la base de la segunda capa de combustible (m).
MXLAD_cbh	MXLAD_cbh Altura de la base del dosel utilizando el método de "LAD máximo %" (m).
BP_cbh	BP_cbh Altura de la base del dosel de la capa de combustible identificada por el método modificado de "punto de corte" (m).
BR_cbh	BR_cbh Altura de la base del dosel identificada por el método original de "punto de corte" (m).
MAX_height	MAX_height Altura máxima del perfil del árbol (m).

Análisis estadístico



Para relacionar los valores de campo con los de LiDAR las áreas de las parcelas se intersectaron con los polígonos de los árboles segmentados previamente. Como en la mayor parte de las parcelas, el número de árboles LiDAR interceptados no coincidía con el número de árboles medidos en campo, se calcularon percentiles (p50, p75, p90, p95, p99). De esta manera, se realizaron regresiones lineales univariadas entre la CBH de campo y las métricas de CBH derivadas de LiDAR por percentiles. Además, se realizaron regresiones con combinaciones pareadas de estas variables de LiDAR contra la CBH de campo para evaluar su poder predictivo combinado. Hay que indicar que la interpretación de los interceptos en las regresiones debe hacerse con precaución. Dado que el valor mínimo de las métricas CBH derivadas de LiDAR es 1.5 m y no es posible que estas variables sean 0, el intercepto en los modelos no tiene una interpretación física. Por esta razón, es necesario interpretar los interceptos como un valor que ajusta el modelo para compensar diferencias en las escalas de las variables, y que la presencia de interceptos negativos no impacta la calidad del modelo.

Finalmente, para obtener modelos de regresión lineal robustos, aplicamos diferentes pruebas y verificamos diversas hipótesis. Primero, eliminamos valores atípicos utilizando la distancia de Cook, aplicando la regla general para identificar observaciones potencialmente influyentes. Además, comprobamos la multicolinealidad utilizando el Factor de Inflación de la Varianza (VIF) y establecimos un criterio de $VIF \leq 5$ (correlación moderada). Posteriormente, evaluamos la adecuación de los modelos lineales entre observados y predichos mediante el test de Sterba que prueba simultáneamente la hipótesis de que la pendiente no difiere significativamente de 1 y que el intercepto del modelo de regresión no difiere significativamente de 0. Si el valor p de la prueba es > 0.05 , indica simultaneidad y un ajuste correcto del modelo. Finalmente, aplicamos las pruebas no paramétricas de Kolmogorov-Smirnov (Prueba KS) para comparar si las distribuciones acumulativas de las CBH de campo y cada métrica de CBH de LiDAR por parcela eran significativamente diferentes, y el test de Wilcoxon (Prueba Wilk) para comparar si los valores medianos de las muestras eran significativamente diferentes. Todos estos análisis se realizaron en el programa R.

4. Resultados

Distribución de los valores de CBH derivados de LiDAR

La caracterización de las parcelas según los datos LiDAR indicaron que las masas de *P. pinaster* presentaron los valores más altos en todas las métricas de CBH (desde 4.5 m en la CBH de la primera capa de combustible (F1_cbh) hasta > 8 m en los CBHs definidos por el método de los puntos de corte (BP_cbh y BR_cbh), confirmando los datos de campo (Tablas 1 y 3). Sin embargo, las diferencias entre la altura de la base de la primera capa de combustible (4.5 m) y la de la copa, así como entre las CBHs derivados por diferentes métodos indica que dosel no está bien definido y que hay otros estratos de combustible bajo el dosel en algunas parcelas (Tabla 3). Por el contrario, las masas de *P. halepensis* presentaron los valores de CBH más bajos y más consistentes entre las métricas LiDAR (CBH: 3.5 m), lo que refleja un dosel más homogéneo y bajo en comparación con otras



especies de *Pinus*, y estando en concordancia con los datos de campo (Tablas 1 y 3). Finalmente, las masas de *P. pinea* se encontraron en un punto intermedio (CBH: 5-7 m) y con la presencia de algunos árboles con vegetación bajo el dosel (F1_cbh: 3.5 m) (Tabla 3).

Entre las fagáceas, las masas de *F. sylvatica* mostraron la CBH más alto (3.5-4.5 m) mientras que las de *Q. petraea* y *Q. pyrenaica* presentaron valores de CBH más bajos (1.5–2.5 m) (Tabla 3). En todos los casos, los valores de LiDAR fueron más bajos que los cuantificados en campo (Tabla 1). Además, los valores de la CBH basada únicamente en los puntos de corte (BR_cbh) fueron extremadamente altos (> 8 m) indicando que hay una organización multicapa o ramificada donde la mayor parte del LAD está a una menor altura separándose de una capa de combustible superior con poco LAD.

Tabla 3. Estadísticas básicas de la altura de la base del primer estrato de combustible (F1_cbh) y de la copa de los árboles, definida por varios métodos (máximo % LAD [MXLAD_cbh], puntos de corte + % LAD [BP_cbh] y solo puntos de corte [BR_cbh]). Se muestran los valores medianos y desviación estándar, así como los valores mínimos y máximos.

Tests de diferencias entre los valores de CBH medidos en campo y los derivados de LiDAR

El 100 % de las parcelas de *P. pinea* y el 76 % de las parcelas de *P. pinaster* mostraron distribuciones similares entre la CBH medida en campo y la métrica CBH de LiDAR basada en el método del punto de corte + % LAD (BP_cbh) (Fig. 3); que fue la más seleccionada en los modelos de regresión (Tabla 4). En el caso de *P. halepensis* solo el 32 % de las parcelas no presentaron diferencias significativas. Por el contrario, gran parte de las parcelas de especies fagáceas mostraron diferencias significativas entre la CBH medida en campo y el BP_cbh en ambos test: *F. sylvatica* (62 %) *Q. petraea* (69 %), y *Q. pyrenaica* (81.5 %). Por tanto, las

distribuciones difirieron tanto en forma como en tendencia central (Fig. 2). Por otro lado, se dieron bastantes casos en los que el KS test fue significativo pero el test Wilk, no. En estos casos, las dos distribuciones (campo vs LiDAR) difirieron en forma o dispersión, pero las tendencias centrales (las medianas) no fueron significativamente diferentes. Las situaciones más llamativas se encontraron en *P. halepensis* (30 % de las parcelas) y *Q. petraea* (23 %) (Fig. 2).

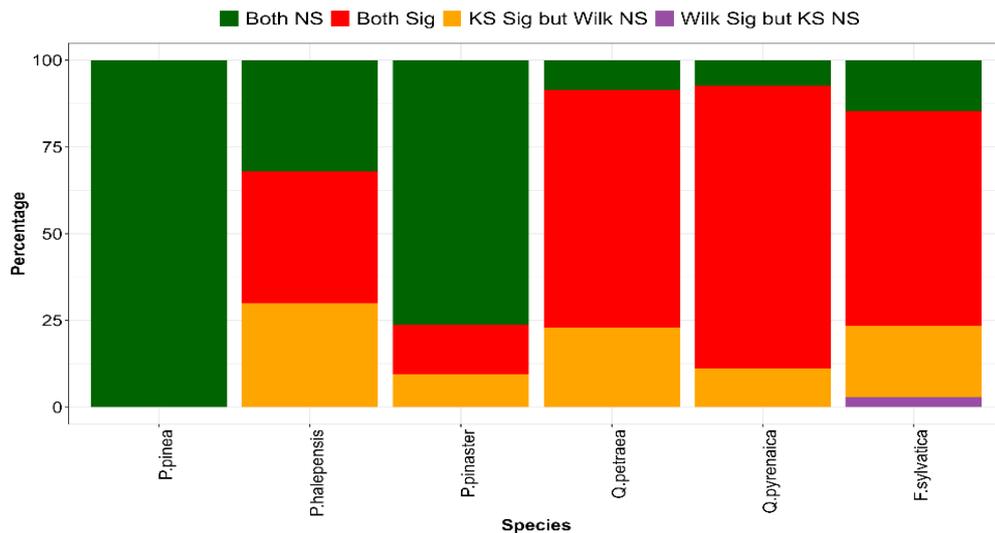


Figura 2. Porcentaje de parcelas que mostraron diferente comportamiento entre la CBH de campo y la CBH de LiDAR (BP_cbh) en función de los tests de diferencias. En verde, las parcelas cuya función de distribución acumulada de la CBH de campo (Wilcoxon test: Wilk) y sus valores medianos (Kolmogorov-Smirnov test: KS) no fueron significativamente diferentes (Both NS). En rojo, cuando ambos tests fueron significativos (Both Sig). En naranja, cuando la función de distribución es diferente pero los valores medianos no lo son (KS Sig. but Wilk. NS); y en morado, cuando las medianas difieren, pero la forma de la distribución de los datos; no (Wilk. Sig but KS NS).

Modelos predictivos de la CBH medido en campo a partir de métricas de CBH derivadas directamente de LiDAR

La CBH de las masas de *Pinus* fue correctamente predicha por la CBH de LiDAR basada en el método de los puntos de corte y modulado por el % LAD (BP_cbh) con un $R^2 > 0.80$ (Tabla 4 y Fig. 3). Los modelos predichos para *P.pinea* y *P.pinaster* cumplieron con todos los tests establecidos, fundamentalmente el test de Sterba; mientras que la CBH de *P.halepensis* solo fue correctamente predicha, cumpliendo el test de Sterba, cuando se incluyó la altura del árbol (MAX_height) en la ecuación (R^2 0.92) (Tabla 4 y Fig. 3). En el caso de las fagáceas, solo la CBH de los *Q.pyrenaica* fue correctamente predicha por la CBH de LiDAR (BP_cbh y BR_cbh) con un $R^2 > 0.8$ (Tabla 4 y Fig. 4). En el resto de fagáceas, la altura máxima del árbol fue el mejor predictor de la CBH ($R^2 > 0.75$), seguido de las CBH de LiDAR basadas en los puntos de corte (BP_cbh y BR_cbh); aunque violando el test de Sterba de simultaneidad

(Tabla 4 y Fig. 4).

Tabla 4. Mejores modelos de regresión lineal para predecir la CBH medida en campo a partir de las métricas de CBH derivadas directamente de LiDAR. Las especies con asterisco indican que su modelo predictivo cumple con el test de simultaneidad de Sterba.

MADRID	P90th	<i>P.pinea*</i>	$-1.47 + 0.73 * BP_cbh + 0.36 * F1_cbh$	0.87
MADRID	P90th	<i>P.pinea*</i>	$-0.41 + 0.94 * BP_cbh$	0.83
ARAGON	P50th	<i>P.halepensis*</i>	$-2.78 + 0.29 * MAX_height + 0.62 * BP_cbh$	0.82
ARAGON	P75th	<i>P.halepensis</i>	$0.00 + 0.97 * BP_cbh$	0.85
MADRID	P50th	<i>P.pinaster*</i>	$0.12 + 0.59 * MXLAD_cbh + 0.66 * BR_cbh$	0.91
MADRID	P50th	<i>P.pinaster*</i>	$3.67 + 0.76 * BP_cbh$	0.86
PALENCIA	P50th	<i>Q.petraea</i>	$-1.85 + 0.5 * MAX_height$	0.85
PALENCIA	P99th	<i>Q.petraea</i>	$3.86 + 0.47 * BP_cbh + 0.42 * F2_cbh$	0.77
PALENCIA	P95th	<i>Q.pyrenaica*</i>	$-0.5 + 0.52 * BP_cbh + 0.35 * BR_cbh$	0.83
PALENCIA	P99th	<i>Q.pyrenaica*</i>	$-0.02 + 0.39 * BP_cbh + 0.35 * BR_cbh$	0.84
PALENCIA	P50th	<i>F.sylvatica</i>	$-1.05 + 0.38 * MAX_height$	0.76
PALENCIA	P90th	<i>F.sylvatica</i>	$0.44 + 0.36 * BR_cbh + 0.25 * BP_cbh$	0.59

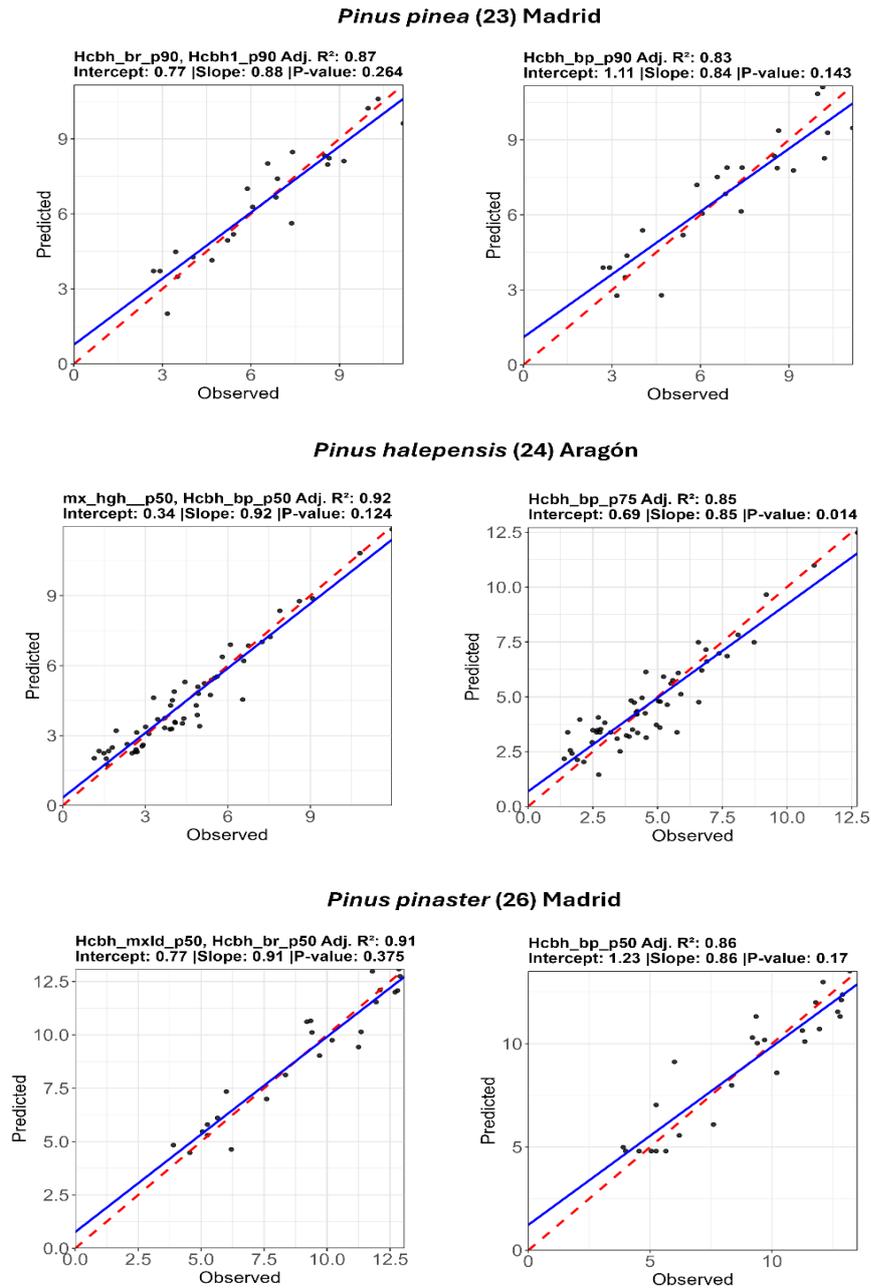


Figura 3. Predichos frente a observados de los mejores modelos de regresión lineal para predecir la CBH de las especies de *Pinus* medida en campo a partir de las métricas de CBH derivadas directamente de LiDAR. El p-valor se refiere al test simultáneo de Sterba.

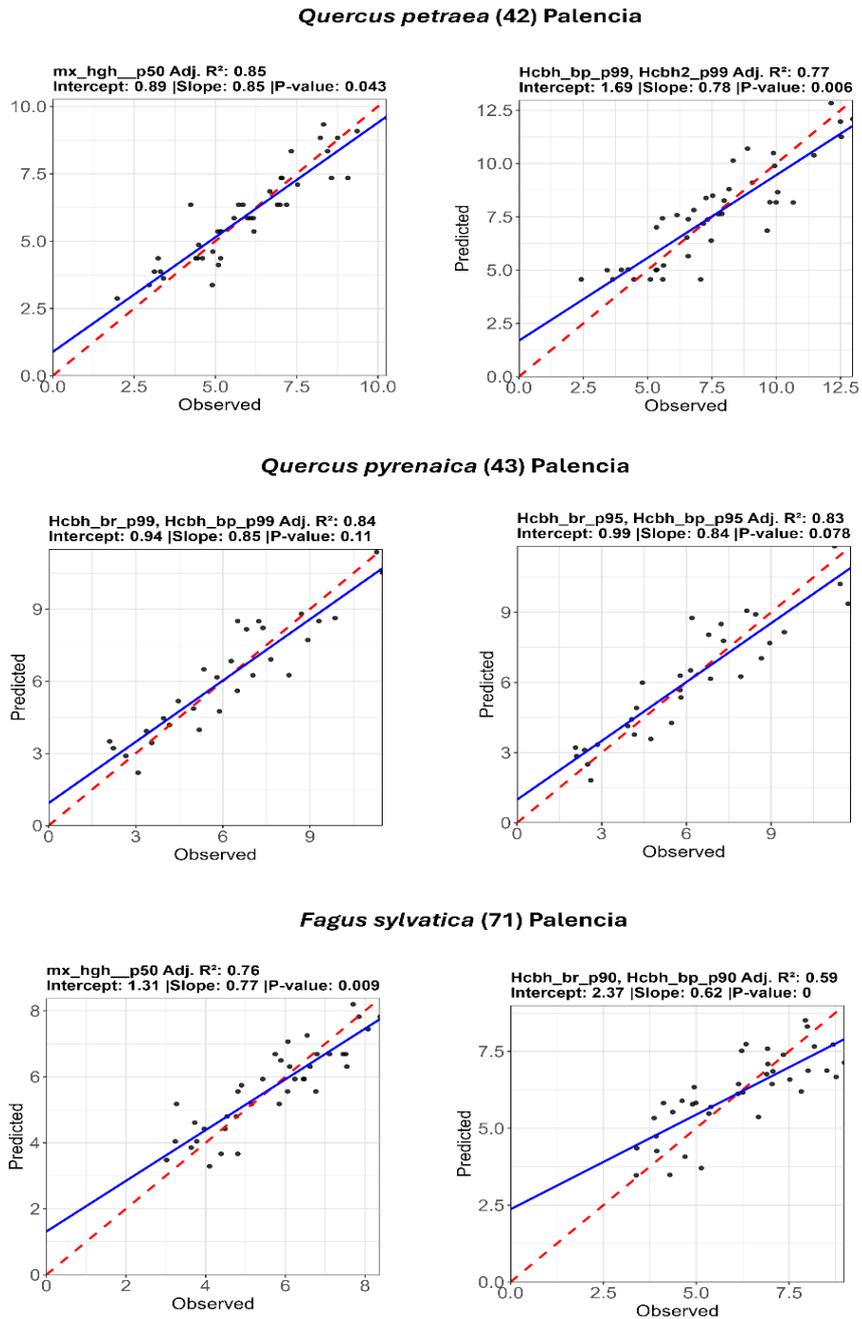


Figura 4. Predichos frente a observados de los mejores modelos de regresión lineal para predecir la CBH de las especies de fagáceas medida en campo a partir de las métricas de CBH derivadas directamente de LiDAR. El p-valor se refiere al test simultáneo de Sterba.

5. Discusión

Los grandes incendios de nueva generación requieren identificar áreas arboladas con las CBHs bajas y con cargas de combustible excesivas, con el objetivo de



priorizar una red de tratamientos selvícolas adecuados para minimizar la alta intensidad y severidad de los incendios, y mantener entornos resilientes al fuego (Fernandes, 2013; Regos et al., 2023). Sin embargo, la estimación precisa y directa de la CBH desde LiDAR para árboles individuales o parcelas sigue siendo una tarea desafiante.

En este trabajo se ha observado que la CBH de las especies de coníferas se explicó mejor que la de las especies de fagáceas. Además, las variables de CBH LiDAR medidas en los percentiles ≥ 75 mostraron modelos más precisos. Por otro lado, el BP_cbh (basado en el método del punto de corte y modulado por el % LAD) fue el mejor predictor de la CBH. Esta métrica LiDAR ha demostrado ser muy resistente a los efectos negativos de la baja densidad de puntos (Viedma et al. en prensa). Por otro lado, la inclusión de la altura del árbol como predictor mejoró la predicción de la CBH, pero algunos de esos modelos no cumplieron con las pruebas de multicolinealidad y simultaneidad. En general, los modelos predictivos en las especies de fagáceas tendieron a sobrestimar los valores más bajos de la CBH de campo (intercepto mayor que 0) mientras que infravaloraron los valores más altos de CBH (pendiente menor que 1). Esto puede explicarse por el propio temperamento de las especies implicadas, ya que los tres pinos evaluados, contrariamente a las fagáceas estudiadas, son taxones intolerantes y por consiguiente suelen presentar auto poda a edades más tempranas, con lo que es más probable que presenten copas mejor definidas y separadas de combustibles bajo ellas (Keeley and Zedler, 1998). La CBH derivado de ecuaciones alométricas son más imprecisas en rodales naturales complejos, debido a la existencia de árboles de pequeño diámetro y arbustos (Mitsopoulos and Dimitrakopoulos, 2014). Estos resultados subrayan el papel fundamental de la densidad de pulsos LiDAR para caracterizar con precisión las estructuras del combustible forestal y sus implicaciones en la evaluación del riesgo de incendios. La baja densidad de pulsos introduce sesgos sistemáticos, especialmente en árboles con copas densas, donde los efectos de ocultamiento distorsionan la delimitación de las capas de combustible. Reconocer estas limitaciones es esencial para mejorar los modelos de comportamiento del fuego, que se basan principalmente en datos LiDAR de resolución baja a moderada a escala nacional.

En los estudios basados en métodos indirectos de regresión, los percentiles y la asimetría de la altura y las métricas de densidad (por rangos de altura) son predictores consistentes de la CBH en áreas con poca complejidad estructural obteniendo valores de R^2 moderados en rodales de especies mixtas, con edades desiguales y sotobosques densos (Olszewski and Bailey, 2022; Stefanidou et al., 2020). Hasta ahora esta limitación se ha solventado mediante modelos de regresión adaptados y calibraciones localizadas (Sumnall et al., 2016). En general, las principales limitaciones de los modelos empíricos de CBH utilizando variables de altura LiDAR es que tienden a sobre ajustarse localmente, limitando su capacidad para generalizar predicciones (Moran et al., 2020). Asimismo, modelos de regresión simplificados (univariantes o bivariantes) a menudo no capturan la complejidad de las estructuras del dosel, lo que lleva a la generación de modelos de regresión complejos (Botequim et al., 2019). Finalmente, esta aproximación no permite capturar explícitamente la disposición espacial de la vegetación ni facilita la interpretación directa de los modelos en relación con la CBH de campo (Zhao et al.,



2011).

En contraste, los métodos directos basados en perfiles verticales voxelizados mostraron mejores resultados en bosques mixtos y heterogéneos, especialmente con altas densidades de puntos LiDAR. A pesar de ello, los métodos directos también han necesitado de algoritmos de corrección (recalibración de los umbrales usados para definir la CBH; recálculo de los puntos de corte; y ajustes específicos por parcela) especialmente en áreas con sotobosque denso o con alta variabilidad en las alturas de los árboles (Zhao and Popescu, 2009). De manera similar, García et al., (2011) a partir de datos de LiDAR terrestre predijeron la CBH con R^2 0.86, pero solo tras excluir parcelas con errores significativos debido a ramas muertas o condiciones complejas en el sotobosque. Cuando no se aplica ningún algoritmo corrector, los resultados fueron moderados (R^2 : 0.45-0.75) en la mayoría de las aproximaciones que utilizan el método directo (Chamberlain et al., 2021; Maguya et al., 2015; Solberg et al., 2006). Solo Luo et al. (2018), calculando la primera y la segunda derivada de los perfiles verticales voxelizados de LiDAR y estimando máximos o mínimos locales, derivaron la CBH directamente logrando un $R^2 > 0.88$, y siendo consistente para diferentes especies

En general, los métodos indirectos y directos de estimación de la CBH a partir de LiDAR se enfrentan a desafíos comunes. Por un lado, la interferencia de la vegetación densa y superpuesta del sotobosque que genera ruido en la señal LiDAR afectando tanto a los métodos de regresión indirecta como a los métodos directos. Por otro, en rodales con árboles de copas densas como en algunas coníferas se reduce la capacidad de penetración de los pulsos LiDAR cometiendo errores en la estimación de la CBH en ambos métodos, observando en algunos casos una sobreestimación de la CBH (Luo et al., 2018; Solberg et al., 2006; Stefanidou et al., 2020; Sumnall et al., 2016).

Finalmente, una densidad baja de puntos LiDAR restringe la detección correcta de estratos de combustible bajo el dosel. Por ejemplo, (Muss et al., 2011) indicó que para obtener perfiles verticales adecuados de la vegetación se necesitan entre 250-500 puntos/m². En este sentido, los análisis de la CBH realizados con imágenes de LiDAR terrestre (TLS: Terrestrial Laser Scanning) con mayor capacidad para penetrar y detectar las regiones inferiores de la copa mostraron diferencias estadísticamente significativas con las estimaciones de CBH obtenidas con LiDAR de baja densidad de puntos (García et al., 2011; Olszewski and Bailey, 2022).

6. Conclusiones

Este trabajo ha mostrado que las métricas de CBH derivadas del paquete LadderFuelsR son adecuadas para predecir la CBH de campo en diversas formaciones arboladas; si bien en algunas especies, propias de bosques complejos con mucho sotobosque, los modelos encontraron más limitaciones debido a la baja densidad de puntos del LiDAR PNOA. A pesar de ello, la métrica CBH de LiDAR más seleccionada en los modelos (BP_cbh) ha mostrado una gran insensibilidad a la baja densidad de puntos LiDAR dándole consistencia como predictor. Por otra



parte, el método de LadderFuelsR representa una mejora respecto a los métodos indirectos y directos en cuanto que no requiere recalibración ni reajuste en función de la estructura de la vegetación. Además, a diferencia de otros métodos directos que establecen la CBH del árbol en umbrales específicos de los cuantiles o modelan la CBH a partir de funciones de distribución complejas, nuestro enfoque permite establecer la CBH con mayor flexibilidad utilizando diferentes criterios y no requiere ajustar ninguna función matemática compleja para identificar los principales vacíos y alturas base del combustible. La principal limitación de estos resultados es que son específicos de cada tipo de ecosistema, y su aplicabilidad a bosques con diferentes especies y complejidades estructurales aún debe ser evaluada. Finalmente, las principales recomendaciones que se derivan de este trabajo son emplear LiDAR de alta resolución para capturar la vegetación bajo el dosel y utilizar métodos robustos que puedan adaptarse mejor a la heterogeneidad del bosque sin requerir ajustes posteriores.

7. Agradecimientos

Este trabajo fue financiado por el proyecto INFORICAM (PID2020-119402RB-I00), financiado por el Gobierno de España MCIN/AEI/10.13039/501100011033 y por la “Unión Europea NextGenerationEU/PRTR”.

8. Bibliografía

- BOTEQUIM, B., FERNANDES, P.M., BORGES, J.G., GONZÁLEZ-FERREIRO, E., GUERRA-HERNÁNDEZ, J., 2019. Improving silvicultural practices for Mediterranean forests through fire behaviour modelling using LiDAR-derived canopy fuel characteristics. *Int J Wildland Fire* 28, 823–839.
- CHAMBERLAIN, C.P., SÁNCHEZ MEADOR, A.J., THODE, A.E., 2021. Airborne lidar provides reliable estimates of canopy base height and canopy bulk density in southwestern ponderosa pine forests. *For Ecol Manage* 481, 118695.
- DE ALMEIDA, D.R.A., STARK, S.C., SHAO, G., SCHIETTI, J., NELSON, B.W., SILVA, C.A., GORGENS, E.B., VALBUENA, R., PAPA, D. DE A., BRANCALION, P.H.S., 2019. Optimizing the remote detection of tropical rainforest structure with airborne lidar: Leaf area profile sensitivity to pulse density and spatial sampling. *Remote Sens (Basel)* 11, 92.
- ERDODY, T.L., MOSKAL, L.M., 2010. Fusion of LiDAR and imagery for estimating forest canopy fuels. *Remote Sens Environ* 114, 725–737.
- FERNANDES, P.M., 2013. Fire-smart management of forest landscapes in the Mediterranean basin under global change. *Landsc Urban Plan* 110, 175-182.
- FORBES, B., REILLY, S., CLARK, M., FERRELL, R., KELLY, A., KRAUSE, P., MATLEY, C., O’NEIL, M., VILLASENOR, M., DISNEY, M., WILKES, P., BENTLEY, L.P., 2022. Comparing Remote Sensing and Field-Based Approaches to Estimate Ladder Fuels and Predict Wildfire Burn Severity. *Frontiers in Forests and Global Change* 5, 818713.
- GARCÍA, M., DANSON, F.M., RIAÑO, D., CHUVIECO, E., RAMIREZ, F.A., BANDUGULA, V., 2011. Terrestrial laser scanning to estimate plot-level forest canopy fuel properties. *International Journal of Applied Earth Observation and Geoinformation* 13, 636–645.
- KEELEY, J.E., ZEDLER, P.H., 1998. Evolution of life histories in *Pinus*, in: Richardson, D. (Ed.), *Ecology and Biogeography of Pines*. Cambridge University Press, pp. 219–



251.

- KHOSRAVIPOUR, A., SKIDMORE, A.K., ISENBURG, M., 2016. Generating spike-free digital surface models using LiDAR raw point clouds: A new approach for forestry applications. *International journal of applied earth observation and geoinformation* 52, 104–114.
- LUO, L., ZHAI, Q., SU, Y., MA, Q., KELLY, M., GUO, Q., 2018. Simple method for direct crown base height estimation of individual conifer trees using airborne LiDAR data. *Opt Express* 26, A562.
- MAGUYA, A.S., TEGEL, K., JUNTILA, V., KAURANNE, T., KORHONEN, M., BURNS, J., LEPPANEN, V., SANZ, B., 2015. Moving voxel method for estimating canopy base height from airborne laser scanner data. *Remote Sens (Basel)* 7, 8950–8972.
- MENNING, K.M., STEPHENS, S.L., 2007. Fire Climbing in the Forest: A Semiquantitative, Semiquantitative Approach to Assessing Ladder Fuel Hazards. *Western Journal of Applied Forestry* 22, 88-93.
- MITSOPOULOS, I.D., DIMITRAKOPOULOS, A.P., 2014. Estimation of canopy fuel characteristics of Aleppo pine (*Pinus halepensis* Mill.) forests in Greece based on common stand parameters. *Eur J For Res* 133, 73–79.
- MORAN, C.J., KANE, V.R., SEIELSTAD, C.A., 2020. Mapping forest canopy fuels in the western united states with LiDAR-Landsat covariance. *Remote Sens (Basel)* 12, 1000.
- MUSS, J.D., MLADENOFF, D.J., TOWNSEND, P.A., 2011. A pseudo-waveform technique to assess forest structure using discrete lidar data. *Remote Sens Environ* 115, 824–835.
- OLSZEWSKI, J.H., BAILEY, J.D., 2022. LiDAR as a Tool for Assessing Change in Vertical Fuel Continuity Following Restoration. *Forests* 13, 503.
- POPESCU, S.C., ZHAO, K., 2008. A voxel-based lidar method for estimating crown base height for deciduous and pine trees. *Remote Sens Environ* 112, 767–781.
- REGOS, A., PAIS, S., CAMPOS, J.C., LECINA-DIAZ, J., 2023. Nature-based solutions to wildfires in rural landscapes of Southern Europe: let's be fire-smart!. *Int. J of Wild. Fire CSIRO*, pp. 942–950.
- ROUSSEL, J.-R., AUTY, D., DE BOISSIEU, F., MEADOR, A.S., 2018. lidR: Airborne LiDAR data manipulation and visualization for forestry applications. R package version 1.
- SOLBERG, S., NAESSET, E., MARTIN BOLLANDSAS, O., 2006. Single Tree Segmentation Using Airborne Laser Scanner Data in a Structurally Heterogeneous Spruce Forest. *PERS* 72, 1369-1378.
- STEFANIDOU, A., GITAS, I.Z., KORHONEN, L., STAVRAKLOUDIS, D., GEORGOPOULOS, N., 2020. LiDAR-based estimates of canopy base height for a dense uneven-aged structured forest. *Remote Sens (Basel)* 12, 1565.
- SUMNALL, M., PEDUZZI, A., FOX, T.R., WYNNE, R.H., THOMAS, V.A., 2016. Analysis of a lidar voxel-derived vertical profile at the plot and individual tree scales for the estimation of forest canopy layer characteristics. *Int J Remote Sens* 37, 2653–2681.
- VIDEMA, O., SILVA, C.A., MORENO, J.M., HUDAK, A.T., 2024. LadderFuelsR: A new automated tool for vertical fuel continuity analysis and crown base height detection using light detection and ranging. *Methods Ecol Evol* 15, 1958-1967.
- ZHAO, K., POPESCU, S., 2009. Lidar-based mapping of leaf area index and its use for validating GLOBCARBON satellite LAI product in a temperate forest of the southern USA. *Remote Sens Environ* 113, 1628–1645.
- ZHAO, K., POPESCU, S., MENG, X., PANG, Y., AGCA, M., 2011. Characterizing forest canopy structure with lidar composite metrics and machine learning. *Remote Sens Environ* 115, 1978–1996.

