



2022
Lleida

27·1
junio · juny
julio · juliol

Cataluña
Catalunya

8º CONGRESO FORESTAL ESPAÑOL

La **Ciencia forestal** y su contribución a
los **Objetivos de Desarrollo Sostenible**

8CFE

Edita: Sociedad Española de Ciencias Forestales
Cataluña | Catalunya · 27 junio | juny - 1 julio | juliol 2022
ISBN 978-84-941695-6-4
© Sociedad Española de Ciencias Forestales

Organiza



¿Podemos estimar la calidad de estación de nuestros rodales forestales a través exclusivamente de la información de dos vuelos LiDAR?

ALONSO PONCE, R.^{1,3}, RODRÍGUEZ-PUERTA, F.^{2,3}, HERNÁNDEZ JIMÉNEZ, Á.⁴, MARTÍN-GARCÍA, S. ^{1,5}, PÉREZ-RODRÍGUEZ, F.¹. y LIZARRALDE, I.^{1,3}

¹ fora forest technologies SLL

² EifAB Universidad de Valladolid

³ Instituto Universitario de Investigación Gestión Forestal Sostenible iuFOR

⁴ Servicio Provincial de Agricultura, Ganadería y Medio Ambiente de Zaragoza - Gobierno de Aragón

⁵ LaboraTe-IBADER, Departamento de Enxeñaría Agroforestal, Universidade de Santiago de Compostela

Resumen

En este trabajo se utilizan datos de LiDAR aerotransportado de baja densidad de puntos para evaluar la calidad de estación en masas regulares de *Pinus sylvestris* y *Pinus halepensis*, de contrastados requerimientos ecológicos. Se han utilizado métodos de masa apoyados en datos LiDAR de la primera y segunda coberturas del Plan Nacional de Ortofotografía Aérea (0.5-1 pt/m²) para calcular el crecimiento en altura dominante y estimar el índice de sitio de manera espacialmente explícita, sin necesidad de conocer la edad de la masa, lo cual además posibilita proyectar con precisión a la fecha deseada cualquier inventario realizado con datos LiDAR desactualizados. Los resultados muestran que el error en la predicción del índice de sitio es suficientemente bajo para las dos especies (12.6 y 18.0%, respectivamente), si bien tienden a sobreestimarlos ligeramente en las calidades bajas y viceversa. Este procedimiento constituye un importante avance en la operatividad de los inventarios LiDAR por métodos de masa al introducir un componente dinámico a partir de dos vuelos, incluso con baja densidad de puntos, aspecto clave en planificación y gestión forestales.

Palabras clave

Inventario, índice de sitio, métodos de masa, *Pinus halepensis*, *Pinus sylvestris*.

1. Introducción

La calidad de la estación forestal es un indicador de la capacidad productiva de un lugar para a una determinada especie forestal y tipo de producto (Álvarez González et al. 2004) y normalmente es la variable conductora de cualquier modelo de crecimiento forestal (Diéguez-Aranda et al. 2009).

En el inventario forestal con tecnología LiDAR, tanto por métodos de masa como por árbol individual, la variable forestal que se predice con mayor precisión es la altura dominante (Rodríguez-Puerta et al. 2014). Aunque la densidad de la nube de puntos LiDAR está muy relacionada con la precisión alcanzable de los resultados del inventario, está muy estudiado que, para el caso del inventario por métodos de masa, la densidad de los datos del Plan Nacional de Ortofotografía Aérea (PNOA) de España es más que suficiente (Fernández-Landa et al. 2018; González-Ferreiro et al. 2014; Guerra-Hernández et al. 2016; Rodríguez-Puerta et al. 2014). Por otra parte, las nubes de puntos repetidas en el tiempo (distintas coberturas PNOA) ofrecen la oportunidad de actualizar los inventarios forestales (Fekety et al. 2015). Por otro lado, es bien conocido uno de los principales problemas del inventario LiDAR: la asincronía entre los datos de campo y los datos del vuelo LiDAR (Sullivan et al. 2014). Una posible solución a esta asincronía la encontramos en la integración de modelos de crecimiento a partir de vuelos multitemporales (Cao et al. 2016; Hopkinson et al. 2008; Zhao et al. 2018).

La información procedente de escaneos LiDAR repetidos en el tiempo igualmente ha probado su eficacia como fuente de datos para ajustar ecuaciones altura dominante – edad tanto en masas monoespecíficas y regulares (Socha et al. 2020, 2017) en Centroeuropa como en otras más complejas específica y estructuralmente (Tompalski et al. 2015) en Norteamérica. Recientemente, Guerra-Hernández et al. (2021) también utilizaron exitosamente este tipo de datos, además con baja densidad de puntos y combinados con información abiótica, para desarrollar un modelo de índice de sitio para *Pinus pinaster* en Galicia.

No obstante, la serie de vuelos multitemporales no solo puede resolver problemas de asincronía de datos y ser fuente de información para alimentar modelos basados en la altura de los árboles, sino que también es una herramienta muy útil para construir una sola vez los modelos de inventario y aplicarlos tantas veces como vuelos LiDAR haya. Esta aplicación del mismo modelo sobre diferentes vuelos se conoce en la literatura forestal como transferibilidad de ecuaciones LiDAR, y ha sido empleada por diferentes autores en múltiples especies y áreas geográficas (Domingo et al. 2019; Fekety et al. 2018; Navarro et al. 2020).

Finalmente, los Diagramas de Manejo de Densidad (DMD) son unas de las herramientas más utilizadas para proyectar el crecimiento de las masas forestales (Bravo et al. 2011) sin necesidad de contar con la edad de la masa, pero sí de la calidad de estación. Estos DMD se basan en el control del espaciamiento a través de la densidad de la masa. Diversos autores los han empleado de forma satisfactoria en multitud de ecosistemas forestales (Barrio Anta y Álvarez González 2005; Castedo-Dorado et al. 2009; Drew y Flewelling 1979; Newton 1997; Williams 1994).

2. Objetivos

El objetivo de este trabajo es evaluar si es factible estimar con precisión suficiente el índice de sitio en masas monoespecíficas y regulares a partir de dos coberturas de LiDAR aerotransportado de baja densidad de puntos, sin necesidad de conocer la edad de la masa. El cálculo de dicho índice de sitio posibilitaría a su vez el empleo de diagramas de manejo de densidad para el cálculo de existencias a la fecha deseada, independientemente del momento de ejecución de los vuelos LiDAR.

3. Metodología

Datos de campo y áreas de estudio

En este trabajo se han empleado dos fuentes de datos de campo (Figura 1):

- a. Treinta parcelas temporales circulares (400 m²) ubicadas en masas monoespecíficas naturales y repobladas de *Pinus sylvestris* en la Sierra de Guadarrama (MUP 148, 154 y 157 de la Comunidad de Madrid), medidas en octubre de 2020.
- b. Cuarenta y nueve parcelas temporales circulares localizadas en masas repobladas de *Pinus halepensis* distribuidas por diferentes MUP de las provincias de Zaragoza y Teruel, medidas en abril de 2017. La superficie de las parcelas fue de 100, 225, 400 o 625 m², dependiendo de la densidad de la masa.

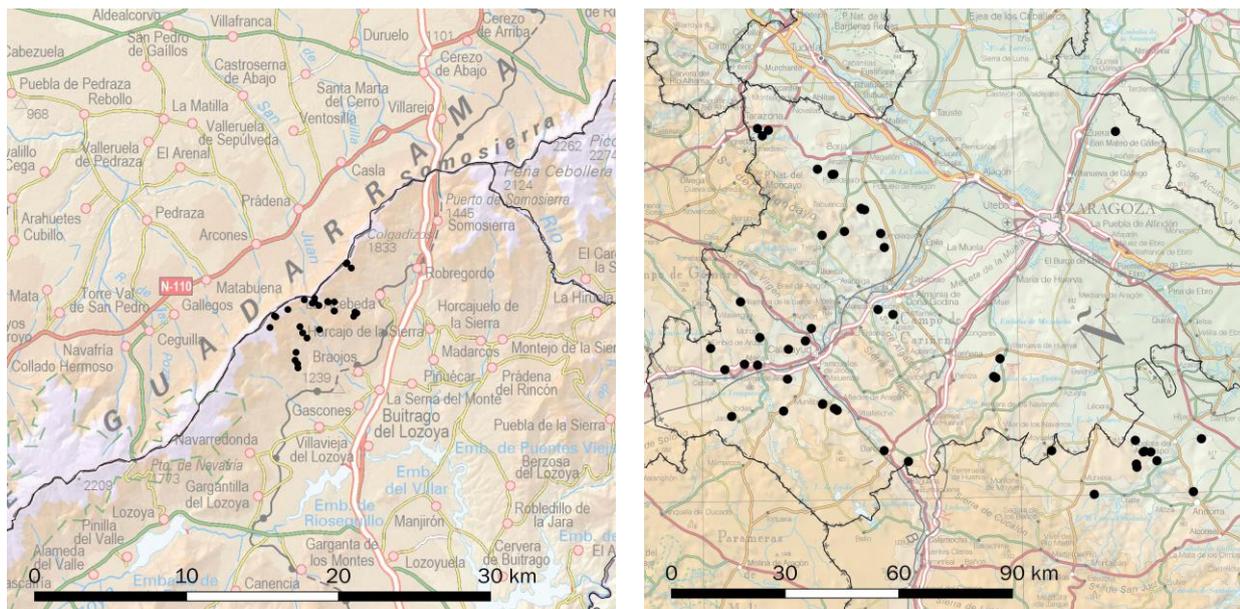


Figura 1. Localización de los dos grupos de parcelas empleadas como fuente de datos de campo: *Pinus sylvestris* (izq., Comunidad de Madrid) y *Pinus halepensis* (dcha., Aragón).

En ambos casos, todas las parcelas cuentan con doble cobertura LiDAR del Plan Nacional de Ortofotografía Aérea (PNOA), y sus coordenadas centrales fueron registradas con precisión submétrica mediante un GPS Trimble Geo7. En todas las parcelas se midieron (entre otras variables) todos los diámetros normales con precisión milimétrica y se tomó una muestra suficiente de alturas totales con precisión decimétrica para poder calcular la altura dominante según el criterio de Assmann. Además, se extrajeron sendas barrenas en la base de dos árboles dominantes de cada parcela con el fin de confirmar o, en su caso, corregir la edad de la masa estimada según la información de gabinete disponible (expedientes de repoblación, documentos de gestión, etc.)

Para calcular el índice de sitio de cada parcela de muestreo se emplearon las ecuaciones altura dominante - edad para *Pinus sylvestris* en la Sierra de Guadarrama (Rojo Alboreca y Montero 1996) y para *Pinus halepensis* en el Valle del Ebro (Rojo-Alboreca et al. 2017). En el pino albar se trata de un haz de curvas ajustadas mediante el procedimiento de la curva guía, siendo el índice de sitio la altura dominante a los 100 años de edad, mientras que para el pino carrasco la ecuación se ajustó mediante la metodología GADA (Castedo-Dorado et al. 2007) y se estableció la edad de referencia en los 60 años. En la Tabla 1 se resumen las variables dendrométricas y dasométricas básicas de los dos conjuntos de parcelas.

Tabla 1. Resumen de las variables dendrométricas y dasométricas básicas de los dos conjuntos de datos. N: densidad (pies/ha); G: área basimétrica (m^2/ha); DG: diámetro medio cuadrático (cm); HO: altura dominante (m); EDAD: edad de la masa (años); IS: índice de sitio (m); dn: diámetro normal (cm).

	<i>Pinus sylvestris</i>				<i>Pinus halepensis</i>			
	media	máx	min	sd	media	máx	min	sd
dn	25.5	50.5	7.5	7.7	17.1	49.6	7.5	6.4
N	730.2	1675.0	175.0	409.2	1057.4	3200.0	176.0	594.0
G	40.6	71.2	10.8	16.7	24.3	58.9	6.3	11.9
DG	28.0	39.4	16.8	4.5	17.9	30.6	11.7	5.1
HO	16.0	22.9	6.2	5.5	10.2	19.1	6.2	3.2
EDAD	65.4	105.0	54.0	9.8	57.1	91.5	24.1	11.1
IS	16.2	35.7	6.3	7.5	10.7	20.2	5.9	3.2

Métricas LiDAR.

Se han empleado las dos coberturas LiDAR del PNOA disponibles en Aragón y en la Comunidad de Madrid para obtener métricas LiDAR para ambos conjuntos de datos. Las especificaciones técnicas básicas de las dos coberturas para los dos casos de estudio se presentan en la Tabla 2.

Tabla 2. Especificaciones técnicas de los vuelos LiDAR aerotransportados empleados para la obtención de métricas.

	<i>Pinus sylvestris</i>		<i>Pinus halepensis</i>	
	PNOA1	PNOA2	PNOA1	PNOA2
Fecha vuelo	Oct 2010	Sep 2016	Ago-oct 2010	Sep-nov 2016
Sensor	LEICA ALS50	LEICA ALS70-HP	LEICA ALS60	LEICA ALS80
Longitud de onda	1064 nm	1064 nm	1064 nm	1064 nm
Angulo de escaneo máximo	14°	19.5°	26°	25°
Densidad nominal de puntos	0.5 pt/m ²	1 pt/m ²	0.5 pt/m ²	1 pt/m ²
Precisión altimétrica	0.40 m	0.15 m	0.20 m	0.09 m

Los datos LiDAR fueron procesados con el software easyLaz (Alonso Ponce et al. 2018), una herramienta propia de for forest technologies basada en el ecosistema FUSION/LDV (McGaughey 2021). En cada parcela se calcularon un total de 31 métricas relativas a la posición (media, percentiles, máximo, mínimo, mediana) y a la dispersión (varianza, desviaciones respecto a la media y la mediana, coeficiente de variación, intervalo intercuartílico, asimetría, curtosis, momentos-L) de la distribución de alturas normalizadas de los retornos. Todos los retornos por debajo de 2 m de altura fueron excluidos del cálculo de métricas con el fin de reducir el ruido introducido por la vegetación baja no arbórea.

Modelos LiDAR predictores de la altura dominante.

Mediante la técnica de métodos de masa se utilizaron las métricas LiDAR anteriormente descritas como variables independientes en el ajuste de ecuaciones LiDAR para predecir la altura dominante de cada parcela. De esta manera, utilizando después las ecuaciones obtenidas es factible estimar la altura dominante de la masa en cualquier punto de la zona de interés, siempre que existan datos LiDAR disponibles. Para este ajuste se emplearon únicamente las métricas correspondientes a la segunda cobertura PNOA, ya que es la más cercana en el tiempo a la toma de datos de campo.

Se emplearon formulaciones tanto potenciales como exponenciales, siendo previamente linealizadas para poder emplear ajustes lineales, es decir:

$$HO = a_0 \cdot x_1^{a_1} \cdot x_2^{a_2} \dots x_n^{a_n} + \varepsilon \rightarrow \ln(HO) = \ln(a_0) + a_1 \ln(x_1) + a_2 \ln(x_2) + \dots + a_n \ln(x_n) + \varepsilon$$

$$HO = a_0 \cdot e^{a_1 x_1} \cdot e^{a_2 x_2} \dots e^{a_n x_n} + \varepsilon \rightarrow \ln(HO) = \ln(a_0) + a_1 x_1 + a_2 x_2 + \dots + a_n x_n + \varepsilon$$

donde x_i son las métricas LiDAR calculadas en cada parcela.

La selección de variables predictoras se realizó mediante el método de búsqueda exhaustiva implementada en el paquete *leaps* (Lumley 2017) de R (R Core Team 2018). La diagnosis de los modelos seleccionados se realizó en R con los paquetes *stats* (R Core Team 2018) y *car* (Fox y Weisberg 2011). Los estadísticos empleados en dicha diagnosis fueron el error medio cuadrático, tanto en términos absolutos (RMSE) como relativos (%RMSE), el error medio en términos absolutos (sesgo) y relativos (%sesgo), su significancia con respecto a cero (p-valor sesgo) y la eficiencia del

modelo (EF). Asimismo, se evaluó visualmente cada ajuste mediante los gráficos de residuos frente a la variable predicha y los de residuos por clases de altura.

Estimación del índice de sitio y diagnóstico de su predicción.

Las ecuaciones para predecir la altura dominante, ajustadas según el método anterior, se aplicaron a las métricas de los dos vuelos PNOA calculadas en cada parcela. De esta manera se obtuvo una estimación de la altura dominante (HO) en dos momentos separados por un lapso de tiempo conocido (distancia temporal entre ambos vuelos). Con esta terna de valores (dos alturas dominantes y un lapso de tiempo), mediante un proceso iterativo aplicado a la ecuación altura dominante-edad correspondiente es posible obtener una estimación del índice de sitio de cada parcela, utilizando exclusivamente información LiDAR.

Como se ha mencionado más arriba, dado que en ambos conjuntos de datos de campo se conoce la edad, el índice de sitio se ha podido calcular directamente a partir de la pareja de valores altura dominante (medida en campo) y edad. Asumiendo este cálculo como el índice de sitio observado, se compararon dichos valores con los índices de sitio predichos a partir exclusivamente de datos LiDAR. La precisión de la predicción se evaluó mediante el error medio cuadrático, tanto en términos absolutos (RMSE) como relativos (%RMSE), el error medio en términos absolutos (sesgo) y relativos (%sesgo) y su significancia con respecto a cero (p-valor sesgo), así como el coeficiente de correlación entre valores observados y predichos ($R^2_{\text{obs-pred}}$). Además, se utilizó el test de Sterba et al. (2001) que contrasta la hipótesis nula de si la recta de regresión entre valores predichos y observados presenta simultáneamente pendiente uno y ordenada en el origen igual a cero. Por último, se evaluó visualmente la predicción mediante los gráficos de valores observados frente a predichos y de residuos frente a clases de índice de sitio.

4. Resultados

Estimación de la altura dominante

Los resultados y la bondad del ajuste de las ecuaciones de estimación de la altura dominante de cada especie se muestran en la Tabla 3 y la Figura 2. En ambos casos la formulación óptima encontrada fue de tipo potencial.

Tabla 3. Estimación de los parámetros ajustados y bondad del ajuste para las ecuaciones LiDAR de altura dominante en los dos casos de estudio. a: parámetros ajustados. Todos los parámetros fueron significativos (** $p < 0.01$, *** $p < 0.001$)

	<i>Pinus sylvestris</i>	<i>Pinus halepensis</i>
a ₀	0.5496***	0.5880***
a ₁	0.8526***	0.1190**
a ₂	-	0.7936***
RMSE	1.370	0.495
%RMSE	8.31	5.19
sesgo	0.018	0.001
%sesgo	0.11	0.01
p-valor sesgo	0.950	0.988
EF	0.937	0.966

Pinus sylvestris

Pinus halepensis

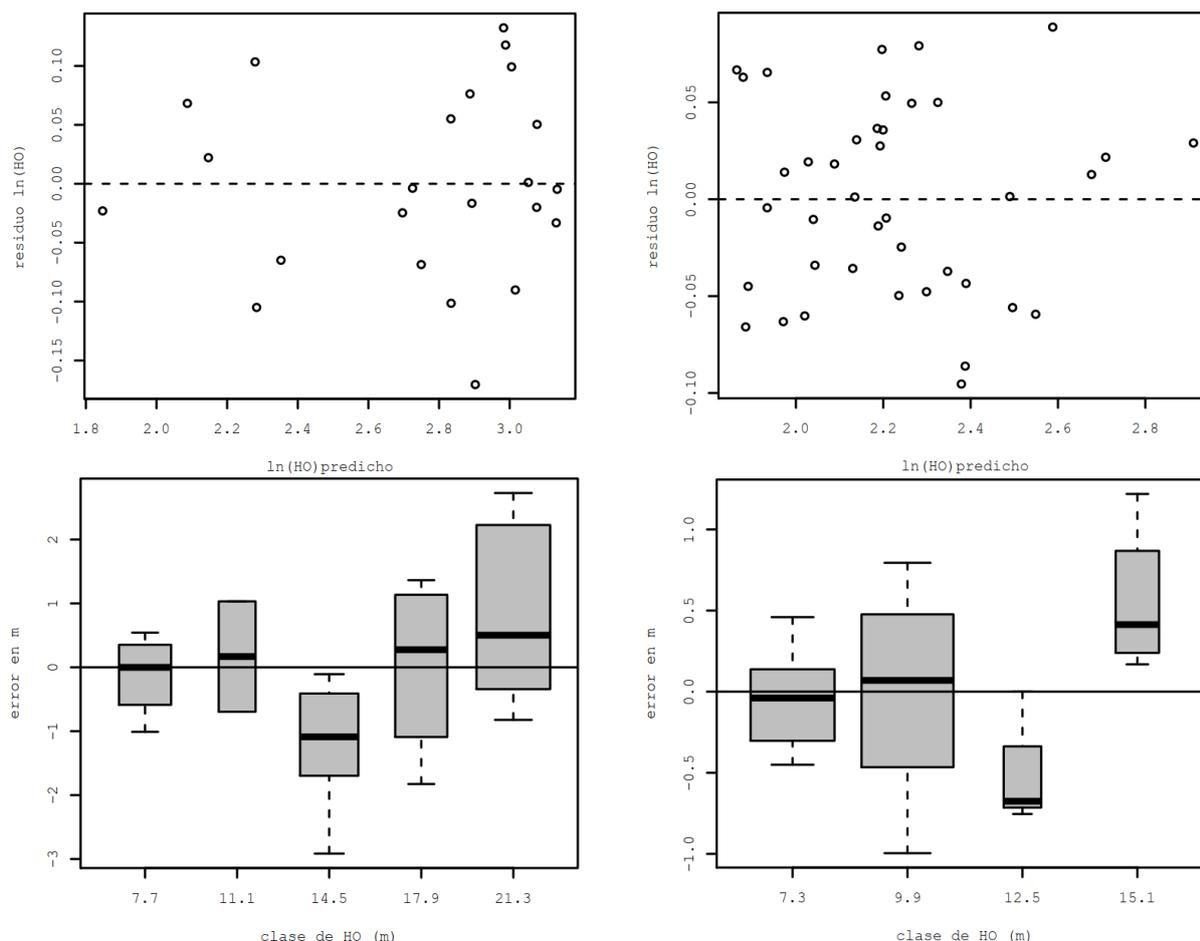


Figura 2. Análisis gráfico de la bondad del ajuste de las ecuaciones LiDAR de altura dominante para *Pinus sylvestris* (izq.) y *Pinus halepensis* (dcha.). Arriba: residuos frente a valores predichos (en unidades logarítmicas). Abajo: residuos por clases de altura.

Los resultados son satisfactorios para ambas especies. Todos los parámetros resultaron significativos y los errores medios cuadráticos ascienden a 1.4 m (8.3% en términos relativos) para *P. sylvestris* y 0.5 m (5.2 %) para *P. halepensis*. Por su parte, el sesgo es virtualmente nulo en ambos casos, si bien se detecta una mayor desviación en alguna clase de altura de la variable predicha de ambas especies. La eficiencia de ambos modelos es muy elevada, claramente superior al 90% en ambos casos.

Una vez deshecha la transformación que linealizaba las expresiones a ajustar y corregido el sesgo sistemático intrínseco a dicha transformación (Sprugel 1983), las ecuaciones predictoras de la altura dominante de cada especie resultaron ser:

$$\text{Pinus sylvestris: } HO = 1.7383 \cdot LH_P80^{0.8526}$$

$$\text{Pinus halepensis: } HO = 1.8028 \cdot LH_MAD_MEDIAN^{0.1190} \cdot LH_P80^{0.7936}$$

donde LH_P80 es el percentil 80 de la altura de todos los retornos por encima de 2 m, y LH_MAD_MEDIAN es la mediana de las desviaciones absolutas con respecto a la mediana de las alturas de todos los retornos por encima de 2 m.

Estimación del índice de sitio

En la Tabla 4 y la Figura 3 se muestran los resultados de comparar la predicción del índice de sitio predicho a partir del cómputo de las alturas dominantes calculadas mediante la información

LiDAR de los dos vuelos disponibles con los índices de sitio calculados conociendo la edad de cada parcela de campo.

Tabla 4. Errores en la estimación del índice de sitio y test simultáneo entre observados y predichos para los dos casos de estudio. Test simultáneo de Sterba et al: a, ordenada en el origen de la recta de regresión entre valores predichos y observados; b, pendiente de dicha recta; F-stat, valor del estadístico del test; p-valor, significancia del test.

	<i>Pinus sylvestris</i>	<i>Pinus halepensis</i>
RMSE	2.704	2.388
%RMSE	12.639	17.983
sesgo	-0.294	-0.564
%sesgo	1.376	4.250
p-valor sesgo	0.553	0.255
R ² obs-pred	0.936	0.707
a	-3.047	4.832
b	1.127	0.610
F-stat	1.440	5.208
p-valor	0.254	0.015

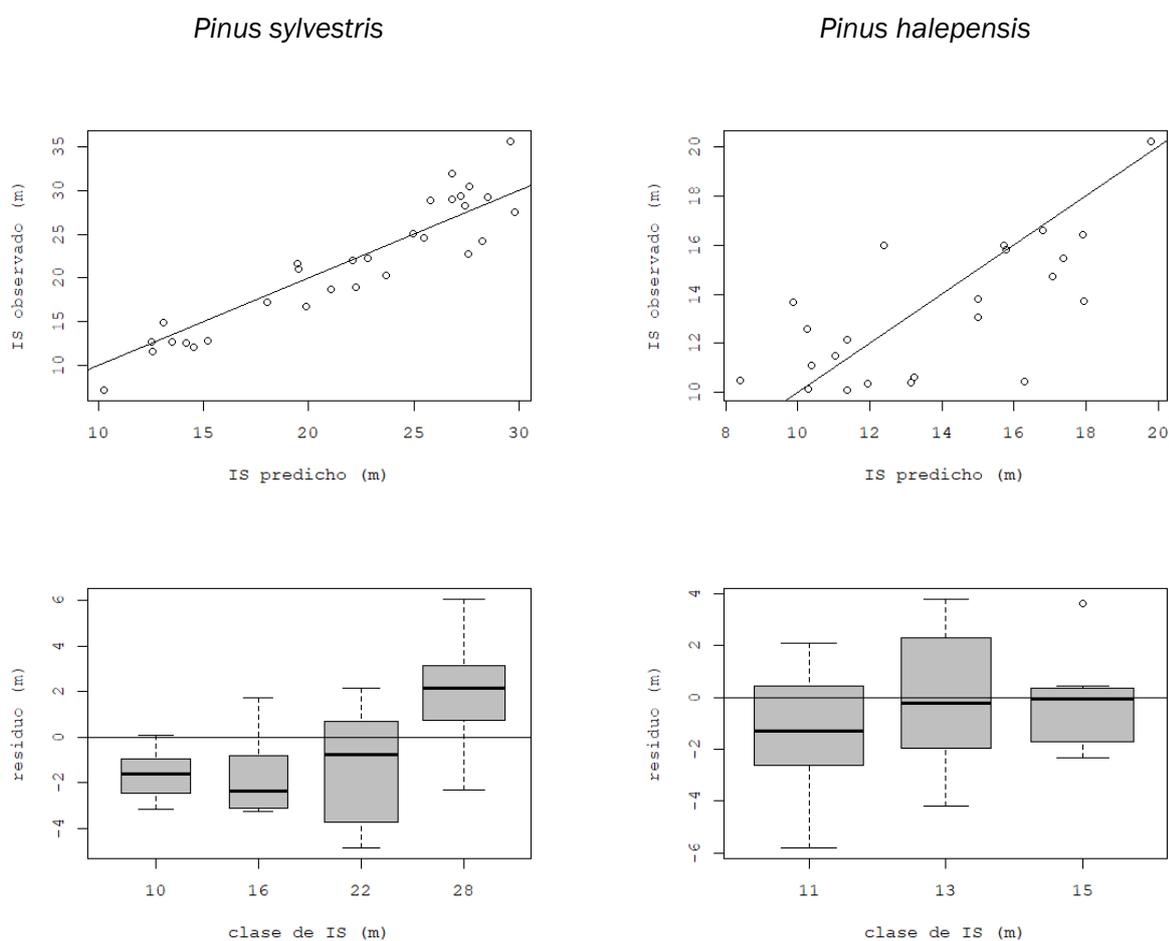


Figura 3. Análisis gráfico de la bondad de la predicción del índice de sitio para *Pinus sylvestris* (izq.) y *Pinus halepensis* (dcha.). Arriba: valores observados frente a valores predichos; la línea continua representa la bisectriz a 45°. Abajo: residuos por clases de índice de sitio.

Los errores medios cuadráticos de la predicción son de 2.7 y 2.3 m, lo que implica un error relativo del 12.6% y del 18.0% (*P. sylvestris* y *P. halepensis*, respectivamente). Si bien el sesgo global no es significativamente distinto de cero para ninguna de las dos especies (en términos relativos, 1.4% y 4.3% para *P. sylvestris* y *P. halepensis*, respectivamente), en el caso de la primera especie se observa una tendencia a la infraestimación del IS en las calidades muy altas y a una sobreestimación en las bajas. El test en el que se plantea la hipótesis nula de que la recta de regresión entre los valores observados y los predichos tenga simultáneamente un término independiente de 0 y una pendiente de 1 dio una probabilidad de 0.254 de equivocarse si se rechaza la hipótesis nula. En el caso de *P. halepensis*, el mismo test da una probabilidad de 0.015, si bien en el análisis gráfico no se observa ninguna relación entre el sesgo y la variable observada.

5. Discusión

En el presente trabajo se evalúa la capacidad de la información LiDAR de baja densidad de puntos del PNOA para estimar la calidad de estación (computada mediante el índice de sitio) en masas regulares y monoespecíficas de dos especies de pinos representativas de condiciones ecológicas contrastadas (*P. sylvestris* y *P. halepensis*). La posibilidad de predecir el índice de sitio de manera espacialmente explícita y continua a partir exclusivamente de información LiDAR, sin necesidad de conocer la edad de la masa, constituye un avance muy relevante para la gestión forestal por, al menos, tres motivos. En primer lugar, sería factible la actualización a la fecha deseada del cálculo de existencias mediante diagramas de manejo de densidad, independientemente de la fecha del vuelo y de, en su caso, la toma de datos de campo. En segundo lugar, el método esquivaría la necesidad de conocer la edad de la masa en cada punto del área de interés, variable que es muy costosa de averiguar en multitud de ocasiones. Por último, facultaría para generar cartografía precisa de la productividad en todo el área de interés, con las implicaciones que ello conlleva en la calidad de la planificación.

Los resultados obtenidos demuestran que, al menos en los dos casos de estudio evaluados, la posibilidad es real. Los errores obtenidos son suficientemente bajos (12% y 18% para *P. sylvestris* y *P. halepensis*, respectivamente) para una escala de monte, y son insesgados a nivel global. Además, estas cifras son perfectamente comparables a los obtenidos por Noordemeer et al. (2018) para masas de *P. sylvestris* y de *Picea abies*, con un 13.9% y un 10.4% de RMSE, respectivamente. En dicho trabajo los autores emplearon el denominado método “indirecto”, que es virtualmente idéntico al planteado aquí salvo por el procedimiento computacional utilizado por nosotros para identificar el índice de sitio más probable en cada parcela. No obstante, es de destacar que en dicho estudio ambos vuelos se realizaron *ad hoc* para la investigación y de manera simultánea al trabajo de campo, y la densidad de puntos del escaneado LiDAR del segundo de los vuelos era un orden de magnitud superior a la del PNOA.

Otros trabajos que emplean la información LiDAR como fuentes de datos para ajustar ecuaciones de la primera relación fundamental han demostrado su potencia y exactitud (Guerra-Hernández et al. 2021; Socha et al. 2017; Tompalski et al. 2015), además de la independencia del resultado con respecto al tamaño de celda empleado (Socha et al. 2020). Sin embargo, nuestro objetivo era probar la viabilidad de estimar el índice de sitio, dada una ecuación ya ajustada, a partir de información LiDAR de baja densidad de puntos sin necesidad de contar con ninguna información sobre la edad de la masa. Aunque creemos que dicha viabilidad ha quedado justificada, se han encontrado ciertos inconvenientes muy relevantes que deben ser tenidos en cuenta.

En el caso de *P. sylvestris*, es detectable cierta tendencia a sobreestimar el índice de sitio en calidades bajas y a infraestimarlos en las altas. En *P. halepensis* ocurre algo parecido, aunque el análisis gráfico no lo revela. Sin embargo, el test simultáneo de la recta de regresión entre valores

predichos y valores observados demuestra una clara desviación con respecto a la bisectriz, con una pendiente claramente por debajo de 1 y una ordenada positiva en el origen. Aunque este test puede ser muy sensible al tamaño de la muestra (Sterba et al. 2001), parece evidente que en el pino carrasco se da la misma tendencia que en *P. sylvestris* a infraestimar el índice de sitio en las localidades más productivas y viceversa. Análogamente, Noordemeer et al. (2018) también encontraron una cierta tendencia a infraestimar el índice de sitio en masas de píceas al emplear el método indirecto, pero no el directo. Sin embargo, este último implica el ajuste de ecuaciones predictivas del índice de sitio a partir de métricas LiDAR (de manera análoga a como se ha mostrado en este trabajo para la altura dominante), con lo cual es necesario conocer la edad de la masa en las parcelas de muestreo.

Ahora bien, el sesgo detectado en nuestra predicción podría ser corregido exitosamente si se cuenta con una pequeña muestra de datos de campo en los que se haya calculado el índice de sitio por métodos directos (medición de la altura dominante y cómputo de la edad). Así, calculando el error cometido al predecir el índice de sitio en esos puntos se podría calibrar la predicción de dicha variable para corregir su sesgo. Dado que normalmente en los planes de gestión elaborados con inventarios LiDAR se prevé la realización del trabajo de campo necesario para el ajuste de las ecuaciones LiDAR, no sería ciertamente muy oneroso planificar la toma de datos para el cómputo de la edad de la masa en una pequeña submuestra del total de parcelas de campo, con el fin de posibilitar la calibración mencionada.

Otro aspecto a tener en consideración es el hecho de que en este trabajo se han contrastado los resultados obtenidos en masas regulares y monoespecíficas de especies perennifolias. A la vista de los resultados obtenidos por Tompalski et al (2015) parece razonable hipotetizar que cualesquiera otras circunstancias (masas irregulares, mixtas, caducifolias) la capacidad predictiva del LiDAR se verá afectada, especialmente cuando la utilización del índice de sitio en masas irregulares o mixtas puede llegar a carecer de sentido. El desempeño de la metodología aquí expuesta en tales circunstancias debe ser contrastada ineludiblemente, a nuestro juicio.

Desde un punto de vista exclusivamente de la gestión, queremos destacar las posibilidades que abre una predicción espacialmente explícita del índice de sitio. En la Figura 4 puede comprobarse cómo se dan multitud de casos en los que una misma unidad de gestión (en este caso, rodales) presenta una gran variabilidad en su calidad de estación, por lo que el cálculo de la posibilidad, la previsión de crecimientos, cortas, etc. se ve sensiblemente mejorada si es factible conocer a priori la productividad de zonas concretas dentro de cada unidad de gestión. Además, mediante el manejo de diagramas de manejo de densidad, de los que ya hay disponibles para *P. halepensis* (Cabanillas-Saldaña et al. 2009; Valbuena et al. 2008), es posible actualizar las variables de masa a la fecha deseada, celda a celda, una vez estimado el índice de sitio en cada una de ellas. Lógicamente, este proceso de simulación no es realizable en aquellas celdas donde se hayan producido perturbaciones significativas en el lapso de tiempo transcurrido entre ambos vuelos LiDAR.

Resulta particularmente relevante también que, por un lado, el método no necesita conocer la edad de la masa, variable que es particularmente costosa de averiguar en multitud de ocasiones, y, por otro, la información LiDAR empleada es de libre acceso y cubre todo el territorio nacional, por lo que está a disposición de cualquier gestor forestal. Aunque esta información LiDAR es de baja densidad de puntos (0.5-1 pt/m²), lo que implica la imposibilidad de utilizar métodos de árbol individual para estimar las variables dasométricas en masas de espesura media y alta, otros trabajos (Socha et al. 2020) han demostrado que los métodos de masa generan resultados de calidad comparable a los de árbol individual, en lo que a la predicción del incremento en altura se refiere, con densidades de puntos poco mayores (4-6 pt/m²) a los empleados en este trabajo, y semejantes a las que se pueden encontrar ya en los nuevos lotes facilitados por el Centro Nacional

de Información Geográfica (por ejemplo, en los lotes de Navarra y del nordeste y sudoeste de Castilla y León).

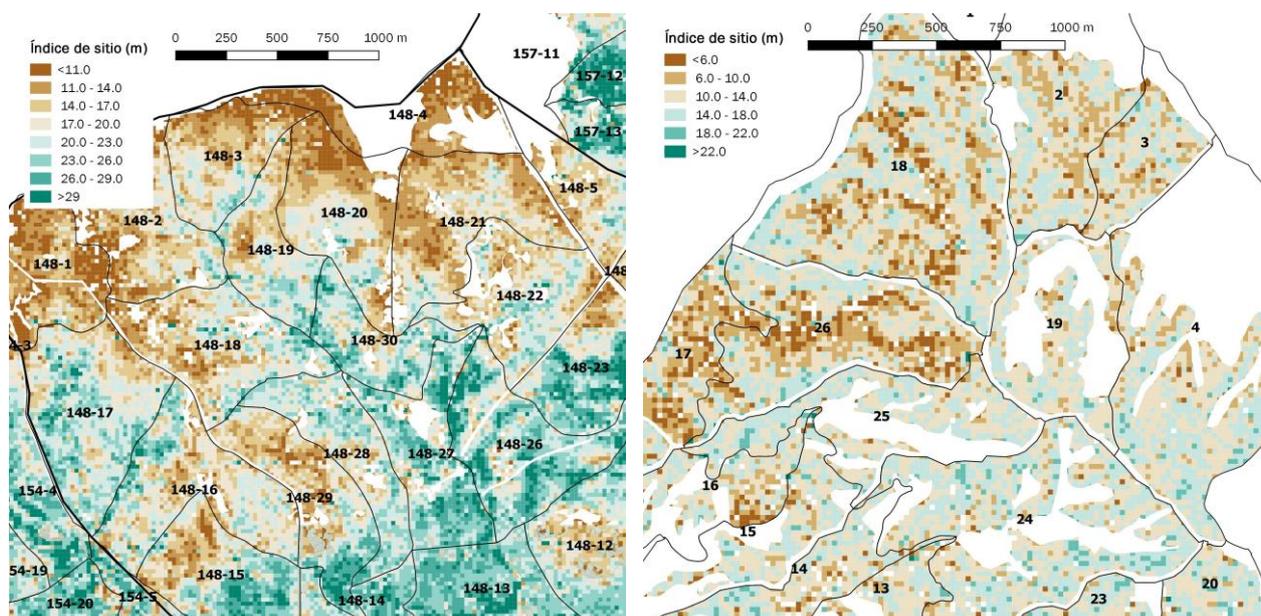


Figura 4. Ejemplos de predicción continua y espacialmente explícita del índice de sitio en masas de *Pinus sylvestris* (izq., MUP 148 de Madrid) y *Pinus halepensis* (dcha., MUP 107 de Zaragoza). Las áreas sin datos son zonas desarboladas.

6. Conclusiones

En este trabajo se ha evaluado la viabilidad de emplear exclusivamente información LiDAR de baja densidad de puntos para estimar el índice de sitio de manera continua y espacialmente explícita en masas monoespecíficas y regulares de *Pinus sylvestris* y *Pinus halepensis*. Los resultados demuestran que es factible obtener una estimación suficientemente precisa de la calidad de estación sin conocer la edad de la masa, si bien se recomienda contar con una pequeña muestra de calibración para corregir posibles sesgos en la predicción. La posibilidad de contar con una predicción suficientemente precisa y espacialmente continua de la productividad, a partir exclusivamente de datos remotos, abre un camino de mejora sustancial en la calidad de los documentos de gestión de nuestros montes.

7. Agradecimientos

Los datos de campo correspondientes a la comunidad autónoma de Aragón fueron financiados con Fondos FEADER al amparo del PDR de Aragón 2014-2020 a través de la Medida 8, Submedida 8.5, Operación 8.5.d - Consecución de una gestión forestal sostenible. "Fondo Europeo Agrícola de Desarrollo Rural: Europa invierte en las zonas rurales".

8. Bibliografía

Alonso Ponce, R.; Lizarralde, I.; Rodríguez-Puerta, F. y Pérez-Rodríguez, F., 2018. EasyLaz 1.0. Registro de la Propiedad Intelectual SO-8/2018.

Álvarez González, J.G.; Barrio Anta, M.; Diéguez Aranda, U. y Rojo Alboreca, A., 2004. Metodología para la construcción de curvas de calidad de estación. *Cuad. la SECF* 18, 303-

309.

Barrio Anta, M. y Álvarez González, J.G., 2005. Development of a stand density management diagram for even-aged pedunculate oak stands and its use in designing thinning schedules. *For. An Int. J. For. Res.* 78, 209-216.

Bravo, F.; Alvarez-Gonzalez, J.G.; del Rio, M.; Barrio, M.; Bonet, J.A.; Bravo-Oviedo, A.; Calama, R.; Castedo-Dorado, F.; Crecente-Campo, F.; Condes, S.; Dieguez-Aranda, U.; Gonzalez-Martinez, S.C.; Lizarralde, I.; Nanos, N.; Madrigal, A.; Martinez-Millan, F.J.; Montero, G.; Ordoñez, C.; Palahi, M.; Pique, M.; Rodriguez, F.; Rodriguez-Soalleiro, R.; Rojo, A.; Ruiz-Peinado, R.; Sanchez-Gonzalez, M.; Trasobares, A. y Vazquez-Pique, J., 2011. Growth and yield models in Spain: Historical overview, Contemporary Examples and perspectives. *For. Syst.* 20, 315-328.

Cabanillas-Saldaña, A.M.; Barrio-Anta, M.; Rojo-Alboreca, A. y Notivol-Paíno, E., 2009. Diagrama de manejo de densidad para masas naturales de pino carrasco (*Pinus halepensis* Mill.) en la depresión del Ebro, en: 5º Congreso Forestal Español. SECF-Junta de Castilla y León. Ávila, España, p. 13.

Cao, L.; Coops, N.C.; Innes, J.L.; Sheppard, S.R.J.; Fu, L.; Ruan, H. y She, G., 2016. Estimation of forest biomass dynamics in subtropical forests using multi-temporal airborne LiDAR data. *Remote Sens. Environ.* 178, 158-171.

Castedo-Dorado, F.; Crecente-Campo, F.; Álvarez-Álvarez, P. y Barrio-Anta, M., 2009. Development of a stand density management diagram for radiata pine stands including assessment of stand stability. *For. An Int. J. For. Res.* 82, 1-16.

Castedo-Dorado, F.; Diéguez-Aranda, U.; Barrio-Anta, M. y Álvarez-González, J.G., 2007. Modelling stand basal area growth for radiata pine plantations in Northwestern Spain using the GADA. *Ann. For. Sci.*

Diéguez-Aranda, U.; Rojo Alboreca, A.; Castedo-Dorado, F.; Álvarez-González, J.G.; Barrio-Anta, M.; Crecente-Campo, F.; González-González, J.M.; Pérez-Cruzado, C.; Rodríguez-Soalleiro, R.; López-Sánchez, C.A.; Balboa-Murias, M.Á.; Gorgoso-Varela, J.J. y Sánchez Rodríguez, F., 2009. Herramientas selvícolas para la gestión forestal sostenible en Galicia. Dirección Xeral de Montes, Consellería do Medio Rural, Xunta de Galicia. 259 pp. Lugo.

Domingo, D.; Alonso Ponce, R.; de la Riva, J.; Lamelas, M.T.; Rodríguez, F. y Montealegre, A.L., 2019. Temporal Transferability of Pine Forest Attributes Modeling Using Low-Density Airborne Laser Scanning Data. *Remote Sens.* 11, 261.

Drew, T.J. y Flewelling, J.W., 1979. Stand Density Management: an Alternative Approach and Its Application to Douglas-fir Plantations. *For. Sci.* 25, 518-532.

Fekety, P.A.; Falkowski, M.J. y Hudak, A.T., 2015. Temporal transferability of LiDAR-based imputation of forest inventory attributes. *Can. J. For. Res.* 45, 422-435.

Fekety, P.A.; Falkowski, M.J.; Hudak, A.T.; Jain, T.B. y Evans, J.S., 2018. Transferability of

lidar-derived basal area and stem density models within a northern Idaho ecoregion. *Can. J. Remote Sens.* 44, 131-143.

Fernández-Landa, A.; Fernández-Moya, J.; Tomé, J.L.; Algeet-Abarquero, N.; Guillén-Climent, M.L.; Vallejo, R.; Sandoval, V. y Marchamalo, M., 2018. High resolution forest inventory of pure and mixed stands at regional level combining National Forest Inventory field plots, Landsat, and low density lidar. *Int. J. Remote Sens.* 39, 4830-4844.

Fox, J. y Weisberg, S., 2011. *An R Companion to Applied Regression*, Second Edition. Thousands Oaks. Sage, CA.

González-Ferreiro, E.; Diéguez-Aranda, U.; Crecente-Campo, F.; Barreiro-Fernández, L.; Miranda, D. y Castedo-Dorado, F., 2014. Modelling canopy fuel variables for *Pinus radiata* D. Don in NW Spain with low-density LiDAR data. *Int. J. Wildl. fire* 23, 350-362.

Guerra-Hernández, J.; Arellano-Pérez, S.; González-Ferreiro, E.; Pascual, A.; Sandoval Altelarrea, V.; Ruiz-González, A.D. y Álvarez-González, J.G., 2021. Developing a site index model for *P. Pinaster* stands in NW Spain by combining bi-temporal ALS data and environmental data. *For. Ecol. Manage.*

Guerra-Hernández, J.; Tomé, M. y González-Ferreiro, E., 2016. Using low density LiDAR data to map Mediterranean forest characteristics by means of an area-based approach and height threshold analysis. *Rev. Teledetección* 103-117.

Hopkinson, C.; Chasmer, L. y Hall, R.J., 2008. The uncertainty in conifer plantation growth prediction from multi-temporal lidar datasets. *Remote Sens. Environ.* 112, 1168-1180.

Lumley, T., 2017. leaps: Regression Subset Selection. R package version 3.0.

McGaughey, R.J., 2021. FUSION/LDV: Software for LIDAR Data Analysis and Visualization. V4.20. USDA. 212 pp. Seattle, WA.

Navarro, J.A.; Tomé, J.L.; Marino, E.; Guillén-Climent, M.L. y Fernández-Landa, A., 2020. Assessing the transferability of airborne laser scanning and digital aerial photogrammetry derived growing stock volume models. *Int. J. Appl. Earth Obs. Geoinf.* 91, 102135.

Newton, P.F., 1997. Stand density management diagrams: Review of their development and utility in stand-level management planning. *For. Ecol. Manage.* 98, 251-265.

Noordermeer, L.; Bollandsås, O.M.; Gobakken, T. y Næsset, E., 2018. Direct and indirect site index determination for Norway spruce and Scots pine using bitemporal airborne laser scanner data. *For. Ecol. Manage.*

R Core Team, 2018. *R: A language and environment for statistical computing*.

Rodríguez-Puerta, F.; Fernández-Landa, A. y Tomé, J.L., 2014. Resultados y reflexiones tras cinco años de inventario forestal con tecnología LiDAR. *Foresta61* 28-33.

Rojo-Alboreca, A.; Cabanillas-Saldaña, A.M.; Barrio-Anta, M.; Notivol-Paíno, E. y Gorgoso-Varela, J.J., 2017. Site index curves for natural Aleppo pine forests in the central Ebro valley (Spain). *Madera y Bosques* 23, 143.

Rojo Alboreca, A. y Montero, G., 1996. El pino silvestre en la Sierra de Guadarrama. MAPA. 293 pp. Madrid.

Socha, J.; Hawryło, P.; Stereńczak, K.; Miścicki, S.; Tymińska-Czabańska, L.; Młoczek, W. y Gruba, P., 2020. Assessing the sensitivity of site index models developed using bi-temporal airborne laser scanning data to different top height estimates and grid cell sizes. *Int. J. Appl. Earth Obs. Geoinf.*

Socha, J.; Pierzchalski, M.; Bałazy, R. y Ciesielski, M., 2017. Modelling top height growth and site index using repeated laser scanning data. *For. Ecol. Manage.*

Sprugel, D.G., 1983. Correcting for Bias in Log-Transformed Allometric Equations. *Ecology* 64, 209-210.

Sterba, H.; Korol, N. y Rössler, G., 2001. Ein Ansatz zur Evaluierung eines Einzelbaumwachstums-simulators für Fichtenreinbestände. *Forstwissenschaftliches Cent.* 120, 406-421.

Sullivan, F.B.; Palace, M. y Ducey, M., 2014. Multivariate statistical analysis of asynchronous lidar data and vegetation models in a neotropical forest. *Remote Sens. Environ.* 154, 368-377.

Tompalski, P.; Coops, N.C.; White, J.C. y Wulder, M.A., 2015. Augmenting site index estimation with airborne laser scanning data. *For. Sci.*

Valbuena, P.; Del Peso, C. y Bravo, F., 2008. Stand Density Management Diagrams for two Mediterranean pine species in Eastern Spain. *Investig. Agrar. Sist. y Recur. For.* 17, 97-104.

Williams, R.A., 1994. Stand Density Management Diagram for Loblolly Pine Plantations in North Louisiana. *South. J. Appl. For.* 18, 40-45.

Zhao, K.; Suarez, J.C.; Garcia, M.; Hu, T.; Wang, C. y Londo, A., 2018. Utility of multitemporal lidar for forest and carbon monitoring: Tree growth, biomass dynamics, and carbon flux. *Remote Sens. Environ.* 204, 883-897.