



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



Extensión del cuarto inventario forestal nacional (IFN 4) mediante técnicas LiDAR en Extremadura

JURADO VARELA, A.¹, y GUERRA HERNÁNDEZ, J. ²

¹ Servicio de Ordenación y Gestión Forestal. Dirección General de Política Forestal. Consejería de Agricultura, Desarrollo Rural, Población y Territorio. Junta de Extremadura. Avenida Luis Ramallo s/n. Mérida.

² Forest Research Centre, School of Agriculture, University of Lisbon, Instituto Superior de Agronomía (ISA), Tapada da Ajuda, 1349-017, Lisboa, Portugal

Resumen

Se describe el trabajo realizado por el Servicio de Ordenación y Gestión Forestal de la Junta de Extremadura consistente en extender los valores dasométricos obtenidos en el cuarto inventario forestal nacional (IFN4) a todos los montes de Extremadura mediante la elaboración de modelos predictivos LiDAR de masa desarrollados a partir de la segunda cobertura LiDAR del PNOA, obteniéndose así datos de las principales variables dasométricas para cada uno de los estratos de vegetación definidos y organizados en celdas cuadradas de 25 metros de lado. Los buenos resultados obtenidos confirman la combinación del IFN con la cobertura LiDAR del PNOA como una excelente metodología a la hora de elaborar inventarios forestales, especialmente en masas densas puras y continuas. En cambio esta metodología no fue tan satisfactoria y debe aplicarse un poco más con cautela en masas mixtas y en masas abiertas como los terrenos adehesados, debido a la baja densidad de puntos del PNOA, y a que no existen suficientes parcelas del IFN4 bien georreferenciadas como para elaborar un modelo de masa preciso que recoja toda la variabilidad de especies presente en las masas mixtas de los montes extremeños.

Palabras clave

Teledetección, PNOA, dasometría.

1. Introducción

El láser escáner aerotransportado (ALS “Airbone Laser Scanning”), también denominado como LiDAR (Light Detection and Ranging) es un sistema de teledetección que estando acoplado a un avión, helicóptero o vehículo aéreo no tripulado emite pulsos láser que retornan una o varias al sistema, creando así una nube de puntos tridimensional con abundante información sobre la estructura vertical de la vegetación (HYYPÄ et al., 2008; LIM et al., 2003)). Las intensidades y estadísticos extraídos a partir de distribución de alturas de la nube de puntos LiDAR, junto con los valores dasométricos de las parcelas de inventario de campo permiten desarrollar modelos predictivos de las principales variables de interés para la gestión forestal sin necesidad de recurrir necesariamente a los inventarios forestales por muestreo (VAN LEEUWEN AND NIEUWENHUIS, 2010).

Aprovechando la circunstancia especialmente favorable de la proximidad entre las fechas del trabajo de campo de las parcelas del Cuarto Inventario Forestal Nacional IFN 4 (2017)(MITECO, 2020) y la fecha del vuelo de la segunda cobertura LiDAR del PNOA (2018) en Extremadura, junto con la buena precisión (1-2 metros) de algunas de las parcelas del IFN 4 tomadas en campo supuso una gran oportunidad para desarrollar y extender los resultados de las existencias obtenidos en el IFN 4 aplicando modelos predictivos de masa basados en los datos LiDAR de baja densidad del PNOA. Dada la coincidencia de fechas anteriormente comentada ha permitido que los modelos LiDAR generados sean atemporales, es decir, pueden volver a aplicarse tanto con las próximas coberturas LiDAR del PNOA de similares características que se lleven a cabo en el futuro, o con la primera cobertura del

PNOA llevada a cabo en Extremadura en el año 2010, y conocer así las existencias pasadas y obtener así por ejemplo mapas de crecimiento o de fijación de carbono por pixel durante el periodo 2010-2018.

Este trabajo se llevó a cabo a través de un contrato de servicios promovido por el Servicio de Ordenación y Gestión Forestal de la Junta de Extremadura, y denominado “*Extensión del cuarto inventario forestal nacional mediante técnicas LiDAR para la gestión forestal sostenible de los montes de Extremadura*”, el cual estuvo cofinanciado por FEADER en un 75% a través de la medida 8.5.1 “Gestión sostenible de los montes” del Programa de Desarrollo Rural de Extremadura 2014-2020.

2. Objetivos

El objetivo de este trabajo describe el trabajo realizado por el Servicio de Ordenación y Gestión Forestal de la Junta de Extremadura consistente en extender los valores dasométricos obtenidos en el cuarto inventario forestal nacional (IFN4) a todos los montes de Extremadura mediante la elaboración de modelos predictivos LiDAR de masa desarrollados a partir de la segunda cobertura LiDAR del PNOA.

3. Metodología

En primer lugar se definieron los 17 estratos de vegetación LiDAR definidos, basados en las formaciones y subformaciones forestales del Mapa Forestal de España (MFE) a escala 1:25000 (MAPA, 2018) sobre los que se elaboraron los modelos predictivos de masa. Cada modelo correspondió a un estrato diferente, a excepción del Pino pinaster y el Pino piñonero, los cuales se dividieron en dos estratos diferentes, uno para la comarca de la Siberia Extremeña, y otro para el resto de Extremadura, para así obtener modelos predictivos más precisos atendiendo a la diferente calidad de estación de ambas zonas.

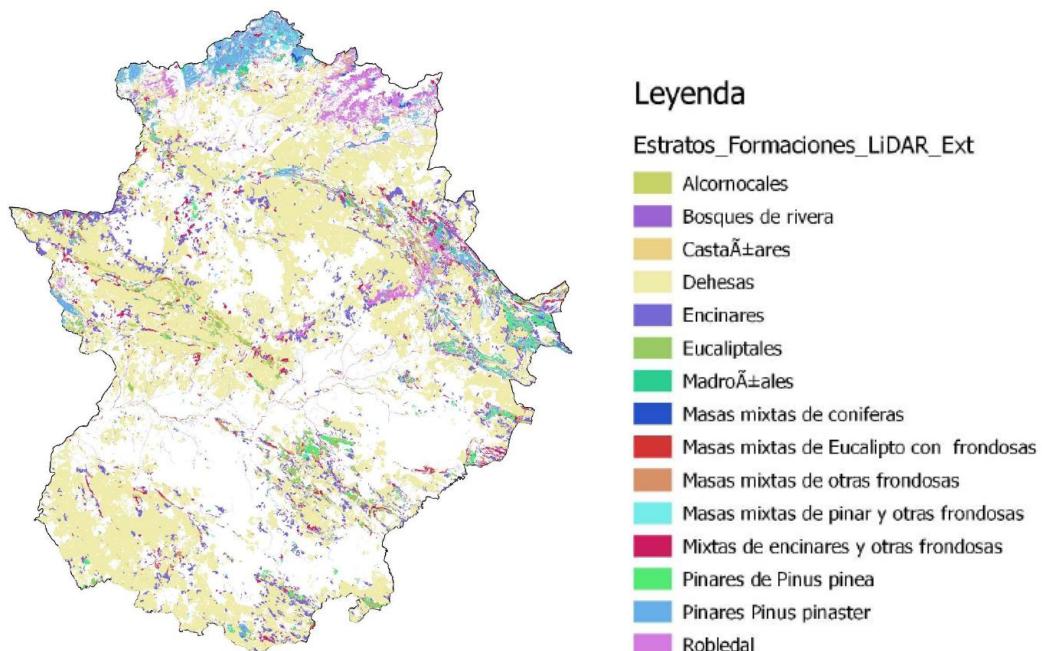


Fig. 1 Estratos de vegetación LiDAR utilizados para elaborar los modelos predictivos de masa

Para obtener los modelos predictivos de masa se aplicó una metodología de inventario forestal a nivel de masa (area-based approach, ABA), con datos LiDAR aerotransportado de baja densidad procedentes de la segunda cobertura del PNOA (1 punto/m² para la provincia de Badajoz, y 2 puntos/m² para Cáceres) (<https://pnoa.ign.es/el-proyecto-pnoa-lidar>), siendo las variables dasométricas que se obtuvieron el Volumen con corteza (Vcc), el área basimétrica (G), la biomasa aérea seca (Wa), el incremento anual de volumen con corteza (IAVC), la altura dominante (m), la fracción de cabida cubierta (%), la altura media (m) y la altura máxima (m), todo ello organizados en celdas cuadradas de 25x25 metros.

Para la fase de modelización de las principales variables dasométricas se realizó un primer análisis de la información de la base de datos de las parcelas procedentes del IFN4 (MITECO, 2020), con el objetivo de realizar un primer filtrado y selección de las parcelas que fueron usadas posteriormente en los ajustes de los modelos para cada formación forestal o estrato LiDAR. Después se realizó un primer análisis del número de parcelas localizadas en cada una de las formaciones forestales arboladas o estratos definidos. De todas las parcelas del IFN se seleccionaron únicamente que cumplieran dos criterios principales: el criterio de georreferenciación que consiste en tener en cuenta solamente parcelas corregidas con un error aproximado de 1-2 m en postproceso, y un criterio de cobertura: que consistió en tener en cuenta únicamente aquellas parcelas con un porcentaje de FCC superior al 10%. Un total de 947 parcelas fueron usadas para generar los modelos LiDAR de masa. Es importante destacar que 5 estratos LiDAR agregados del MFE (Mezclas de *Pinus pinaster* y otras frondosas, Madroñales (*Arbutus unedo*), Mezclas de *Eucalyptus* spp. con otras especies; y choperas y plataneras de producción, Castaños (*Castanea sativa*), Mezclas de *Pinus pinea* y *P. pinaster*, pinar de pino albar (*Pinus sylvestris*) no contaban con un número mínimo de 30 parcelas corregidas con una georreferenciación precisa de 1-2 metros, de forma que para estas formaciones se usaron el número total parcelas ,tanto las que cumplían y las que no cumplían el criterio de georreferenciación.

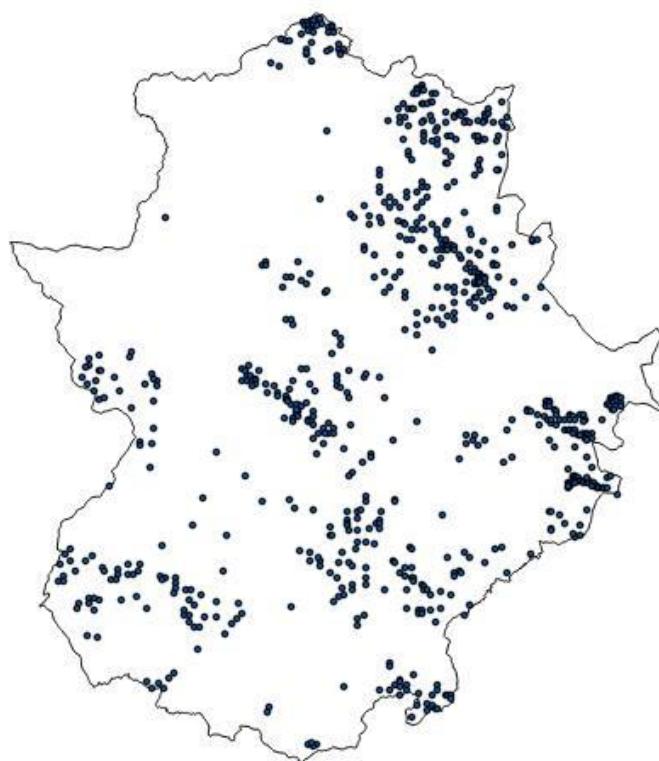


Fig. 2 Parcelas del IFN 4 utilizadas para elaborar los modelos LIDAR

De forma general, el tratamiento de los datos LiDAR se dividió en tres grandes fases que fueron: preparación de los datos (compresión, creación índice espacial, eliminación del ruido, etc.), procesado de los datos (clasificación, normalización, extracción de métricas, etc.) y la generación de los productos (raster asociados con DEM, aplicación modelos desarrollados, etc.). En total se procesaron 11.520 ficheros las originales, clasificados y normalizados con LAStools (Isenburg, 2020) y procedentes del Instituto Geográfico Nacional, con un tamaño original de 2x2km.

Una vez realizado el primer análisis de las parcelas del IFN se ajustaron los modelos de masa (ABA) para cada uno de los estratos LiDAR con un máximo dos variables independientes, combinando una métrica de altura con una métrica de cobertura. El modelo ajustado para establecer las relaciones empíricas entre las variables calculadas a partir de los datos de campo tomados y los estadísticos LiDAR fue de tipo potencial y relacionó la variable de masa a estimar en las parcelas del IFN4 con los estadísticos o métricas procedentes de la nube de puntos LiDAR extraídos en un buffer circular de 25 m a nivel de parcela. Se ajustaron modelos alométricos (Ecuación 1) para estimar el volumen con corteza (Vcc), Área Basimétrica (G), incremento anual de Volumen con corteza (IAVC) y la biomasa aérea total (Wa), donde y es la variable dependiente, X_i son los estadísticos procedentes de la nube de puntos LiDAR y a,b,c,...,m son parámetros a estimar.

$$y = a \cdot X_1^b \cdot X_2^c \cdot \dots \cdot X_n^m \quad (1)$$

La selección del mejor conjunto de variables independientes para cada especie se realizó mediante el análisis de los valores del coeficiente de correlación de Pearson y un ajuste previo del modelo alométrico linealizado mediante logaritmos en el que se usó el método de selección de variables "stepwise". Los ajustes se realizaron con el software R (R Core Team, 2020).

La evaluación del comportamiento de los modelos se basó en el análisis de los estadísticos de bondad del ajuste y eficiencia del modelo (EM), error medio cuadrático (REMC) y error medio cuadrático relativo (rREMC) junto con el análisis visual de las gráficas de valores observados frente a valores predichos y de residuos, donde y_i , \hat{y}_i , \bar{y}_i son respectivamente los valores observados, predichos y el valor medio de la variable dependiente, n es el número total de observaciones, y p es el número de parámetros del modelo.

$$EM = 1 - \frac{(n - 1) \sum_{i=1}^n (y_i - \hat{y}_i)^2}{(n - p) \sum_{i=1}^n (y_i - \bar{y}_i)^2}$$

$$REMC = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n - p}}$$

$$rREMC = \frac{RMSE}{\bar{y}} * 100$$

3. Resultados

Teniendo en cuenta la superficie forestal de Extremadura y que los resultados generados se han organizado en celdas cuadradas de 25 metros de lado para cada una de las 8 variables dasométricas consideradas, se han obtenido como resultado de este trabajo más de 250 millones de estimativas de variables dasométricas a nivel de pixel para todo el territorio extremeño.

Los resultados de las estimativas procedente de la aplicación de los modelos LiDAR de masa comparados con los del IFN 4 a nivel de los estratos definidos muestran resultados muy similares, inferiores a un 10% para las variables volumen con corteza, área basimétrica y biomasa seca obtenidos a nivel de estrato de inventario por muestreo (Tabla 1).

Tabla 1. Comparativa de los resultados medios obtenidos con el LiDAR y el IFN 4 a nivel de Extremadura

	IFN 4	LIDAR	Diferencia (%)
Biomasa (t/ha)	38,01	35,22	7,34
VCC (m ³ /ha)	21,21	19,35	8,77
Área basimétrica (m ² /ha)	6,44	5,95	7,73
Crecimiento (m ³ /ha/año)	0,53	0,42	19,91

En cuanto a los valores de eficiencia de cada uno de los modelos generados (Tabla 2) para cada estrato y para cada una de las variables dasométricas consideradas se observa en general valores de eficiencia considerables para las masas puras y continuas de coníferas, por lo que son modelos que podrían aplicarse a pequeña escala (cantón o monte) en los inventarios forestales de los instrumentos de gestión forestal, teniendo en cuenta el crecimiento de la masa desde la fecha del vuelo (2018) a la fecha actual.

En cambio, en las masas forestales abiertas como los terrenos adehesados se observan unos valores de eficiencia del modelo inferiores, debido principalmente a que los modelos LiDAR de baja densidad de puntos del PNOA no recogen toda la variabilidad de las masas abiertas, por lo que en estos casos parece más adecuado utilizar la metodología de árbol individual en lugar de la metodología de LiDAR de masa. El mismo problema de valores bajos de eficiencia del modelo y valores mayores en términos de RMSE lo encontramos en las masas mixtas en las que no existen suficientes parcelas del IFN4 con una coordenada corregida de precisión métrica como para elaborar un modelo de masa que recoja toda la variabilidad y casuística presente en los estratos mixtos definidos a partir de la agrupación de distintos estratos (a veces muy dispares) del MFE. En general, los modelos regionales LiDAR para la variable IAVC fueron modelos menos precisos en términos de Mef y rRMSE que para Vcc, G y Wa a nivel de cada ecosistema forestal (Tabla 3).

Tabla 2. Número de parcelas utilizadas y valores de Eficiencia del modelo para cada uno de los estratos LiDAR definidos:
 Vcc: Volumen con corteza (m³/ha), G: Área basimétrica (m²/ha), IAVC: crecimiento anual de volumen con corteza
 (m³/ha/año) , y Wa: biomasa seca (t/ha).

Estrato de vegetación LiDAR	Formación arbolada	Numero de parcelas	Vcc (m ³ /ha)	G (m ² /ha)	IAVC (m ³ /ha/año)	Wa(t/ha)
Eficiencia del Modelo (EF)						
1	Dehesas	198	0,29	0,30	0,22	0,27
2	Encinares	92	0,44	0,55	0,16	0,61
3.1	Pinares de <i>Pinus pinaster</i> zona Siberia	30	0,78	0,68	0,51	0,61
3.2	Pinares de <i>Pinus pinaster</i> resto	52	0,83	0,74	0,68	0,79
4	Mixtas de encinares y otras frondosas	38	0,53	0,57	0,55	0,55
5	Masas mixtas de otras frondosas	29	0,84	0,76	0,84	0,76
6	Robledal	50	0,40	0,39	0,26	0,54
7	Eucaliptales	68	0,72	0,65	0,74	0,76
8	Alcornocales	50	0,64	0,74	0,72	0,84
9.1	Pinares de <i>Pinus pinea</i> Siberia	33	0,87	0,80	0,63	0,84
9.2	Pinares de <i>Pinus pinea</i> Resto	32	0,89	0,80	0,63	0,86
10	Masas mixtas de pinar y otras frondosas	25	0,87	0,77	0,62	0,92
11	Bosques de ribera	29	0,83	0,48	0,64	0,53
12	Madroñales	27	0,44	0,51	0,54	0,65
13	Masas mixtas de Eucalipto con otras frondosas y choperas	29	0,86	0,53	0,87	0,76
14	Castañares	27	0,54	0,59	0,53	0,59
15	Masas mixtas de coníferas	20	0,70	0,68	0,61	0,73

Tabla 3. Valores de error medio cuadrático (REMC) y error medio cuadrático relativo (rREMC) del modelo entre paréntesis para cada uno de los estratos LiDAR definidos: Vcc: Volumen con corteza (m³/ha), G: Área basimétrica (m²/ha), IAVC: crecimiento anual de volumen con corteza (m³/ha/año), y Wa: biomasa seca (t/ha).

Estrato de vegetación LiDAR	Formación arbolada	Número de parcelas	Vcc (m ³ /ha)	G (m ² /ha)	IAVC (m ³ /ha/año)	Wa (t/ha)
REMC (rREMC(%))						
1	Dehesas	198	6,74 (46,56)	2,65 (42,96)	0,11 (51,99)	20,49 (49,75)
2	Encinares	92	10,79 (62,71)	2,65 (49,91)	0,241 (94,89)	14,54 (51,48)
3.1	Pinares de <i>Pinus pinaster</i> zona Siberia	30	39,34 (24,05)	6,97 (27,38)	2,06 (44,79)	14,54 (51,48)
3.2	Pinares de <i>Pinus pinaster</i> resto	52	36,59 (33,87)	6,33 (33,85)	1,62 (46,51)	22,17 (35,74)
4	Mixtas de encinares y otras frondosas	38	14,4 (57,90)	3,97 (55,50)	0,31 (72,82)	17,58 (57,88)
5	Masas mixtas de otras frondosas	29	21,45 (54,65)	5,04 (53,55)	0,44 (56,97)	27,05 (63,91)
6	Robledal	50	39,37 (63,12)	6,54 (50,64)	0,91 (63,77)	35,28 (51,63)
7	Eucaliptales	68	19,47 (46,50)	3,28 (46)	0,56 (46,95)	17,06 (46,64)
8	Alcornocales	50	15,47 (54,32)	2,74 (33,82)	0,18 (42,06)	9,26 (31,01)
9.1	Pinares de <i>Pinus pinea</i> Siberia	33	15,5 (26,66)	3,37 (25,49)	1,1 (41,03)	13,66 (24,99)
9.2	Pinares de <i>Pinus pinea</i> Resto	32	14,74 (28,80)	3,62 (29,21)	1,1 (41,03)	13,46 (27,22)
10	Masas mixtas de pinar y otras frondosas	25	29,99 (57)	5,4 (52,96)	1,24 (75,84)	17,73 (41,99)
11	Bosques de ribera	29	28,84 (55,41)	8,79 (73,87)	0,77 (64,94)	56,47 (79,03)
12	Madroñales	27	10,79 (62,71)	7,12 (104,97)	0,62 (99,69)	26,14 (93,17)
13	Masas mixtas de Eucalipto con otras frondosas; y choperas	29	22,46 (50,46)	4,95 (63,76)	0,52 (41,49)	20,4 (50,04)
14	Castañares	27	62,05 (74,31)	8,00 (54,61)	0,63 (58,75)	65,98 (65,23)
15	Masas mixtas de coníferas	20	54,87 (54,87)	7,94 (46,19)	3,32 (64,26)	29,40 (43,47)

Estos valores bajos de eficiencia del modelo en algunos de los estratos LiDAR definidos no implican necesariamente que esta metodología no sea válida para estimar las existencias a una escala regional o provincial, ya que fueron ajustados con una muestra grande representativa de toda la población. Por ejemplo, en los terrenos adehesados en los que la eficiencia del modelo oscila entre el 0,25 y el 0,30 se observa que las diferencias obtenidas con el IFN superan ligeramente solamente el 10 % a nivel regional para las variables biomasa, volumen, y área basimétrica y ligeramente superiores al 5% para la variable biomasa seca, tal como se muestra en la siguiente tabla (Tabla 4):

Tabla 4. Diferencia de las existencias en el IFN 4 y los obtenidos con el LIDAR en el estrato de dehesa con un bajo valor de eficiencia del modelo a nivel de Extremadura.

Formación arbolada	IFN 4	LIDAR	Diferencia (%)
Biomasa (tn/ha)	40,29	34,84	5,45
Volumen (m ³ /ha)	13,77	11,98	13,03
Área basimétrica (m ² /ha)	5,86	5,18	11,61
Crecimiento (m ³ /ha/año)	0,19	0,17	11,95

A continuación se muestran los mapas generados para cada una de las variables dasométricas consideradas (Figura 3):

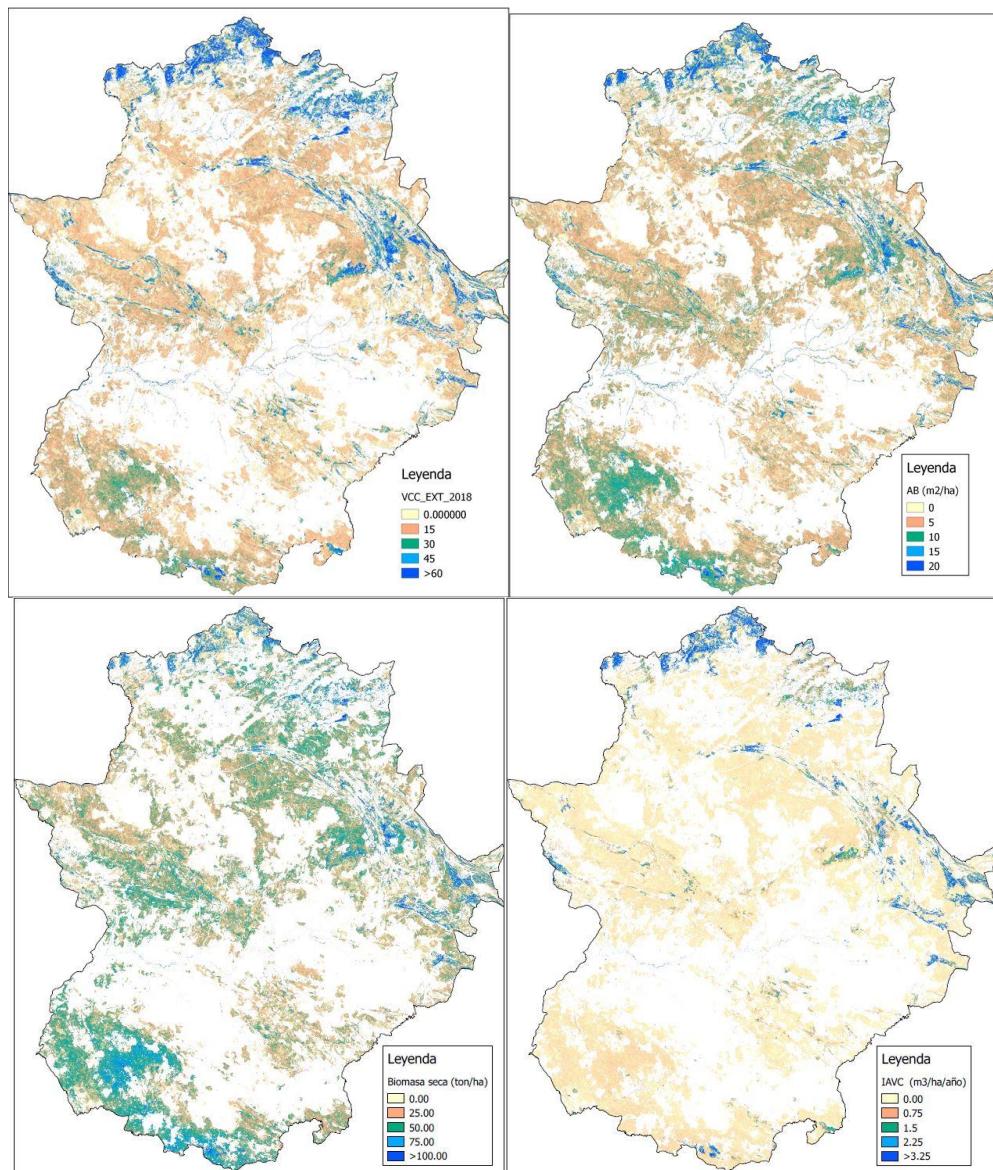


Figura 3 .De arriba abajo, y de izquierda a derecha, Volumen con corteza (m³/ha), Área basimétrica (m²/ha), biomasa seca (t/ha), y crecimiento anual de volumen con corteza (m³/ha/año).

En cuanto al análisis de costes se ha tenido en cuenta tanto el coste del vuelo LiDAR PNOA para toda Extremadura como el coste de la contratación del servicio descrito en el presente artículo, y se obtiene un coste medio de inventario LiDAR PNOA de 0,23 euros /ha, valor muy inferior a la media de los costes de inventarios de los servicios de planes técnicos y proyectos de ordenación de montes licitados por el Servicio de Ordenación y Gestión Forestal (5,23 euros /ha y 10,96 euros /ha respectivamente).

4. Discusión

La combinación del Inventario Forestal Nacional (IFN) con la cobertura LIDAR de baja densidad del PNOA se presenta como una excelente metodología a la hora de elaborar inventarios forestales a nivel regional, ya que los resultados obtenidos solamente presentan una ligera variación inferior al 10% a los obtenidos con respecto al cuarto inventario forestal nacional (IFN4) para las variables volumen, área basimétrica y biomasa seca. Los modelos predictivos de masa desarrollados son especialmente eficientes en masas densas puras y continuas de pinares, por lo que su aplicación a una escala de monte o incluso cantón puede abaratar en gran medida los costes de los inventarios forestales, con la ventaja añadida de recoger la variabilidad de la masa forestal a pequeña escala y permitir elaborar mapas de existencias de detalle.

En cambio esta metodología de LiDAR de masa de baja densidad no fue tan satisfactoria y debe aplicarse un poco más con cautela en masas abiertas como los terrenos adehesados, y en masas mixtas, debido a que los modelos LiDAR PNOA de baja densidad no funcionan bien en masas abiertas como las dehesas. En el caso de estratos mixtos, madroñales y castaños nos encontramos con 2 problemas: (i) la agrupación de distintos estratos del MFE que engloban diferentes formaciones forestales en un solo estrato, y (ii) que no se disponen de suficientes parcelas corregidas del IFN4 con una georreferenciación de 1-2 metros de precisión como para elaborar un modelo de masa preciso que recoja toda la variabilidad de especies presentes en los montes extremeños. Por esta razón parece más idóneo recurrir a la metodología de LiDAR árbol individual en masas adehesadas y al inventario por muestreo en masas mixtas de frondosas anteriormente referidas.

Por último, las parcelas del IFN4 con una buena georreferenciación de 1-2 metros de precisión localizadas en dehesas tienen poca efectividad y utilidad a la hora de relacionarlo con los estadísticos LiDAR de baja densidad del PNOA, ya que se ha constatado que la precisión del GPS en estas masas adehesadas no tiene tanta influencia en el comportamiento de los modelos LiDAR generados. En ese sentido, se deberían centrar los esfuerzos por parte del MITECO en los próximos IFN en la toma de coordenadas GPS de buena precisión en masas forestales densas y continuas en las que la precisión del GPS sí tiene más influencia en el comportamiento de los modelos generados, y en aquellos estratos cuyo número de parcelas con coordenada corregida no alcanzan al mínimo necesario para generar con garantías un modelo LiDAR de masa eficiente.

Pocos autores han estudiado la eficiencia de los modelos predictivos de masa LiDAR resultantes de la combinación del Inventario Forestal Nacional con las coberturas LIDAR del PNOA, a excepción de GUERRA-HERNANDEZ, J et al. (2019), que estudió también la expansión continua del IFN4 en Extremadura y Canarias mediante técnicas LiDAR, pero usando la primera cobertura LiDAR del PNOA (año 2010), a diferencia de segunda la cobertura LiDAR-PNOA utilizada en el presente trabajo (año 2018). Sus resultados fueron también similares a los obtenidos en este trabajo, en cuanto al efecto de la georreferenciación en masas adehesadas, a los modelos de masa eficientes en masas puras, densas y uniformes de pinar, eucaliptal y alcornocal, y a los modelos menos satisfactorios en las masas abiertas de terrenos adehesados y en masas mixtas.

5. Conclusiones

Se confirma con este trabajo que la combinación del IFN con la cobertura LIDAR del PNOA resulta una excelente metodología de bajo coste a la hora de elaborar inventarios forestales, especialmente en masas densas, puras y continuas con un número suficiente de parcelas de inventario con coordenadas de precisión, en la que los modelos de masa LiDAR explican un alto porcentaje de la variabilidad para las principales variables dasométricas estudiadas. Por ello, estos modelos podrían ser aplicados a escala de monte o incluso cantón en estas circunstancias, con la consecuente ventaja de su bajo coste, y de que son capaces de recoger todas las existencias presentes en el monte a muy pequeña escala y de elaborar mapas de detalle, a diferencia de los inventarios por muestreo.

En cambio esta metodología de combinar el LiDAR-PNOA con el IFN 4 no fue tan satisfactoria y debe aplicarse un poco más con cautela en masas abiertas como los terrenos adehesados debido a la baja densidad de puntos del PNOA, y en las masas mixtas debido a que no existen suficientes parcelas del IFN4 bien georreferenciadas que recojan toda la variabilidad de dichas masas. Esto no quiere decir que no sea aplicable para estimar las existencias de las masas adehesadas presentes a un nivel superior (comarcal, provincial o regional), dada la escasa diferencia (entorno al 10%) con los resultados obtenidos tras expandir los modelos LiDAR generados con las existencias recogidas en el inventario forestal nacional.

Se confirma que en las masas abiertas como las Dehesas las parcelas del IFN4 tomadas con una coordenada precisa tienen poca efectividad y utilidad a la hora de relacionarlo con los estadísticos LIDAR de baja densidad del PNOA, ya que se ha constatado que la precisión del GPS en estas masas adehesadas no tiene tanta influencia en el comportamiento de los modelos LIDAR generados.

6. Bibliografía

GUERRA-HERNANDEZ, J.; AVILES, C.; BOTEQUIM, B.; JURADO-VARELA, A.; SANDOVAL, V.; ROBLA GONZALEZ, E.; 2019. Expansión continua del IFN4 de Extremadura y Canarias mediante técnicas LiDAR. En: Teledetección: Hacia Una Visión Global Del Cambio Climático. XVIII Congreso de la Asociación Española de Teledetección, Valladolid, España Valladolid, pp. 467-470.

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

ISENBURG, M., 2020. LASTTOOLS—efficient tools for LiDAR processing (Version 200216, academic).

LIM, K.; TREITZ, P.; WULDER, M.; ST-ONGE, B.; FLOOD, M.; 2003. LiDAR remote sensing of forest structure. *Progress in physical geography* 27, 88–106

MALTAMO, M., NÆSSET, E., VAUHKONEN, J., 2014. Forestry applications of airborne laser scanning. Springer.

MAPA, 2018. Mapa Forestal de España. Escala 1:25.000. Ministerio de Agricultura, Pesca y Alimentación. Dirección General de Desarrollo Rural, Innovación y Política Forestal.

MITECO, 2020. 4rd Inventory Forestal en Extremadura. Ministerio para la Transición Ecológica y el Reto Demográfico.

R CORE TEAM, 2020. R: A language and environment for statistical computing (Version 3.6.1)[Computer software]. Vienna, Austria: R Foundation for Statistical Computing.

VAN LEEUWEN, M.; NIEUWENHUIS, M.; 2010. Retrieval of forest structural parameters using LiDAR remote sensing. *European Journal of Forest Research* 129, 749–770.