



2022
Lleida

27 · 1
junio · juny
juliol · 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

Efectos de los errores de mapas en la incertidumbre de las estimaciones de volumen: un estudio de las principales especies forestales de La Rioja

ESTEBAN CAVA, J.¹, McROBERTS, R.², FERNÁNDEZ-LANDA, A.¹ y TOMÉ, J.L.¹

¹ AGRESTA Sociedad Cooperativa

² Universidad de Minnesota.

Resumen

En el proceso de estimación de variables forestales se suelen emplear cartografías base sobre la distribución de especies forestales. Sin embargo, y a pesar de su uso generalizado, no se suele cuantificar la incertidumbre asociada con estos mapas pudiendo suponer fuentes de error no controladas. El objetivo de este estudio era estimar el efecto que tiene la incertidumbre de un mapa de distribución de especies utilizado en el proceso de estimación del volumen de madera (V) de las principales especies forestales de La Rioja en un inventario LiDAR con métodos de masa. Para la estimación del V se ajustaron modelos Random Forest relacionando los datos de las parcelas del cuarto Inventario Forestal Español con datos LiDAR de 2010. Se generó un mapa de tipos de especies forestales a partir de imágenes espectrales de Landsat-5. Para cuantificar la incertidumbre de los modelos de predicción de V y del mapa Landsat se implementaron distintas técnicas de remuestreo bootstrapping. La incertidumbre del volumen total aumentó entre 1,6 y 3,1 veces en el caso de considerar la incertidumbre del mapa Landsat, el cual es más acusado para las masas forestales más discontinuas y con una superficie menor. Los resultados revelan que los efectos de la incertidumbre del mapa sobre la incertidumbre de las estimaciones de volumen son significativos, y el hecho de ignorar dichos efectos podría poner en peligro la fiabilidad de las estimaciones de volumen forestal.

Palabras clave

Random forest, propagación, bootstrapping, Landsat, LiDAR.

1. Introducción

Los inventarios forestales nacionales (IFN) nacieron con el objetivo de obtener la mayor cantidad posible de información sobre el estado de los bosques, siendo una fuente primordial de datos para la evaluación de los recursos forestales a grandes escalas (Travaglini et al., 2013). Uno de los principales inconvenientes de los IFNs, es el elevado coste asociado con la medición de parcelas (White et al., 2016). En este sentido la integración de los muestreos tradicionales de parcelas de campo con información de sensores remotos es un aspecto clave ya que permite reducir costes en la estimación de atributos forestales (McRoberts et al., 2002), a la vez que aumentar la eficiencia de los muestreos y la precisión de las estimaciones (Gregoire et al., 2016). Además, la integración de fuentes de datos satelitales en los inventarios, permite obtener estimaciones con una resolución temporal mayor. Consecuentemente, la gran disponibilidad de datos provenientes de diferentes sensores (tanto activos como pasivos) y plataformas (aerotransportadas y satelitales) ha hecho que la integración de fuentes diversas de información sea un campo cada vez más estudiado (Chirici et al., 2020; Deo et al., 2017; Maselli et al., 2014).

Este hecho ha impulsado la aplicación y el desarrollo de nuevos métodos de inferencia que ajustan modelos predictivos integrando información auxiliar proveniente de sensores remotos (Ståhl et al., 2016). La aplicación de modelos para la estimación de atributos forestales en grandes superficies es una práctica muy extendida en la comunidad científica (Chen et al., 2016; Chirici et

al., 2020; Margolis et al., 2015; Saarela et al., 2015). Sin embargo, hay que tener en cuenta que la eficacia de los métodos de inferencia basados en modelos depende de la bondad de ajuste del modelo aplicado, por lo que los estimadores poblacionales pueden ser sesgados e imprecisos (McRoberts, 2010). Estas dificultades han propiciado un menor desarrollo de esta disciplina (McRoberts et al., 2018), existiendo estudios en los que a pesar de aplicar este marco de inferencia no se desarrolla una estimación rigurosa de la incertidumbre del estimador en cuestión (Ståhl et al., 2016). Sin embargo, tal y como establece el Grupo Intergubernamental de Expertos sobre el Cambio Climático (IPCC) las incertidumbres deben reducirse en la medida de lo posible (IPCC, 2019b) pero antes de poder reducir las incertidumbres, estas deben estimarse adecuadamente.

En las últimas décadas los avances más importantes en el desarrollo de procedimientos que consideran múltiples fuentes de incertidumbre se han llevado principalmente a cabo con técnicas de modelización paramétricas (Chen et al., 2016; McRoberts and Westfall, 2016; Saarela et al., 2020, 2016; Shettles et al., 2015), ya que cuando se aplican modelos no paramétricos el procedimiento de estimación de la incertidumbre es más complejo y laborioso de implementar (Kangas et al., 2016) al no existir métodos analíticos. Además, hay otras fuentes de incertidumbre que no se suelen cuantificar como la implicación de mapas base de cartografía de especies (Hansen et al., 1983; McRoberts et al., 2014). Estos mapas pueden utilizarse en la fase de diseño (Grafstörn et al., 2014) y en la fase de estimación de las variables forestales (McRoberts et al., 2010; Tomppo et al., 2010), por lo que ignorar su incertidumbre podría afectar a la fiabilidad de las estimaciones forestales proporcionadas. Las estimaciones nacionales como las incertidumbres de las estimaciones son necesarias para los informes de los IFNs y se requieren específicamente para los inventarios de gases de efecto invernadero.

2. Objetivos

El objetivo de este trabajo era cuantificar el impacto que tiene la incertidumbre de un mapa de distribución de especies, realizado con técnicas de teledetección, en la incertidumbre total de la variable volumen de madera en un inventario LiDAR con métodos de masa.

3. Metodología

La zona de estudio se sitúa en la provincia de La Rioja con una superficie de 5.045 km² (Figura 1). La Rioja está rodeada por dos grandes unidades de relieve con elevaciones desde los 260 a los 2300 m aproximadamente. Este gran gradiente altitudinal contribuye a una rica diversidad vegetal. Los terrenos forestales cubren el 34,7% de La Rioja siendo las principales especies forestales, por orden de superficie: rebollo (*Quercus pyrenaica* Willd), pino silvestre (*Pinus sylvestris* L.), haya (*Fagus sylvatica* L.) y encina (*Quercus ilex* L.) (Ministerio de Agricultura, 2013) (p. 11). El resto de la zona de estudio son tierras bajas compuestas por campos de secano y regadío donde el paisaje se vuelve más homogéneo.

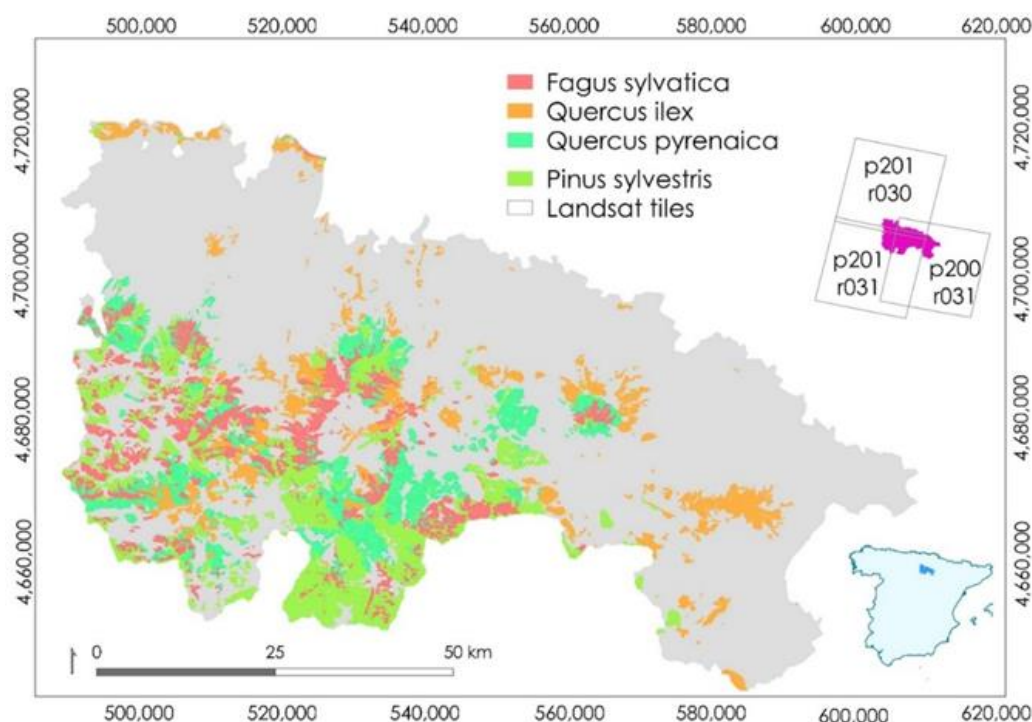


Figura 1. Localización de la zona de estudio y distribución de las especies forestales principales.

El enfoque metodológico desarrollado ha utilizado distintas fuentes de información:

1. **Imágenes Landsat** para construir un **mapa de las principales especies forestales** (“mapa Landsat”). La zona de estudio está cubierta por tres escenas Landsat con path (p) y row (r): p201 r031, p200 r031 y p200 r030 (Figura 1). Para cada escena, se utilizaron imágenes Landsat 5 Thematic Mapper (TM) predominantemente libres de nubes del 1 de junio al 31 de agosto de 2010. Se construyeron compuestos anuales de verano basados en los píxeles más verdes disponibles definidos por el Índice de Vegetación de Diferencia Normalizada (NDVI). Se obtuvieron tres índices de vegetación a partir de los compuestos anuales de verano: NDVI, el índice de humedad diferencial normalizado (NDMI) y el índice de quemado normalizado (NBR).
2. **Datos LiDAR** de 2010 del Plan Nacional de Ortofotografía Aérea con los que se ha obtenido una serie de estadísticos con el software FUSION (McGaughey et al., 2003). Los datos LiDAR fueron adquiridos entre agosto y octubre de 2010, con una densidad de pulsos media de 0,5 pulsos por m² y un error cuadrático medio vertical (RMSE) ≤ 0,20 m. Las métricas LiDAR incluían la media, la varianza (varia), la desviación estándar (stdev), el coeficiente de variación (cv), el rango intercuartil (iq), la curtosis (kurto), los percentiles (que van del percentil 1 al 99: p1, p5, p25, p50, p75, p95 y p99), la proporción del relieve del dosel (crr) y la cobertura del dosel forestal (lfcc). Estas métricas sirvieron como variables predictoras para ajustar modelos de volumen con corteza (V, m³/ha).
3. **Parcelas** de campo del cuarto inventario forestal español (IFN), medidas entre 2011 y 2012. Estas parcelas se han utilizado para ajustar modelos de predicción de V para las especies principales utilizando como variables predictivas el conjunto de métricas de estructura de los datos LiDAR. Una de las mayores dificultades derivadas de integrar datos

de sensores remotos y parcelas de los IFN es el error de geolocalización del centro de las coordenadas de sus parcelas, influyendo en la correlación entre las variables medidas en campo y los datos de teledetección. Es por ello que aquellas que presentaron mayor discrepancia entre los valores de altura medidos en campo y con LiDAR se eliminaron.

En el estudio se utilizaron tres técnicas estadísticas principales. En primer lugar, se utilizaron modelos Random forests para la clasificación del mapa Landsat y para predecir el V. En segundo lugar, se utilizaron métodos de inferencia basados en el modelo (*model-based*) para estimar el V total de la población y su error estándar. En tercer lugar, para estimar la incertidumbre de los modelos de clasificación y de predicción se aplicaron técnicas de remuestreo bootstrapping. La esencia de esta metodología consiste en construir sucesivamente nuevas muestras de remuestreo que simulen la muestra original. Estas muestras sirven posteriormente para calibrar distintos modelos que se aplican a toda la población obteniéndose estimaciones poblacionales y la incertidumbre de dichas estimaciones. Estos pasos se repiten un número de iteraciones hasta que se consigue la estabilización de estos estimadores.

A la hora de generar la muestra de remuestreo existen diversos métodos habiéndose utilizado métodos pair bootstrapping (p) (Efron and Tibshirani, 1994) para la incertidumbre del mapa Landsat y métodos wild bootstrapping (w) (Liu, 1988) para la incertidumbre del modelo de V. La técnica pair consiste en seleccionar aleatoriamente la muestra original de manera que algunas unidades muestrales pueden estar repetidas y otras excluidas. Por el contrario, la técnica wild bootstrapping es más difícil de implementar y requiere de unos cálculos iniciales. En este caso la muestra resampleada se obtiene a partir de la suma de los valores predichos del modelo inicial ajustado y los residuos.

La estimación de la incertidumbre del modelo del V conllevó los siguientes pasos:

- (1) Selección de las parcelas del IFN localizadas en zonas arboladas de acuerdo con el mapa Landsat inicial y creación de una muestra de remuestreo (con métodos wild) a partir de los datos IFN de V iniciales.
- (2) Calibración de un nuevo modelo de predicción de V con la muestra del paso 1.
- (3) Obtención de un nuevo mapa de V al aplicar el modelo RF del paso 2 sobre el mapa Landsat inicial.
- (4) Estimación del V total (m^3) para cada una de las especies forestales analizadas de acuerdo con el mapa Landsat inicial.
- (5) Repetición de los pasos 1-4 (2.000 repeticiones).

Una vez finalizadas las 2.000 repeticiones se procedió a la estimación del volumen total poblacional ($\widehat{VT}_{w plot}^k$) y de su error estándar ($SE(\widehat{VT}_{w plot}^k)$) como:

$$SE(\widehat{VT}_{w plot}^k) = \sqrt{\frac{1}{n_{boot} - 1} \sum_{b=1}^{n_{boot}} (\widehat{VT}_{wb}^k - \widehat{VT}_{w plot}^k)^2}$$

Donde nboot hace referencia al número de iteraciones bootstrapping y \widehat{VT}_{wb}^k al volumen total para cada una de las especies forestales que se obtiene en cada una de las iteraciones.

La estimación de la incertidumbre del mapa Landsat sobre las predicciones de V conllevó los siguientes pasos (Figura 2):

- (1) Selección de una muestra de remuestreo (con métodos pair) a partir de los datos de entrenamiento utilizados para calibrar el modelo inicial de clasificación RF.
- (2) Calibración de un nuevo modelo de clasificación con la muestra del paso 1.

- (3) Obtención de un nuevo mapa Landsat al aplicar el modelo RF del paso 2.
- (4) Selección de las parcelas del IFN localizadas en zonas arboladas de acuerdo con el mapa Landsat del paso 3 y creación de una muestra de remuestreo (con métodos wild) a partir de los datos IFN de V iniciales.
- (5) Calibración de un nuevo modelo de predicción de V con la muestra del paso 4.
- (6) Obtención de un nuevo mapa de V al aplicar el modelo RF del paso 5 sobre el mapa Landsat nuevo.
- (7) Estimación del V total para cada una de las especies forestales analizadas de acuerdo con el mapa Landsat nuevo.
- (8) Repetición de los pasos 1-7 (2.000 repeticiones).

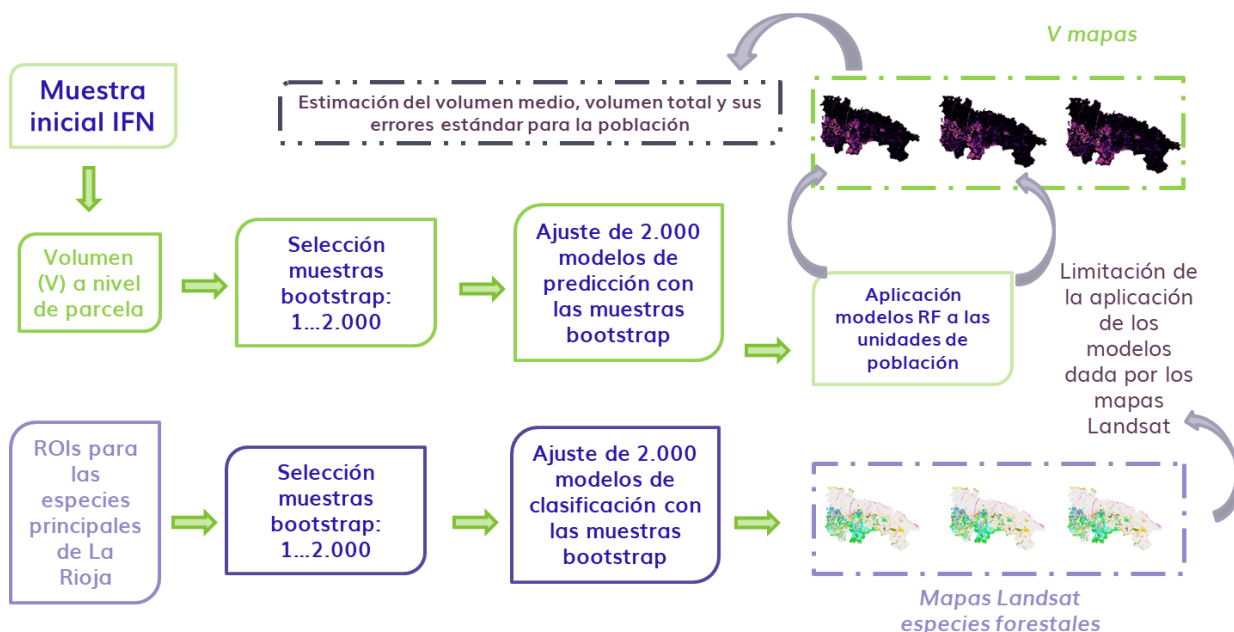


Figura 2. Resumen metodológico de las técnicas bootstrapping pair y wild aplicadas para cuantificar la incertidumbre del mapa Landsat sobre las predicciones de volumen.

Una vez finalizadas las 2.000 repeticiones se procedió a la estimación poblacional del error estándar del volumen total ($SE(\widehat{VT}_{p\ map}^k)$) teniendo solo en cuenta la incertidumbre del mapa Landsat.

$$SE(\widehat{VT}_{p\ map}^k) = \sqrt{\frac{1}{n_{boot} - 1} \sum_{b=1}^{n_{boot}} (\widehat{VT}_{p\ b}^k - \widehat{VT}_{p\ map}^k)^2}$$

Finalmente, una vez que se cuantificó de manera individual la incertidumbre del mapa Landsat y del modelo de V, se procedió a la estimación del error estándar del volumen total ($SE(\widehat{VT}_{total}^k)$) propagando las dos fuentes de incertidumbre como:

$$SE(\widehat{VT}_{total}^k) = \sqrt{SE^2(\widehat{VT}_{p\ map}^k) + SE^2(\widehat{VT}_{w\ plot}^k)}$$

4. Resultados

La evaluación de la exactitud de la clasificación Landsat se realizó con la validación interna de Random Forest presentando una exactitud global del 88% con errores de omisión y comisión inferiores al 10% para la mayoría de las especies forestales. Los peores resultados de exactitud del usuario y productor se obtuvieron para la clase de *Quercus* con 23% de error de comisión y un 16% de omisión.

Los resultados muestran (Tabla 1) que los efectos de la incertidumbre del mapa Landsat no son insignificantes para ninguna de las principales especies forestales, con un error estándar que oscilaba entre el 3% y el 12%, siendo para la encina (12,05%). Los resultados reflejan que la incertidumbre total está más influida por los efectos de la incertidumbre del mapa Landsat que por la incertidumbre del modelo de V, con valores de error estándar entre 3-12% frente a los errores estándar del modelo de V entre 2-9%. Cuando se tienen en cuenta ambas incertidumbres el error estándar aumenta en un 5% para la mayoría de las especies. Los mayores errores estándar en la propagación se observan para QI con un aumento del 9 al 15%. Es decir, en el caso de considerar la incertidumbre tanto de los modelos de predicción de volumen como de la cartografía de especies, el error estándar es entre 1,6 y 3,1 veces mayor que en el caso de no considerar la incertidumbre del mapa, el cual es más acusado para las masas forestales más discontinuas y menos representadas como la encina.

Tabla 1. Fuentes de incertidumbre en la estimación del volumen total para las especies forestales principales de La Rioja.

Especies forestales*	Incertidumbre mapa Landsat	Incertidumbre modelo de V	Incertidumbre total
	$SE(\widehat{VT}_{p\ map}^k)$ (%)	$SE(\widehat{VT}_{w\ plot}^k)$ (%)	$SE(\widehat{VT}_{total}^k)$ (%)
FS	3,17	2,46	4,01
PS	4,65	2,37	5,22
Q	4,66	2,84	5,46
QI	12,05	9,07	15,08

* FS: *Fagus sylvatica*; PS: *Pinus sylvestris*; Q: *Quercus pyrenaica/faginea*; QI: *Quercus ilex*.

5. Discusión

En este artículo se han implementado técnicas wild and pair bootstrapping para cuantificar la incertidumbre de las estimaciones obtenidas en base al algoritmo random forests. El uso de técnicas bootstrapping ha permitido enriquecer todavía más la cuantificación de recursos forestales propagando distintas fuentes de incertidumbre (Andersen et al., 2012; Condés and McRoberts, 2017; Fortin et al., 2018; Hou et al., 2017; Sexton and Laake, 2009). A pesar de que numerosos autores han demostrado que la clasificación de imágenes de satélite multispectral permite generar cartografía temática añadiendo valor a los inventarios (Blázquez-Casado et al., 2019; Dalponte et al., 2012; Fernández-Landa et al., 2018; Fragoso-Campón et al., 2020; Shendryk, 2013), hasta ahora la mayoría de trabajos no ha considerado esta componente de incertidumbre (Margolis et al., 2015; Neigh et al., 2013; Su et al., 2016). Los resultados obtenidos confirman que no se puede ignorar la incertidumbre de la cartografía temática, en los inventarios LiDAR por métodos de masa, siendo estos consistentes con los de otros autores que analizaron la influencia de la incertidumbre

de cartografías de especies o mapas de composición específica. Rodríguez-Veiga et al. (2016) demostró que el uso de diferentes máscaras de bosque tiene un impacto en la estimación de carbono de México. La variación en la extensión de bosque dada por cada máscara da lugar a diferencias de hasta 0,45 giga toneladas de carbono. Breidenbach et al. (2020) empleó una máscara de zonas de bosque y no bosque, obtenida a partir del mapa noruego nacional de recursos del suelo, con una exactitud del 92% y a una escala 1:5.000. Esta máscara se utilizó como mapa base para estimar la superficie de los estratos de pino, abeto y caducifolias para todo el territorio nacional. Para ello aplicó inferencia asistida por modelos demostrando que cuando se ignora el error de la máscara hay una pérdida de exactitud de alrededor del 6%. Esa misma máscara es utilizada en otro estudio para asistir un modelo en la estimación del diámetro a la altura del pecho demostrando así mismo, que el error de la máscara conlleva una pérdida de exactitud (Räty et al., 2020). Li et al. (2017) afirmó que los efectos de la incertidumbre de una cartografía de coberturas del suelo afectaban sustancialmente a las estimaciones de flujos de calor utilizadas en técnicas de modelización del clima.

Dado que la zona de estudio representa una gran superficie no se ha cuantificado la variabilidad de los residuos como fuente de incertidumbre, sin embargo, es importante destacar que en áreas más pequeñas (a nivel de rodal) no se puede considerar que esta fuente de incertidumbre sea insignificante (Breidenbach and Astrup, 2012; McRoberts et al., 2018). Otras fuentes de incertidumbre que no se han considerado han sido el error de medición y el error de las ecuaciones alométricas de árbol empleadas para predecir el volumen total de cada parcela. Ninguna de estas fuentes contribuye considerablemente a la incertidumbre de las estimaciones finales, sobre todo cuando las ecuaciones alométricas se calibran con bases de datos con un número elevado de mediciones (McRoberts and Westfall, 2016). No obstante, cuando el número de árboles medidos disminuye, aumenta la incertidumbre de las ecuaciones alométricas. En el estudio de Chen et al. (2015) simulaban una reducción del tamaño de la muestra de árboles medidos desde 4000 a 400 árboles y a 40 que supuso un incremento del error del 0,74% al 2,52% y 5,69%, respectivamente.

En virtud de los resultados obtenidos se recomienda que futuros estudios sobre el presente tema repliquen la metodología desarrollada en otro tipo de ecosistemas forestales y que analicen las implicaciones derivadas de no cuantificar la incertidumbre de los mapas base en inventarios LiDAR por métodos de masa. En este trabajo, la cartografía temática se utiliza como base para la aplicación de los modelos LiDAR de volumen específicos y para la selección de las parcelas de campo utilizadas para la calibración de los modelos. Sería necesario analizar también cómo contribuye el error de la información temática en otro tipo de estudios como cuando se utiliza una cartografía como máscara para limitar la superficie de estudio en la que realizar el análisis (DeVries et al., 2015; Fang et al., 2018; Hamunyela et al., 2020; Schultz et al., 2018; Vogeler et al., 2018).

6. Conclusiones

El estudio ha evaluado el efecto de la incertidumbre de un mapa de especies forestales que interviene en la selección de las parcelas de campo utilizadas para calibrar los modelos de volumen y en la estimación del volumen poblacional. Del estudio se extrajeron tres conclusiones (1) los efectos de la incertidumbre del mapa sobre la incertidumbre de las estimaciones de volumen son significativos, y el hecho de ignorar dichos efectos podría poner en peligro la fiabilidad de las estimaciones de volumen forestal; (2) los efectos de la incertidumbre del mapa aumentan para las masas forestales con estructura abierta; y (3) los resultados son relevantes para los países que utilizan un mapa de bosques/no bosques basado en la teledetección para guiar la distribución de parcelas de campo. Se recomienda seguir trabajando en una variedad de entornos forestales para evaluar si las conclusiones pueden generalizarse más allá de los ecosistemas mediterráneos.

7. Agradecimientos

Gracias al Instituto Geográfico Nacional de España y al Inventario Forestal Nacional por el acceso gratuito a los datos LiDAR y a los datos de inventario.

8. Bibliografía

ANDERSEN, H.E., STRUNK, J., TEMESGEN, H., ATWOOD, D., WINTERBERGER, K., 2012. Using multilevel remote sensing and ground data to estimate forest biomass resources in remote regions: A case study in the boreal forests of interior Alaska. *Can. J. Remote Sens.* 37, 596–611. <https://doi.org/10.5589/m12-003>

BLÁZQUEZ-CASADO, Á., CALAMA, R., VALBUENA, M., VERGARECHEA, M., RODRÍGUEZ, F., 2019. Combining low-density LiDAR and satellite images to discriminate species in mixed Mediterranean forest. *Ann. For. Sci.* 76, 57. <https://doi.org/10.1007/s13595-019-0835-x>

BREIDENBACH, J., ASTRUP, R., 2012. Small area estimation of forest attributes in the Norwegian National Forest Inventory. *Eur. J. For. Res.* 131, 1255–1267. <https://doi.org/10.1007/s10342-012-0596-7>

BREIDENBACH, J., WASER, L.T., DEBELLA-GILO, M., SCHUMACHER, J., RAHLF, J., HAUGLIN, M., PULITI, S., ASTRUP, R., 2020. National mapping and estimation of forest area by dominant tree species using sentinel-2 data. *Can. J. For. Res.* <https://doi.org/10.1139/cjfr-2020-0170>

CHEN, Q., MCROBERTS, R.E., WANG, C., RADTKE, P.J., 2016. Forest aboveground biomass mapping and estimation across multiple spatial scales using model-based inference. *Remote Sens. Environ.* 184, 350–360. <https://doi.org/10.1016/j.rse.2016.07.023>

CHEN, Q., VAGLIO LAURIN, G., VALENTINI, R., 2015. Uncertainty of remotely sensed aboveground biomass over an African tropical forest: Propagating errors from trees to plots to pixels. *Remote Sens. Environ.* 160, 134–143. <https://doi.org/10.1016/j.rse.2015.01.009>

CHIRICI, G., GIANNETTI, F., MCROBERTS, R.E., TRAVAGLINI, D., PECCHI, M., MASELLI, F., CHIESI, M., CORONA, P., 2020. Wall-to-wall spatial prediction of growing stock volume based on Italian National Forest Inventory plots and remotely sensed data. *Int. J. Appl. Earth Obs. Geoinf.* 84, 101959. <https://doi.org/10.1016/j.jag.2019.101959>

CONDÉS, S., MCROBERTS, R.E., 2017. Updating national forest inventory estimates of growing stock volume using hybrid inference. *For. Ecol. Manage.* 400, 48–57. <https://doi.org/10.1016/j.foreco.2017.04.046>

DALPONTE, M., BRUZZONE, L., GIANELLE, D., 2012. Tree species classification in the Southern Alps based on the fusion of very high geometrical resolution multispectral / hyperspectral images and LiDAR data. *Remote Sens. Environ.* 123, 258–270. <https://doi.org/10.1016/j.rse.2012.03.013>

DEO, R.K., RUSSELL, M.B., DOMKE, G.M., WOODALL, C.W., FALKOWSKI, M.J., COHEN, W.B.,

2017. Using Landsat Time-Series and LiDAR to Inform Aboveground Forest Biomass Baselines in Northern Minnesota, USA. *Can. J. Remote Sens.* 43, 28–47. <https://doi.org/10.1080/07038992.2017.1259556>

DEVRIES, B., DECUYPER, M., VERBESSELT, J., ZEILEIS, A., HEROLD, M., JOSEPH, S., 2015. Tracking disturbance-regrowth dynamics in tropical forests using structural change detection and Landsat time series. *Remote Sens. Environ.* 169, 320–334. <https://doi.org/10.1016/j.rse.2015.08.020>

EFRON, B., TIBSHIRANI, R.J., 1994. *An Introduction to the Bootstrap*. Chapman and Hall, New York, NY, USA.

FANG, X., ZHU, Q., REN, L., CHEN, H., WANG, K., PENG, C., 2018. Large-scale detection of vegetation dynamics and their potential drivers using MODIS images and BFAST: A case study in Quebec, Canada. *Remote Sens. Environ.* 206, 391–402. <https://doi.org/10.1016/j.rse.2017.11.017>

FERNÁNDEZ-LANDA, A., FERNÁNDEZ-MOYA, J., TOMÉ, J.L., ALGEET-ABARQUERO, N., GUILLÉN-CLIMENT, M.L., VALLEJO, R., SANDOVAL, V., 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.* 00, 1–15. <https://doi.org/10.1080/01431161.2018.1430406>

FORTIN, M., MANSO, R., SCHNEIDER, R., 2018. Parametric bootstrap estimators for hybrid inference in forest inventories. *Forestry* 91, 354–365. <https://doi.org/10.1093/forestry/cpx048>

FRAGOSO-CAMPÓN, L., QUIRÓS ROSADO, E., GUTIÉRREZ GALLEGÓ, J.A., 2020. Clasificación supervisada de imágenes PNOA-NIR y fusión con datos LiDAR-PNOA como apoyo en el inventario forestal. Caso de estudio: Dehesas. *Cuad. la Soc. Española Ciencias For.* 45, 77–96. <https://doi.org/10.31167/csecfv0i45.19882>

GRAFSTÖRM, A., SAARELA, S., ENE, L., 2014. Efficient sampling strategies for forest inventories by spreading the sample in auxiliary space. *Can. J. For. Res.* 44, 1156–1164.

GREGOIRE, T.G., NÆSSET, E., MCROBERTS, R.E., STÅHL, G., ANDERSEN, H.E., GOBAKKEN, T., ENE, L., NELSON, R., 2016. Statistical rigor in LiDAR-assisted estimation of aboveground forest biomass. *Remote Sens. Environ.* 173, 98–108. <https://doi.org/10.1016/j.rse.2015.11.012>

HAMUNYELA, E., BRANDT, P., SHIRIMA, D., DO, H.T.T., HEROLD, M., ROMAN-CUESTA, R.M., 2020. Space-time detection of deforestation, forest degradation and regeneration in montane forests of Eastern Tanzania. *Int. J. Appl. Earth Obs. Geoinf.* 88, 102063. <https://doi.org/10.1016/j.jag.2020.102063>

HANSEN, M.H., MADOW, W.G., TEPPING, B.J., 1983. An evaluation of model-dependent and probability-sampling inferences in sample surveys. *J. Am. Stat. Assoc.* 78, 776–793. <https://doi.org/10.1080/01621459.1983.10477018>

HOU, Z., XU, Q., MCROBERTS, R.E., GREENBERG, J.A., LIU, J., HEISKANEN, J., PITKÄNEN, S., PACKALÉN, P., 2017. Effects of temporally external auxiliary data on model-based inference. *Remote Sens. Environ.* 198, 150–159. <https://doi.org/10.1016/j.rse.2017.06.013>

KANGAS, A., MYLLYMÄKI, M., GOBAKKEN, T., NÆSSET, E., 2016. Model-assisted forest inventory with parametric, semi-parametric and non-parametric models. *Can. J. For. Res.* 46, 855–868.

LI, X., MESSINA, J.P., MOORE, N.J., FAN, P., SHORTRIDGE, A.M., 2017. MODIS land cover uncertainty in regional climate simulations. *Clim. Dyn.* 49, 4047–4059. <https://doi.org/10.1007/s00382-017-3563-7>

LIU, R., 1988. Bootstrap Procedures under some Non-I.I.D. Models. *Ann.Sta* 16, 1696–1708. <https://doi.org/10.1214/aos/1176351062>

MARGOLIS, H.A., NELSON, R.F., MONTESANO, P.M., BEAUDOIN, A., SUN, G., ANDERSEN, H.-E., WULDER, M.A., 2015. Combining satellite lidar, airborne lidar, and ground plots to estimate the amount and distribution of aboveground biomass in the boreal forest of North America. *Can. J. For. Res.* 45, 838–855. <https://doi.org/10.1139/cjfr-2015-0006>

MASELLI, F., CHIESI, M., MURA, M., MARCHETTI, M., CORONA, P., CHIRICI, G., 2014. Combination of optical and LiDAR satellite imagery with forest inventory data to improve wall-to-wall assessment of growing stock in Italy. *Int. J. Appl. Earth Obs. Geoinf.* 26, 377–386. <https://doi.org/10.1016/j.jag.2013.09.001>

MCGAUGHEY, R., FORESTER, R., CARSON, W., 2003. Fusing LIDAR data, photographs, and other data using 2D and 3D visualization techniques. *Proc. Terrain Data Appl. Vis. Connect.* 28–30, 16–24.

MCROBERTS, R.E., 2010. Probability- and model-based approaches to inference for proportion forest using satellite imagery as ancillary data. *Remote Sens. Environ.* 114, 1017–1025. <https://doi.org/10.1016/j.rse.2009.12.013>

MCROBERTS, R.E., COHEN, W.B., ERIK, N., STEHMAN, S. V., TOMPPA, E.O., 2010. Using remotely sensed data to construct and assess forest attribute maps and related spatial products. *Scand. J. For. Res.* 25, 340–367. <https://doi.org/10.1080/02827581.2010.497496>

MCROBERTS, R.E., NÆSSET, E., GOBAKKEN, T., 2014. Estimation for inaccessible and non-sampled forest areas using model-based inference and remotely sensed auxiliary information. *Remote Sens. Environ.* 154, 226–233. <https://doi.org/10.1016/j.rse.2014.08.028>

MCROBERTS, R.E., NÆSSET, E., HOU, Z., WALTERS, B.F., NÆSSET, E., GOBAKKEN, T., CHIRICI, G., CONDÉS, S., HOU, Z., SAARELA, S., CHEN, Q., STÅHL, G., WALTERS, B.F., 2018. Assessing components of the model-based mean square error estimator for remote sensing assisted forest applications. *Can. J. For. Res.* 48, 642–649. <https://doi.org/10.1139/cjfr->

2017-0396

MCROBERTS, R.E., WENDT, D.G., NELSON, M.D., HANSEN, M.H., 2002. Using a land cover classification based on satellite imagery to improve the precision of forest inventory area estimates. *Remote Sens. Environ.* 81, 36–44. [https://doi.org/10.1016/S0034-4257\(01\)00330-3](https://doi.org/10.1016/S0034-4257(01)00330-3)

MCROBERTS, R.E., WESTFALL, J.A., 2016. Propagating uncertainty through individual tree volume model predictions to large-area volume estimates. *Ann. For. Sci.* 73, 625–633. <https://doi.org/10.1007/s13595-015-0473-x>

NEIGH, C.S.R., NELSON, R.F., RANSON, K.J., MARGOLIS, H.A., MONTESANO, P.M., SUN, G., KHARUK, V., NÆSSET, E., WULDER, M.A., ANDERSEN, H.E., 2013. Taking stock of circumboreal forest carbon with ground measurements, airborne and spaceborne LiDAR. *Remote Sens. Environ.* 137, 274–287. <https://doi.org/10.1016/j.rse.2013.06.019>

RÄTY, J., ASTRUP, R., BREIDENBACH, J., 2020. Prediction and model-assisted estimation of diameter distributions using Norwegian national forest inventory and airborne laser scanning data. preprint.

RODRÍGUEZ-VEIGA, P., SAATCHI, S., TANSEY, K., BALZTER, H., 2016. Magnitude, spatial distribution and uncertainty of forest biomass stocks in Mexico. *Remote Sens. Environ.* 183, 265–281. <https://doi.org/10.1016/j.rse.2016.06.004>

SAARELA, S., GRAFSTRÖM, A., STÅHL, G., KANGAS, A., HOLOPAINEN, M., TUOMINEN, S., NORDKVIST, K., HYYPPÄ, J., 2015. Model-assisted estimation of growing stock volume using different combinations of LiDAR and Landsat data as auxiliary information. *Remote Sens. Environ.* 158, 431–440. <https://doi.org/10.1016/j.rse.2014.11.020>

SAARELA, S., HOLM, S., GRAFSTRÖM, A., SCHNELL, S., NÆSSET, E., GREGOIRE, T.G., NELSON, R.F., STÅHL, G., 2016. Hierarchical model-based inference for forest inventory utilizing three sources of information. *Ann. For. Sci.* 73, 895–910. <https://doi.org/10.1007/s13595-016-0590-1>

SAARELA, S., WÄSTLUND, A., HOLMSTRÖM, E., MENSAH, A.A., HOLM, S., NILSSON, M., FRIDMAN, J., STÅHL, G., 2020. Mapping aboveground biomass and its prediction uncertainty using LiDAR and field data, accounting for tree-level allometric and LiDAR model errors. *For. Ecosyst.* 7, 1–13. <https://doi.org/10.1186/s40663-020-00245-0>

SCHULTZ, M., SHAPIRO, A., CLEVERS, J.G.P.W., BEECH, C., HEROLD, M., 2018. Forest cover and vegetation degradation detection in the Kavango Zambezi Transfrontier Conservation area using BFAST monitor. *Remote Sens.* 10, 1850. <https://doi.org/10.3390/rs10111850>

SEXTON, J., LAAKE, P., 2009. Standard errors for bagged and random forest estimators. *Comput. Stat. Data Anal.* 53, 801–811. <https://doi.org/10.1016/j.csda.2008.08.007>

SHENDRYK, I., 2013. Integration of LiDAR data and satellite imagery for biomass estimation in conifer-dominated forest. Lund University.

SHETTLES, M., TEMESGEN, H., GRAY, A.N., HILKER, T., 2015. Comparison of uncertainty in per unit area estimates of aboveground biomass for two selected model sets. *For. Ecol. Manage.* 354, 18–25. <https://doi.org/10.1016/j.foreco.2015.07.002>

STÅHL, G., SAARELA, S., SCHNELL, S., HOLM, S., BREIDENBACH, J., HEALEY, S.P., PATTERSON, P.L., MAGNUSSEN, S., NÆSSET, E., MCROBERTS, R.E., GREGOIRE, T.G., 2016. Use of models in large-area forest surveys: comparing model-assisted, model-based and hybrid estimation. *For. Ecosyst.* 3, 5. <https://doi.org/10.1186/s40663-016-0064-9>

SU, Y., GUO, Q., XUE, B., HU, T., ALVAREZ, O., TAO, S., FANG, J., 2016. Spatial distribution of forest aboveground biomass in China: Estimation through combination of spaceborne lidar, optical imagery, and forest inventory data. *Remote Sens. Environ.* 173, 187–199. <https://doi.org/10.1016/j.rse.2015.12.002>

TOMPPA, E., GSCHWANTNER, T., LAWRENCE, M., MCROBERTS, R.E., 2010. National forest inventories: Pathways for common reporting. Springer, Dordrecht, The Netherlands.

TRAVAGLINI, D., CHIRICI, G., BOTTALICO, F., FERRETTI, M., CORONA, P., BARBATI, A., FATTORINI, L., 2013. Chapter 7 - Large-Scale Pan-European Forest Monitoring Network: A Statistical Perspective for Designing and Combining Country Estimates. Example for Defoliation, in: Ferretti, M., Fischer, R.B.T.-D. in E.S. (Eds.), *Forest Monitoring*. Elsevier, pp. 105–135. <https://doi.org/https://doi.org/10.1016/B978-0-08-098222-9.00007-8>

VOGELER, J.C., BRAATEN, J.D., SLESAK, R.A., FALKOWSKI, M.J., 2018. Extracting the full value of the Landsat archive: Inter-sensor harmonization for the mapping of Minnesota forest canopy cover (1973–2015). *Remote Sens. Environ.* 209, 363–374. <https://doi.org/10.1016/j.rse.2018.02.046>

WHITE, J.C., COOPS, N.C., WULDER, M.A., VASTARANTA, M., HILKER, T., TOMPALSKI, P., 2016. Remote Sensing Technologies for Enhancing Forest Inventories: A Review. *Can. J. Remote Sens.* 42, 619–641. <https://doi.org/10.1080/07038992.2016.1207484>