



2025 | **16-20**
GIJÓN | **JUNIO**

9º CONGRESO FORESTAL ESPAÑOL

9CFE-1894

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

Organiza





Estimación de índice de sitio y distribuciones diamétricas en masas de sabina del sistema ibérico usando datos LiDAR multitemporales

MAURO GUTIERREZ F. (1), CANDEL PÉREZ D. (1-2), GOMEZ ROUX M. (1), DOMINGO RUIZ D. (1,3), MANZANERA DE LA VEGA J. (4), GONZALEZ MESQUIDA J. (1), GARCIA GOMEZ R(1).

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

(2) (2) Sección de Desarrollo Territorial Sostenible, NASUVINSA, Pamplona (Navarra).

(3) GEOFOREST, Universidad de Zaragoza, 50009 Zaragoza, España.

(4) Universidad Politécnica de Madrid. ETS de Ingeniería de Montes, Forestal y del Medio Natural

Resumen

Los sabinares de *Juniperus thurifera* L. son formaciones singulares cuya conservación y gestión activa debe ser considerada una prioridad. Tradicionalmente, los sabinares se han gestionado mediante entresaca regularizada persiguiendo estructuras de masa irregular y existen modelos selvícolas que permiten guiar la gestión de dicha masa empleando como inputs la calidad de estación y su distribución diamétrica. En el presente estudio se han empleado observaciones del inventario forestal nacional para desarrollar modelos que permiten predecir clases de calidad de estación de sabinares del Sistema Ibérico empleando datos LiDAR multitemporales. Por otro lado, los datos del inventario forestal nacional combinados con alometrias para obtener volúmenes de 'árbol, se han empleado para desarrollar y comparar modelos para predecir distribuciones diamétricas compatibles con los modelos selvícolas existentes a partir de datos LiDAR unitemporales y datos climáticos y topográficos. La estimación de clases de calidad de estación arrojó valores del índice kappa de 0.52. Los coeficientes de determinación para la predicción del volumen por clases diamétricas fueron 60.5% para la clase de 7.5 cm a 15 cm, 74.5% para la clase de 15 cm a 25 cm, 75.3% para la clase de 25 cm a 23 cm y de 41.6% para la clase de árboles mayores de 35 cm de diámetro.

Palabras clave

Sabinares, LiDAR, distribución diamétrica, índice de sitio.

1. Introducción

Endémica del suroeste de Europa y el noroeste de África, la sabina albar (*Juniperus thurifera* L.) forma bosques en España, Francia, Marruecos y Argelia. Debido a su singularidad, estos bosques están protegidos por normativas de la Unión Europea. Las altas mesetas entre los sistemas Ibérico y Central son una de las principales áreas del rango de distribución de la sabina albar. Varias amenazas ponen en peligro la conservación de estos bosques y se espera que el calentamiento global cause una drástica contracción en el rango de distribución de la especie, junto con el abandono de prácticas ganaderas asociado a procesos de despoblación del



medio rural que conduzcan al reemplazo de la sabina albar por especies como *Quercus ilex* L.

Preservar y mantener en un estado de conservación favorable los bosques de sabina albar requiere de una gestión forestal proactiva. Desde una perspectiva operativa, los gestores requieren al menos de dos tipos distintos de información para establecer tratamientos selvícolas que aseguren la estabilidad de los bosques. Primero, se necesitan modelos de referencia que definan un estado ideal u objetivo para la masa a gestionar. En segundo lugar, se necesita una evaluación precisa del estado actual del bosque. Con esta información, los gestores pueden diseñar tratamientos dirigidos basados en las diferencias entre el estado actual del bosque y su estado objetivo. En España, los bosques de sabina albar se han gestionado tradicionalmente como masas irregulares con objetivos de producción de ramón y madera para construcción. Actualmente existe un modelo de referencia para la gestión de masas irregulares de sabina albar (Barrio de Miguel, 2006) que proporciona una descripción del estado ideal de una masa expresado como una distribución de diámetros a la altura del pecho para tres clases de calidad de estación. Este modelo incluye prescripciones de cortas espaciadas 20 años en el tiempo, así como distribuciones diamétricas tras las cortas. Para la aplicación efectiva de este modelo, los gestores forestales necesitan información detallada sobre la clase de calidad de estación y la distribución diamétrica de los rodales o unidades de gestión consideradas

Tradicionalmente, la calidad de estación y las distribuciones diamétricas se han estimado mediante inventarios de campo, que son costosos y requieren mucho esfuerzo y tiempo. Estos métodos hacen un uso muy limitado o nulo de la gran cantidad de información auxiliar espacialmente explícita disponible en la actualidad, y presentan limitaciones muy importantes a la hora de determinar la distribución espacial de estas variables. Estudios previos han demostrado que la integración de técnicas de aprendizaje supervisado con datos de teledetección puede mejorar la eficiencia en la estimación tanto de la calidad de estación a través del índice de sitio (IS) (Gatziolis, 2007; Penner et al., 2023) como de distribuciones diamétricas (Bollandsås and Næsset, 2007; Maltamo et al., 2007). Sin embargo, el nivel de eficiencia alcanzado por estas técnicas depende en gran medida de factores como la disponibilidad de información auxiliar y la elección de las técnicas de modelización.

El IS es el descriptor de calidad de estación más empleado en modelos de crecimiento a nivel de rodal. Para masas regulares, el IS suele definirse como una altura dominante a una edad de referencia. Diversos estudios han intentado obtener predicciones espacialmente explícitas del IS a partir de variables topográficas y climáticas (Gustafson et al., 2003; McKenney and Pedlar, 2003). Sin embargo, estos modelos carecían de la resolución espacial necesaria para informar decisiones de gestión forestal detallada. El uso de tecnologías LiDAR en inventarios forestales, ha hecho posible determinar el IS para resoluciones espaciales de 20-30 m en zonas donde la edad del arbolado es conocida (Gatziolis, 2007). Sin embargo, la edad de un rodal puede ser desconocida en áreas de regeneración natural o en áreas sin registros de gestión precisos. Además, para masas irregulares, no existe



un concepto claro de edad del rodal, ya que coexisten múltiples cohortes en un mismo lugar. Varios autores han mostrado que, al comparar las tasas de cambio en las métricas LiDAR con curvas de crecimiento, se puede determinar el IS en masas regulares aun cuando no se dispone de información sobre la edad del rodal (Guerra-Hernández et al., 2021; Penner et al., 2023). Este es un avance prometedor que plantea preguntas sobre el posible uso de datos LiDAR multitemporales para estimar el IS en masas irregulares de sabina albar.

La estimación de distribuciones diamétricas a partir de datos LiDAR usando el método “*area based approach*” (ABA) se ha estudiado con detalle en las últimas décadas. El uso de modelos de regresión multivariante para predecir percentiles de la distribución diamétrica (Bollandsås and Næsset, 2007; Gobakken and Næsset, 2012; Maltamo et al., 2007), el uso de modelos para la abundancia por clases de diámetro (Finley et al., 2014) y el uso de métodos de recuperación y predicción de parámetros para modelizar distribuciones de diámetros continuas (Arias-Rodil et al., 2018) han sido estudiados con profundidad. Otras alternativas paramétricas basadas en modelos lineales generalizados (Breidenbach et al., 2008; Rätty et al., 2021) o basadas en modelos geométricos que relacionan intercepción de retornos LiDAR con distribuciones de diámetros y alturas (Magnussen et al., 1999; Mehtätalo and Nyblom, 2012; Spriggs et al., 2015) también han mostrado ser efectivos. Finalmente, los métodos ABA basados en técnicas de imputación de k-vecinos más próximos han demostrado ser eficaces para predecir listas de árboles, esto es, tablas que imitan la estructura de un conjunto de mediciones a nivel de parcela y que permiten reconstruir distribuciones diamétricas discretas con clases de diámetro arbitrarias (Packalén and Maltamo, 2007; Mauro et al., 2019; Pukkala et al., 2024). Los métodos de detección de árboles individuales (ITD) también han recibido importante atención, y aunque son más intensivos computacionalmente, permiten predecir distribuciones de diámetros con precisión. Factores como la densidad de los retornos LiDAR o el grado de apertura de la masa tienen un impacto en los resultados de los métodos ITD, y los mejores rendimientos generalmente se obtienen con densidades de retornos superiores a 10 retornos por metro cuadrado en bosques poco densos.

Considerando la rica información auxiliar disponible en España, con cobertura nacional de datos LiDAR multitemporales, y la gran diversidad de métodos para predecir IS y distribuciones de diámetros, se hace evidente que es necesario una comparación directa de dichos métodos para seleccionar una forma eficiente cómo predecir estas variables que proporcionan información relevante para la gestión de masas de sabina albar.

2. Objetivos

El primer objetivo de este estudio fue el desarrollo, evaluación cuantitativa y comparación de modelos alternativos para predecir clases de IS y distribuciones diamétricas a partir de una combinación de datos LiDAR multitemporales, series temporales Landsat, predictores topográficos, geográficos y climáticos en las provincias de Segovia y Soria. Como objetivo secundario, para facilitar el uso del modelo selvícola de sabina albar, los mejores modelos para clases de IS y distribuciones de diámetros se utilizaron para generar predicciones espacialmente



explícitas de estas variables. Estas predicciones se compararon con las referencias del modelo selvícola de Barrio de Miguel (2006) para evaluar cuantitativamente el estado actual de los sabinares en relación con su estado objetivo.

3. Metodología

El área de estudio está constituida por el conjunto de polígonos del mapa forestal de España (MFE) de las provincias de Soria y Segovia donde la sabina albar tiene al menos un 80% de ocupación. En total, 1268 teselas que representan aproximadamente 44400 hectáreas lo que implica un tamaño medio de 35 hectáreas. La elevación varía entre 920 y 1340 m sobre el nivel del mar, los suelos son predominantemente básicos y poco desarrollados y el clima es continental, caracterizado por veranos calurosos e inviernos fríos y con una precipitación media anual de que varía entre los 395 mm y los 876 mm.

Observaciones de campo

Se seleccionaron las parcelas del inventario forestal nacional (IFN) incluidas en los polígonos seleccionados del MFE. En total, se contó con 128 parcelas con coordenadas GPS submétricas, de las cuales 115 tenían mediciones en el tercer y cuarto ciclo del IFN. Aquellas parcelas donde se observaron pérdidas de área basimétrica de sabina o donde los equipos de campo del IFN indicaron indicios de cortas se clasificaron como parcelas perturbadas. Para las parcelas no perturbadas se calculó la clase de calidad de estación (baja, media, alta) empleando el modelo de Barrio de Miguel (2006) que asigna el IS a partir del incremento anual en área basimétrica. Dada la escasa presencia de la clase de calidad Media en el territorio, se unió está con la clase de calidad Alta y en todos los análisis posteriores se consideraron las clases de calidad; Baja y Media-Alta.

Para todas las parcelas, se calculó la distribución diamétrica a partir de las mediciones del cuarto ciclo del IFN. Las distribuciones diamétricas se expresaron en términos de volumen por clases diamétricas. Los volúmenes se obtuvieron de la base de datos del IFN y las clases de diámetro empleadas fueron las cuatro clases de tamaño (Clase 1: de 5 a 15 cm, Clase 2: de 15 a 25 cm, Clase 3: de 25 a 35 cm y Clase 4: mayor que 35 cm) consideradas en el modelo de Barrio de Miguel (2006)

Tabla 1. Síntesis de las parcelas empleadas para modelizar IS y distribuciones diamétricas. “Todas las parcelas” representa todas las parcelas del 4º ciclo del IFN empleadas en el estudio. Remedidas indica las parcelas con mediciones para el IFN3 e IFN4

		n			
Todas las parcelas	117				
Remedidas	105	Calidad de estación (clase de IS)			
	Con perturbaciones	28	Baja	Media	Alta
	Sin perturbaciones.	77	49	8	20

Información auxiliar

Para generar predicciones de IS y distribuciones diamétricas, se construyó una base de datos de información auxiliar que incluyó datos LiDAR de la primera y segunda cobertura del plan nacional de ortofotografía (PNOA), datos de series temporales de imágenes satelitales landsat, variables topográficas y climáticas. Estas variables se agruparon en proxies de cambio y proxies de estado. Todas las variables se obtuvieron con una resolución de 30 m.

Predictores LiDAR ABA

Los datos LiDAR de la primera y segunda cobertura del PNOA, PNOA1 y PNOA2 de aquí en adelante, fueron normalizados empleando la clasificación del suelo proporcionada por el PNOA empleando el paquete lidR (Roussel et al., 2020) de R. Una vez normalizados, se calcularon las métricas LiDAR descritas en Hudak et al., (2020). Como proxies de cambio, se calculó la tasa de cambio para cada una de estas métricas como la diferencia entre el PNOA2 y el PNOA1 dividida por el número de años transcurrido entre ambos vuelos.

Predictores landsat ABA

Se obtuvieron mosaicos anuales libres de nubes para la zona de estudio durante el periodo 1984-2022 considerando imágenes del periodo junio-septiembre. Para cada imagen se calculó el valor del índice de vegetación de diferencia normalizada (NDVI). Las series temporales de NDVI se segmentaron empleando el algoritmo LandTrendr (Kennedy et al., 2018, 2010) en la plataforma Google Earth Engine (Gorelick et al., 2017). Una vez segmentada la serie de NDVI, los puntos de corte de la serie segmentada se emplearon para suavizar los mosaicos anuales y calcular las variables auxiliares indicadas en la tabla 2 para cada año de la serie. Finalmente, se extrajeron los valores de dichas variables para el año de medición del IFN3 e IFN4 y se calculó la tasa de cambio de estas variables dividiendo las diferencias entre las fechas del IFN4 e IFN3 por el tiempo transcurrido entre inventarios.

Predictores topográficos, geográficos y climáticos ABA

Las nubes de puntos del PNOA2 se emplearon para obtener modelos digitales del terreno que se emplearon para calcular índices topográficos generales como la elevación, orientación, pendiente, así como métricas relacionadas con la



variabilidad y rugosidad del terreno. Además, se emplearon la latitud y longitud como predictores adicionales. Finalmente, se obtuvieron 19 índices bioclimáticos proporcionados por WorldClim2 (Fick and Hijmans, 2017). Estos índices tienen una resolución base de 30 arcos de segundo y fueron remuestreados a 30 m mediante interpolación bilineal.

Cálculo de predictores ABA para parcelas

Para cada parcela del IFN se obtuvieron las variables auxiliares anteriormente descritas. Las variables LiDAR se obtuvieron recortando las nubes de puntos del PNOA1 y PNOA2 para un área circular de 16.93 m de radio de forma que la superficie de cómputo de métricas LiDAR, 900 m², concordase con la resolución de la base de datos de información auxiliar. Las variables auxiliares landsat, topográficas, geográficas y climáticas se obtuvieron intersecando los centros de las parcelas con las capas ráster de la base de datos de información auxiliar.

Identificación de árboles individuales

Además de las variables auxiliares calculadas con una resolución espacial de 30 m, para cada parcela se obtuvo un modelo digital de altura de la vegetación, MDAV, para un área circular de 100 m en torno al centro de la parcela empleando el método de Khosravipour et al., (2014). Este MDAV se empleó como input para el método de detección de árboles individuales de Popescu and Wynne, (2004), y el radio de 100 m se seleccionó para evitar efectos de borde. Posteriormente se seleccionaron todos los ápices detectados que estaban incluidos en un radio de 16.93m en torno al centro de la parcela. Finalmente, se obtuvo un histograma de las alturas de los ápices detectados empleando clases de altura de 1 m de ancho.

Modelos predictivos:

Se consideraron tres variables respuesta en los modelos predictivos. La primera respuesta modelizada fue la presencia/ausencia de perturbaciones ya que antes de estimar el índice de sitio es necesario separar áreas que han sufrido algún tipo de perturbación o corta y donde los cambios en la información auxiliar no se corresponden con factores relacionados con la calidad de estación. La segunda respuesta fue la clase de calidad de estación de acuerdo con el modelo selvícola de Barrio de Miguel (2006). Por último, la tercera respuesta considerada fue la distribución diamétrica considerando las cuatro clases del modelo selvícola.

Modelos de perturbaciones

Las parcelas con mediciones para el IFN3 e IFN 4 se emplearon para ajustar modelos de clasificación donde la variable respuesta fue la presencia o ausencia de perturbaciones. Las variables auxiliares empleadas fueron las variables ABA de estado y de cambios para LiDAR y Landsat y las variables ABA topográficas y climáticas. El primer tipo de modelo ajustado fue un modelo de tipo random forest donde las variables independientes fueron seleccionadas empleando el algoritmo VSURF. El segundo tipo de modelo fue un modelo lineal generalizado de tipo logístico. Las variables independientes iniciales fueron las seleccionadas para el



modelo de random forest pero se hizo una eliminación de variables no significativas basado en stepwise. Los modelos se compararon según su precisión global (PG) para seleccionar el mejor modelo.

Modelos de Índice de sitio

El modelo de índice de sitio se desarrolló empleando las parcelas con mediciones para IFN3 e IFN4, pero usando solo aquellas parcelas que no hubiesen sufrido perturbaciones en dicho periodo. La respuesta fue la clase de calidad de estación (Clase Baja y Clase Media-Alta). Las variables auxiliares fueron las mismas que se consideraron para los modelos de perturbaciones. Se desarrollaron dos modelos de clasificación similares a los modelos de perturbaciones. Además, se desarrollaron dos modelos adicionales de regresión considerando como variable respuesta el incremento anual de área basimétrica. Las predicciones de estos modelos de regresión se convirtieron en categorías de IS empleando las ecuaciones proporcionadas por el modelo selvícola. Los cuatro modelos se compararon usando PG como criterio para seleccionar el mejor modelo.

Modelos de distribuciones diamétricas

El modelo para predecir distribuciones diamétricas se desarrolló empleando todas las parcelas disponibles para el IFN4 ya que es una respuesta que describe la situación actual de una parcela. En total se tienen cuatro variables respuesta, una por clase diamétrica. Las variables auxiliares fueron las variables ABA de estado para LiDAR y Landsat y las variables ABA topográficas, geográficas y climáticas. Se desarrollaron y compararon ocho modelos agrupados en 4 tipologías. Los tipos de modelos fueron: 1) modelos de regresión lineal, 2) modelos de regresión tipo random forest, 3) modelos de imputación k-NN y 4) red neuronal (NN por sus siglas en inglés) que calibra el resultado de un método de detección de árboles y lo transforma en una distribución de diámetros. En este último tipo las variables auxiliares son el histograma de alturas obtenido aplicando el método ITD más las variables ABA usadas para el resto de los modelos. Dentro de cada tipología se consideraron modelos separados para cada clase diamétrica (modelos univariantes) y modelos donde las cuatro clases diamétricas se predecían de forma conjunta (modelos multivariantes). La selección de variables para los modelos lineales y de tipo random forest fue similar a la empleada para las perturbaciones e índice de sitio. Para los modelos de imputación se empleó el método de selección de variables descrito en (Mauro et al. 2019). Los modelos se compararon empleando la distancia de Mahalanobis media (DMM) entre predicciones y observaciones de las cuatro clases diamétricas. El modelo que resultó en un menor valor de este indicador fue seleccionado para hacer predicciones espaciales.

Comparación de distribuciones diamétricas con el modelo selvícola de referencia

Una vez seleccionados los mejores modelos para la predicción de perturbaciones, IS y distribución diamétrica, éstos se aplicaron a los polígonos del mapa forestal que define el área de estudio. Los polígonos donde más del 40% de la superficie fue clasificada como sujeta a perturbaciones se eliminaron del análisis. En el resto de los polígonos se obtuvo la diferencia entre las distribuciones diamétricas predichas



y los valores de referencia aportados por el modelo selvícola de referencia para la clase de calidad predicha por el modelo de índice de sitio. Los valores de referencia para la clase de calidad Media-Alta fueron la media de ambas calidades. Finalmente se crearon dos indicadores, I1 definido como la suma de diferencias respecto al modelo selvícola para la primera y segunda clase diamétrica e I2, idéntico, pero para las clases tres y cuatro. Estos índices se calcularon para parcelas y polígonos del mapa forestal que posteriormente fueron representados en el plano I1xI2 para analizar patrones globales de divergencias con respecto al modelo selvícola de referencia.

4. Resultados

Modelos de perturbaciones

El modelo lineal generalizado logístico, con una PG de 0.80, superó al modelo de random forest, cuya PG fue de 0.73. El algoritmo VSURF seleccionó predictores que incluyen una métrica de cambio de LiDAR, un índice topográfico y una métrica climática, pero no seleccionó ninguna métrica de estado LiDAR, métrica espectral ni métrica de cambio espectral. El modelo logístico retuvo una métrica de cambio en los predictores de LiDAR, el cambio en el número de estratos de 1m de altura con primeros retornos LiDAR, junto con un índice topográfico, la pendiente, y una métrica climática, la estacionalidad de la precipitación (Tabla 2).

Tabla 2. Coeficientes del modelo logístico para predicción de presencia de perturbaciones.

	Estimate	std error	p-value	AIC
Ordenada en el origen	9.53	3.49	<0.01	
Pendiente (%)	-0.04	0.02	0.06	
Estacionalidad de precipitación	-0.33	0.12	<0.01	121.1
Numero de estratos de 1m de altura con primeros retornos LiDAR	-7.52	3.04	0.01	

Modelos de índice de calidad

El modelo de regresión lineal para el incremento en área basimétrica y el modelo de clasificación tipo random forest tuvieron la mayor precisión global 0.75, seguidos por el modelo logístico de clasificación y el modelo tipo random forest de regresión para el incremento en área basimétrica. Dada su simplicidad se seleccionó el modelo de regresión lineal para el incremento anual en área basimétrica con objeto de realizar predicciones de índice de sitio, transformando las predicciones de incremento en área basimétrica en clases de calidad empleando las ecuaciones del modelo selvícola de referencia. Este modelo incluyeo

predictores LiDAR de estado y cambio (Tabla 3)

Tabla 3. Coeficientes del modelo lineal para el incremento anual en área basimétrica.

	Estimación	Error estándar	p-value	Varianza residual
Ordenada en el origen	-0.75	0.19	<0.01	
Proporción de primeros retornos entre 1 y 2 m	0.02	0.01	<0.01	
Percentil 25 de la elevación de retornos LiDAR	0.16	0.03	<0.01	
Proporción de primeros retornos entre 1 y 2 m	-0.13	0.04	<0.01	0.1
Percentil 90 de la elevación de retornos LiDAR	-0.59	0.20	<0.01	
Precipitación del cuatrimestre más húmedo	0.00	0.00	0.02	

Modelos de distribución diamétrica

La mejor estrategia de modelado para la distribución de diámetros fue el conjunto de modelos de imputación univariantes que obtuvieron los valores más bajos de DMM. Además, esta estrategia de modelado mostró los mayores coeficientes de determinación para todas las clases de diámetro (Tabla 4). En términos de DMM, la siguiente estrategia fue el modelo de imputación multivariante, seguido por el conjunto de redes neuronales para la calibración de un ITD. Para todas las estrategias de modelado, se obtuvieron peores resultados para la primera clase de diámetro y, excluyendo el modelo de tipo random forest multivariante, los coeficientes de determinación aumentaron de la primera a la tercera clase de diámetro (Figura 1).

Tabla 4. Valor de la distancia media de Mahalanobis (DMM) entre distribuciones diamétricas observadas y predichas para los ocho tipos de modelos testeados.



Tipo de model	Respuesta	DMM	Orden preferencia
Random forest	Univariate	0.82	6
	Multivariate	0.89	8
Lineal	Multivariate	0.82	4
	Univariate	0.82	5
Imputación k-nn	Univariate	0.49	1
	Multivariate	0.77	2
ITD + red neuronal	Univariate	0.80	3
	Multivariate	0.83	7

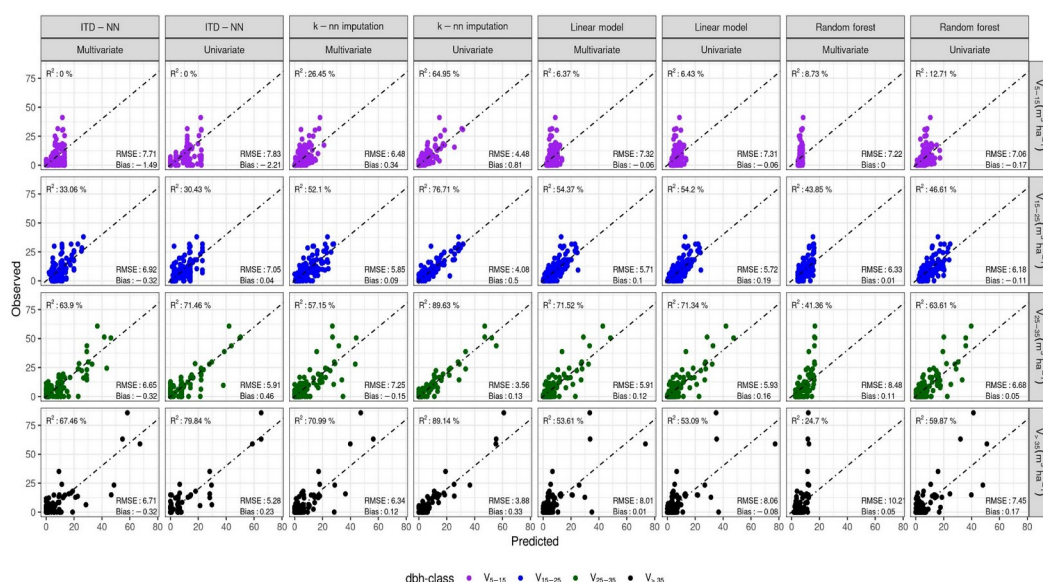


Figura 1. Diagramas de observación predicción para los ocho tipos de modelos de predicción por clases diamétricas. ITD-NN: método de calibración de un resultado de ITD usando una red neuronal. kNN: Imputación usando los k vecinos más próximos.

Comparación de distribuciones diamétricas con el modelo de selvícola de referencia

Los modelos seleccionados para las perturbaciones, las clases de IS y distribuciones diamétricas se aplicaron a toda el área de estudio. Se hizo una inspección visual de los mapas de perturbaciones, clases de índice de sitio y distribuciones de diámetros y no se observaron artefactos relacionados con las diferentes densidades de retorno de las adquisiciones LiDAR del PNOA1 y PNOA2 utilizadas en el estudio. Posteriormente se calcularon las diferencias entre distribuciones diamétricas predichas por el modelo y las recomendadas por el modelo selvícola de la especie. Una vez eliminados los polígonos del mapa forestal con más del 40% de su área clasificada como perturbada se procedió a representar

el resto de los polígonos en el espacio $I_1 \times I_2$. A partir de esta representación, fue posible observar que el conjunto de modelos k-NN no tuvo sesgo para las diferencias respecto al modelo de referencia para las dos primeras clases, pero tendió a sobreestimar la proporción de áreas con un déficit de árboles en la tercera y cuarta clases de diámetro. La proporción del área con déficit de árboles jóvenes, $I_1 < 0$, estimada por el modelo es del 20.39%, un 8.5% menos que la estimación de IFN, que es del 28.92%, y se encuentra dentro del intervalo de confianza (IC) de la estimación del IFN (IC 18.53%, 34.45%). El modelo predijo que el 95.60% tiene un déficit de árboles maduros, $I_2 < 0$, fuera del IC de la estimación del IFN 78.31% (IC: 69.27%, 87.36%), lo que indica que las predicciones del modelo introducen un sesgo en la estimación de I_2 .

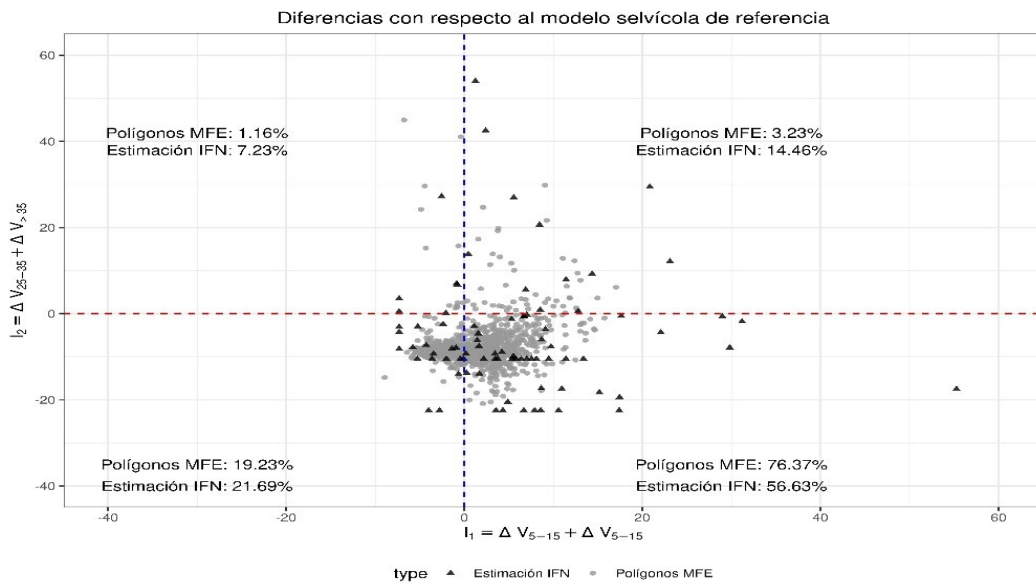


Figura 2. Representación de las parcelas del Inventario Forestal Nacional de España (IFN, en negro) y los polígonos del Mapa Forestal de España (MFE, en gris), dominados por sabina albar, en el espacio $I_1 \times I_2$. I_1 : Suma de las diferencias entre el volumen real y el volumen predicho en las terceras y cuartas clases de diámetro, y el volumen de referencia para estas clases según el modelo silvicultural de Barrio de Miguel (2006). I_2 : Suma de las diferencias entre el volumen real y el volumen predicho en las primeras y segundas clases de diámetro, y el volumen de referencia para estas clases según el modelo silvicultural de Barrio de Miguel (2006).

5. Discusión

5.1 Modelos para perturbaciones e IS

De acuerdo con los hallazgos de Moan et al. (2024), el modelo paramétrico superó al modelo de random forest para detectar perturbaciones siendo fácilmente interpretable. Los coeficientes negativos observados para el número de estratos de 1 m de altura con primeros retornos LiDAR y para la pendiente del terreno indican que las áreas perturbadas presentan estructuras verticales simplificadas y se localizan en áreas con pendientes suaves, concordando con la práctica común de gestión que evita operaciones en terrenos escarpados. En términos de PG, nuestro modelo fue menos preciso que los de Moan et al. (2024) y Noordermeer et al. (2020) pudiéndose atribuir el resultado a dos factores principales. Primero, la inexistencia



de vuelos LiDAR anteriores a 2010 no posibilita la captura LiDAR de perturbaciones previas a dicha fecha. Además, los sabinares presentan estructuras dispersas e irregulares, lo que dificulta la detección de perturbaciones de menor magnitud, como aclareos de baja intensidad.

El mejor modelo para predecir las clases de IS se basó principalmente en los cambios en las métricas LiDAR, lo que confirma que los datos LiDAR multitemporales son de interés para evaluar la productividad de las masas forestales a diversas escalas (Guerra-Hernández et al., 2021; Penner et al., 2023; Riofrío et al., 2023). Una innovación notable de nuestro estudio es su enfoque en una especie que típicamente forma estructuras de edades desiguales, donde coexisten árboles de diferentes cohortes de edad. A diferencia de las definiciones tradicionales de índice de sitio que se basan en la altura dominante, la métrica IS utilizada en el presente estudio se basa en el incremento en área basimétrica y es similar a las medidas recientemente propuestas para rodales irregulares y mixtos (Dănescu et al., 2017). Nuestros hallazgos demuestran que los datos LiDAR multitemporales también pueden predecir el IS en masas irregulares.

5.2 Modelos para distribuciones de diámetros

El enfoque más efectivo para predecir las distribuciones de diámetros fue el conjunto de modelos de imputación kNN separados por clase de diámetro, lo que concuerda con investigaciones anteriores que destacan la idoneidad de los métodos basados en imputación para la predicción de la distribución de diámetros (Räty et al., 2021). Los avances recientes de Paramasivam et al. (2023); Sani et al. (2017) proponen métodos de imputación kNN basados en redes neuronales. Dado el éxito reciente de estos métodos resolviendo problemas complejos, es razonable pensar que métodos kNN basados en redes neuronales puedan mejorar las predicciones de distribuciones diamétricas a partir de datos de teledetección. Estos métodos basados en redes neuronales ofrecen la ventaja de calcular distancias entre instancias de predicción y entrenamiento, lo cual es de interés cuando las imputaciones kNN se utilizan para reconstruir listas de árboles (Packalén y Maltamo, 2007) que se usen como inputs en simuladores de crecimiento y dinámica de las masas forestales como Medfate (De Cáceres et al., 2022) o SIMANFOR (Bravo et al., 2012).

El usar una red neuronal para calibrar una salida de un método ITD representa un nuevo y prometedor método para modelizar distribuciones de diámetros, combinando las fortalezas de las metodologías ABA e ITD. Los métodos ITD tradicionales incluyen, en primer lugar, la detección de árboles de forma no supervisada y, posteriormente, se realizan los cálculos alométricos para predecir diámetros y/o volúmenes en función de las alturas de las copas detectadas. Vauhkonen et al. (2014) mostraron varias limitaciones de este enfoque: las incertidumbres en las mediciones de altura de las copas pueden propagarse a través de los cálculos alométricos, y las omisiones de árboles del sotobosque a menudo reducen la precisión, especialmente para las clases de diámetro más pequeñas. Además, los métodos ITD suelen infrautilizar los datos de campo, incorporándolos principalmente en la fase de validación en lugar de durante el ajuste del modelo. Nuestro enfoque de calibración ITD usando una red neuronal incorpora información de campo en la fase de ajuste del modelo y evita la



necesidad de alometrías a nivel de árbol individual ya que la red aprende a traducir un histograma de alturas de copas en una distribución de diámetros utilizando los datos de entrenamiento.

5.3 Desviaciones del estado de referencia

La visualización de las parcelas IFN en el plano I1 x I2 muestra que más de tres cuartas partes de las áreas dominadas por sabina albar tienen un déficit de árboles en las terceras y cuartas clases de diámetro en relación el modelo selvícola de Barrio de Miguel (2006) y una proporción similar tiene un exceso de volumen en las primeras y segundas clases de diámetro. Estos resultados plantean serias preocupaciones para la gestión resiliente y sostenible de los bosques de sabina. Los modelos desarrollados en este estudio, junto con los índices I1 e I2, facilitan la identificación rápida de polígonos IFN específicos donde las intervenciones de manejo son más urgentes. Si bien estos modelos tienen incertidumbres inherentes, ofrecen una aproximación práctica y eficiente para priorizar las acciones de manejo a escala de paisaje.

6. Conclusiones

La principal conclusión de este trabajo es que la combinación de las bases de datos de información de teledetección disponibles para el territorio y de las mediciones de campo sobre parcelas permanentes del IFN permite desarrollar modelos de predicción que permiten generar inputs completos para la aplicación de modelos selvícolas de masas irregulares de sabina albar.

7. Agradecimientos

Los autores agradecen la financiación recibida por parte del Ministerio de Ciencia e Innovación para el desarrollo del proyecto TLM-PROJECT (PID2022-140104OA-I00). Francisco Mauro recibió una ayuda María Zambrano financiada por la Universidad de Valladolid. David Candel-Pérez recibió una ayuda postdoctoral (CONTPO-2021-105) financiada por la Universidad de Valladolid. Manuel Gomez-Roux disfruta de una ayuda predoctoral FPI (CONTFPI-2023-91) asociada al proyecto TLM-PROJECT.

8. Bibliografía

- Arias-Rodil, M., Diéguez-Aranda, U., Álvarez-González, J.G., Pérez-Cruzado, C., Castedo-Dorado, F., González-Ferreiro, E., 2018. Modeling diameter distributions in radiata pine plantations in Spain with existing countrywide LiDAR data. *AnnLiDAR of Forest Science* 75, 36. <https://doi.org/10.1007/s13595-018-0712-z>
- Barrio de Miguel, J.M., 2006. Propuesta de modelo de selvicultura de masas irregulares de sabina albar (*Juniperus Thurifera* L.). Presented at the III Coloquio Internacional sobre sabinas y enebrales (género *Juniperus*): Ecología y gestión forestal sostenible., Valladolid (Spain).
- Bollandsås, O.M., Næsset, E., 2007. Estimating percentile-based diameter distributions in uneven-sized Norway spruce stands using airborne laser scanner data. *Scandinavian Journal of Forest Research* 22, 33–47. <https://doi.org/10.1080/02827580601138264>
- Breidenbach, J., Gläser, C., Schmidt, M., 2008. Estimation of diameter distributions by means of airborne laser scanner data. *Canadian Journal of Forest Research* 38, 1611–1620.
- Fick, S.E., Hijmans, R.J., 2017. WorldClim 2: new 1-km spatial resolution climate



- surfaces for global land areas. *International journal of climatology* 37, 4302–4315.
- Finley, A.O., Banerjee, S., Weiskittel, A.R., Babcock, C., Cook, B.D., 2014. Dynamic spatial regression models for space-varying forest stand tables. *Environmetrics* 25, 596–609. <https://doi.org/10.1002/env.2322>
- Gatziolis, D., 2007. LiDAR-derived site index in the US pacific northwest—challenges and opportunities. *Proc. SilviLaser* 136.
- Gobakken, T., Næsset, E., 2012. Estimation of diameter and basal area distributions in coniferous forest by means of airborne laser scanner data. *Scandinavian Journal of Forest Research* 19, 529–542. <https://doi.org/10.1080/02827580410019454>; M3: doi: 10.1080/02827580410019454; 07
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., Moore, R., 2017. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*. <https://doi.org/10.1016/j.rse.2017.06.031>
- Guerra-Hernández, J., Arellano-Pérez, S., González-Ferreiro, E., Pascual, A., Sandoval Altelarrea, V., Ruiz-González, A.D., Álvarez-González, J.G., 2021. Developing a site index model for *P. Pinaster* stands in NW Spain by combining bi-temporal LiDAR data and environmental data. *Forest Ecology and Management* 481, 118690. <https://doi.org/10.1016/j.foreco.2020.118690>
- Gustafson, E.J., Lietz, S.M., Wright, J.L., 2003. Predicting the Spatial Distribution of Aspen Growth Potential in the Upper Great Lakes Region. *Forest Science* 49, 499–508. <https://doi.org/10.1093/forestscience/49.4.499>
- Hudak, A.T., Fekety, P.A., Kane, V.R., Kennedy, R.E., Filippelli, S.K., Falkowski, M.J., Tinkham, W.T., Smith, A.M.S., Crookston, N.L., Domke, G.M., Corrao, M.V., Bright, B.C., Churchill, D.J., Gould, P.J., McGaughey, R.J., Kane, J.T., Dong, J., 2020. A carbon monitoring system for mapping regional, annual aboveground biomass across the northwestern USA. *Environmental Research Letters* 15, 095003. <https://doi.org/10.1088/1748-9326/ab93f9>
- Hudak, A.T., Haren, A.T., Crookston, N.L., Liebermann, R.J., Ohmann, J.L., 2014. Imputing Forest Structure Attributes from Stand Inventory and Remotely Sensed Data in Western Oregon, USA. *Forest Science* 60, 253–269. <https://doi.org/10.5849/forsci.12-101>
- Kennedy, R.E., Yang, Z., Cohen, W.B., 2010. Detecting trends in forest disturbance and recovery using yearly Landsat time series: 1. LandTrendr — Temporal segmentation algorithms. *Remote Sensing of Environment* 114, 2897–2910. <https://doi.org/10.1016/j.rse.2010.07.008>
- Kennedy, R.E., Yang, Z., Gorelick, N., Braaten, J., Cavalcante, L., Cohen, W.B., Healey, S., 2018. Implementation of the LandTrendr Algorithm on Google Earth Engine. *Remote Sensing* 10. <https://doi.org/10.3390/rs10050691>
- Khosravipour, A., Skidmore, A.K., Isenburg, M., Wang, T., Hussin, Y.A., 2014. Generating Pit-free Canopy Height Models from Airborne Lidar. *Photogrammetric Engineering & Remote Sensing* 80, 863–872. <https://doi.org/doi:10.14358/PERS.80.9.863>
- Magnussen, S., Eggermont, P., LaRiccia, V.N., 1999. Recovering Tree Heights from Airborne Laser Scanner Data. *Forest Science* 45, 407–422(16).
- Maltamo, M., Suvanto, A., Packalén, P., 2007. Comparison of basal area and stem frequency diameter distribution modelling using airborne laser scanner data and calibration estimation. *Forest Ecology and Management* 247, 26–34.
- Mauro, F., Frank, B., Monleon, V.J., Temesgen, H., Ford, K.R., 2019. Prediction of diameter distributions and tree-lists in southwestern Oregon using LiDAR and stand-level auxiliary information. *Canadian Journal of Forest Research* 49, 775–787.



- McKenney, D.W., Pedlar, J.H., 2003. Spatial models of site index based on climate and soil properties for two boreal tree species in Ontario, Canada. *Forest Ecology and Management* 175, 497–507. [https://doi.org/10.1016/S0378-1127\(02\)00186-X](https://doi.org/10.1016/S0378-1127(02)00186-X)
- Mehtätalo, L., Nyblom, J., 2012. A Model-Based Approach for Airborne Laser Scanning Inventory: Application for Square Grid Spatial Pattern. *Forest Science* 58, 106–118.
- Packalén, P., Maltamo, M., 2007. The k-MSN method for the prediction of species-specific stand attributes using airborne laser scanning and aerial photographs. *Remote Sensing of Environment* 109, 328–341.
- Penner, M., Woods, M., Bilyk, A., 2023. Assessing Site Productivity via Remote Sensing—Age-Independent Site Index Estimation in Even-Aged Forests. *Forests* 14. <https://doi.org/10.3390/f14081541>
- Popescu, S.C., Wynne, R.H., 2004. Seeing the Trees in the Forest. *Photogrammetric Engineering & Remote Sensing* 70, 589–604.
- Pukkala, T., Aquilué, N., Just, A., Corbera, J., Trasobares, A., 2024. Developing kNN forest data imputation for Catalonia. *Journal of Forestry Research* 35, 80. <https://doi.org/10.1007/s11676-024-01735-5>
- Räty, J., Astrup, R., Breidenbach, J., 2021. Prediction and model-assisted estimation of diameter distributions using Norwegian national forest inventory and airborne laser scanning data. *Can. J. For. Res.* 51, 1521–1533. <https://doi.org/10.1139/cjfr-2020-0440>
- Roussel, J.-R., Coops, N.C., TompLiDARki, P., Goodbody, T.R.H., Meador, A.S., Bourdon, J.-F., Boissieu, F. de, Achim, A., 2020. lidR: An R package for analysis of Airborne Laser Scanning (LiDAR) data. *Remote Sensing of Environment* 251, 112061. <https://doi.org/10.1016/j.rse.2020.112061>
- Spriggs, R.A., Vanderwel, M.C., Jones, T.A., Caspersen, J.P., Coomes, D.A., 2015. A simple area-based model for predicting airborne LiDAR first returns from stem diameter distributions: an example study in an uneven-aged, mixed temperate forest. *Can. J. For. Res.* 45, 1338–1350. <https://doi.org/10.1139/cjfr-2015-0018>