



2025 | **16-20**
GIJÓN | JUNIO

9º CONGRESO **FORESTAL** ESPAÑOL

9CFE-1280

Organiza





Cartografía de productividad y prioridad de gestión forestal basadas en teledetección: el caso de los pinares de *Pinus halepensis* Mill. de Ibiza.

RIBAS COSTA, V. A. (1, 2, 3), GASTÓN GONZÁLEZ, A. (1), TRLICA, A. (2), COOK, R. (2)

(1) Centro para la Conservación de la Biodiversidad y el Desarrollo Sostenible (CBDS), ETSI Montes, Forestal y del Medio Natural, Universidad Politécnica de Madrid, Calle José Antonio Novais 10, 28040 Madrid, Spain

(2) Department of Forestry and Environmental Resources, NC State University, Raleigh, NC 27695, USA

(3) Terrapi World S.L., Carrer Formentera 1, apt. 301, 07800 Eivissa, Illes Balears, Spain

Resumen

Cuantificar y cartografiar la productividad de los ecosistemas forestales es necesario para gestionarlos. Sin embargo, estas estimaciones son complejas, costosas y a menudo restringidas a observaciones puntuales, faltando casi siempre mapas continuos. En este contexto, y seleccionando como área de interés espacial la isla de Ibiza, se desarrolla y presenta una metodología funcional basada en datos públicos tele-detectados (el segundo vuelo LiDAR y una serie de ortofotografías históricas y modernas del Plan Nacional de Ortofotografía Aérea) y validados con datos de campo para (1) desarrollar modelos de altura dominante y volumen maderable aplicables a los pinares de pino carrasco Ibiza, (2) estudiar la evolución forestal en los pasados 70 años con el fin de establecer clases de edad de los pinares actuales, y (3) combinar (1) y (2) generando mapas continuos de productividad forestal tanto en forma de calidad de estación (altura dominante a la edad de referencia) como en crecimiento medio. Y finalmente, (4) se integra la productividad forestal con otros factores mediante un proceso de decisión multicriterio para obtener mapas de prioridad de gestión forestal para los pinares de *Pinus halepensis* Mill. de Ibiza.

Palabras clave

LiDAR, ortofotografía aérea histórica, altura dominante, volumen maderable, calidad de estación, prioridad de gestión.

1. Introducción

La prioridad de gestión forestal (PGF) puede definirse como la manera óptima de utilizar unos recursos limitados para realizar ciertas operaciones forestales y conseguir un conjunto de objetivos preestablecidos, normalmente para encontrar aquella alternativa que maximiza más factores decisores (ARANDA & HERATH, 2009). Históricamente, la principal motivación relacionada con la gestión forestal fue la recuperación y mantenimiento de la cubierta forestal con un mínimo de productividad garantizada y sostenida en el tiempo (XIMÉNEZ DE EMBÚN I OSEÑALDE & CEBALLOS, 1939; PEMÁN et al., 2017). Hoy en día, esa PGF entendida desde el punto de vista productor ha ido evolucionando hacia las necesidades económicas, ambientales y sociales (WINKEL & JUMP, 2014; BORRASS et al., 2017), incluyendo aspectos como el aumento de los sumideros de carbono, la conservación de la biodiversidad e incluso aspectos recreativos. Todo ello ha dado lugar al concepto de bosque multifuncional hoy en día utilizado (VADELL et al., 2022).



Sin embargo, el conocimiento de la productividad de las masas arboladas sigue siendo un aspecto clave en la planificación forestal, tanto en ecosistemas forestales muy gestionados (DIÉGUEZ-ARANDA et al., 2006; GUERRA-HERNÁNDEZ et al., RIBAS-COSTA et al., 2024b) como en otras zonas con una gestión menos intensiva (BRAVO-OVIEDO & MONTERO, 2005; KAHRIMAN et al., 2018; KHERCHOUCHE et al., 2021), puesto que permite una toma de decisiones más informada. Normalmente, esta productividad forestal se mide en términos de calidad de estación, es decir, altura dominante a una edad de referencia (SHARMA et al., 2002). Gracias a las nuevas tecnologías basadas en teledetección, y específicamente las que usan LiDAR, existen dos maneras de obtener estimaciones continuas de esta variable en grandes áreas (SOLBERG et al., 2019): varias adquisiciones de datos LiDAR separadas un intervalo de tiempo conocido (NOORDERMEER et al., 2020; GUERRA-HERNÁNDEZ et al., 2021) o una adquisición única de datos LiDAR conociendo la edad de la masa forestal (TOMPALSKI et al., 2015; RIBAS-COSTA et al., 2024b). Mientras que la primera metodología, independiente de la edad, permite estimar la productividad al comparar el cambio en altura de copas, la segunda metodología estima directamente la productividad comparando la altura obtenida del LiDAR a la edad correspondiente. Esta tecnología LiDAR permite obtener, estimaciones de altura dominante para cada punto del territorio. Esto es posible gracias a la fuerte relación existente entre la altura dominante, normalmente definida en Europa como la altura media de los 100 pies más gruesos por hectárea (adaptación del criterio de ASSMAN, 1970), con la altura sobre el suelo de los retornos más altos de la nube de puntos LiDAR (GOPALAKRISHNAN et al., 2019; GUERRA-HERNÁNDEZ et al., 2021; RIBAS-COSTA et al., 2024a; RIBAS-COSTA et al., 2024b).

En cualquier caso, una vez obtenida la variable de productividad forestal, es recomendable integrarla junto a otras variables para contribuir a una toma de decisiones más informada. En el Mediterráneo, el principal factor que ha influido en la PGF ha sido la prevención y extinción de incendios forestales (ALCASENA et al., 2019; MOREIRA et al., 2020; GAMBOA et al., 2023; KRŠNIK et al., 2024). Sin embargo, la potencialidad de crecimiento de la masa arbolada debería considerarse como un factor relevante en la planificación, pues puede paliar limitaciones de la gestión forestal mediterránea como la ineficiencia económica (MERLO & ROJAS-BRIALES, 2000), las limitaciones ambientales en espacios protegidos (VALLS-DONDERIS et al., 2015; ROJAS-BRIALES et al., 2018) o el solape de intereses múltiples (PONS & RULLAN, 2014). Una cartografía que incorpore la productividad forestal a los demás criterios de gestión puede optimizar recursos para localizar con mayor precisión áreas prioritarias bajo una gestión multifuncional.

2. Objetivos

Los objetivos de este trabajo son:

1. Presentar unos modelos de altura dominante y volumen maderable para los pinares de *Pinus halepensis* Mill. de la isla de Ibiza
2. Presentar la evolución de los pinares de Ibiza desde mediados del siglo XX hasta la actualidad, con el fin de elaborar y validar una cartografía de clases de edad.
3. Mostrar la combinación de las anteriores variables (altura dominante y existencias junto con la clase de edad) para la elaboración y validación de una cartografía de calidad de estación para dichos pinares.
4. Mostrar la integración de dicha cartografía de calidad de estación en un sistema multicriterio para proponer una cartografía de prioridad de

gestión forestal.

3. Metodología

3.1. Datos de campo de inventario forestal

Entre octubre de 2021 y mayo de 2024, se establecieron un total de 156 parcelas en Ibiza, cada una con un radio fijo de 10 m. Se midieron árboles con más de 7.5 cm de diámetro normal, registrando el diámetro a la altura del pecho (DAP) y la altura total (AT). Además, se estimó la edad media por parcela mediante el barreno y conteo directo de anillos en los tres árboles más gruesos de cada parcela.



Figura 1: Localización de las parcelas de campo utilizadas en este trabajo.

Para la estimación de la altura dominante, se obtuvo como la media de los 2 pies más gruesos por parcela. Por su parte, para la estimación del volumen maderable, el volumen individual de los pies se estimó mediante las ecuaciones volumétricas del Inventario Forestal Nacional (IFN) (MAGRAMA, 2012), para luego sumar todos los volúmenes individuales y dividir el total entre la superficie de la parcela. La ecuación volumétrica del IFN (DAP en centímetros, AT en metros) produce las estimaciones en decímetros cúbicos por árbol, pero posteriormente se transformaron a metros cúbicos por hectárea para los valores totales por parcela.

$$VOL = 47,45 + 0,0000257 \cdot (DAP \cdot 10)^2 \cdot AT$$

Ecuación 1

3.2. Elaboración de modelos de altura dominante y volumen maderable

Los datos LiDAR se obtuvieron de la segunda adquisición de cobertura nacional del PNOA (2016–2019), específicamente entre noviembre y diciembre de 2019. El sensor utilizado fue un LEICA ALS80 con precisión XY de 0,3 m y Z de 0,15 m. El preprocesamiento incluyó la descarga y fusión de mosaicos, recorte, filtrado estadístico de ruido y reclasificación del suelo. Se utilizó un enfoque basado en

área, calculando una serie de estadísticos de altura (altura media, percentiles, porcentaje de retornos por encima de cierto valor, etc.) para parcelas de terreno, excluyendo retornos menores a 2 m. Una vez obtenidas las variables descriptoras, se realizó una inspección visual de los datos y se usaron regresiones lineales simples para modelar las variables objetivo con las covariables más explicativas. Para este análisis sólo se utilizaron 113 parcelas de inventario. Para la validación de los modelos, se utilizó un proceso de remuestreo o *bootstrapping* de 500 repeticiones, utilizando el paquete *rms* de R (HARRELL, 2023). Se evaluó la capacidad predictiva mediante el coeficiente de determinación (R^2), el error cuadrático medio, el error cuadrático medio relativo (RMSE y RRMSE, respectivamente, mostradas en sendas Ecuaciones 2 y 3) y el Criterio de Información de Akaike (AIC). Más información sobre esta metodología puede encontrarse en RIBAS-COSTA et al. (2024a).

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

Ecuación 2

$$RRMSE = \frac{RMSE}{\bar{y}}$$

Ecuación 3

3.3. Estudio de la evolución forestal de los pinares de *Pinus halepensis* Mill.

3.3.1. Segmentación de las ortoimágenes

Este trabajo se basa en la aplicación del Análisis de Imágenes Basado en Objetos Geográficos (GEOBIA), un enfoque muy utilizado para interpretar y analizar imágenes satelitales y aéreas (BLASCHKE, 2010). A diferencia de los métodos tradicionales basados en píxeles, GEOBIA se centra en analizar objetos o regiones completas dentro de una imagen. En el caso de este trabajo, se utilizó esta metodología para la obtención y validación de una cartografía de clases de edad para las masas de *Pinus halepensis* Mill. de Ibiza (Figura 2). Tal y como se describe en RIBAS-COSTA et al. (2024c), tres ortofotos (dos históricas y una moderna) fueron utilizadas para estudiar la evolución de los bosques de la isla de Ibiza desde mediados del siglo XX hasta el presente. Las ortoimágenes utilizadas fueron el Vuelo Americano Serie B de 1956, el Vuelo Balear de 1989 y la ortofoto de máxima actualidad del PNOA de 2021.

Siguiendo la metodología propuesta por otros estudios similares (KWON et al., 2017; ALMONACID-CABALLER et al., 2017; MAXWELL et al., 2019; TASSI & VIZZARI, 2020; LANGENKAMP & RIENOW, 2023; GROMADA, 2022;) y tras un preprocesado de las ortoimágenes que consistió aplicar una disminución de la resolución a 2,5 m y la ejecución de dos filtros (de mediana y Gaussiano), se procedió a la segmentación automática no supervisada de las ortoimágenes. La parametrización

de los algoritmos de segmentación (uno por cada ortofoto) se realizó manualmente mediante ajuste manual de los parámetros tras exploración de los resultados y la segmentación se ejecutó con el software ERDAS Imagine.



Figura2: Diagrama de flujo de los datos, métodos y resultados obtenidos para la elaboración de una cartografía de clases de edad. El color verde indica el origen de los datos, el color rosa los pasos relacionados con la supervisión, el color naranja los pasos asociados a la ortofoto interpretación para asignación de coberturas forestales, el color azul son los pasos asociados a la modelización, y el color gris indica los últimos pasos para elaborar y validar las clases de edad de la masa forestal.

3.3.2. Ortofoto interpretación de la cobertura o uso del suelo para el set de datos de entrenamiento

Tras la segmentación de cada imagen, se seleccionó un conjunto de segmentos o polígonos individuales mediante una combinación de muestreo sistemático y aleatorio. Cada segmento fue fotointerpretado visualmente y clasificado en una de las 6 categorías definidas de tipos de cobertura o uso de suelo (Tabla 1). Para la elaboración del sistema de clasificación, se utilizaron clasificaciones existentes (GONZÁLEZ-ÁVILA & ELENA-ROSSELLÓ, 2009; TADESE et al., 2020; DELGADO-ARTÉS et al., 2022; SHIMIZU et al., 2023), que fueron parcialmente adaptadas para la realidad de la isla.

Tabla1: Tipos de cobertura o uso de suelo utilizadas en este trabajo.

CLASE	CÓDIGO	DESCRIPCIÓN
Bosque denso	BD	Áreas dominadas por vegetación forestal alta, bosques densos y/o maduros.
Bosque ralo	BR	Áreas dominadas por vegetación forestal de menor talla o densidad (matorrales o árboles).
Rocallas o pastizales	RP	Áreas dominadas o bien por vegetación forestal de muy baja talla, con una fracción de cabida cubierta muy baja, dominado en general por rocas. También incluye pastizales y, si son distinguibles, bancales agrícolas abandonados, si no han sido colonizados por vegetación forestal alta todavía.
Terreno agrícola aterrazado	AGT	Bancales agrícolas o Terrazas, generalmente situadas en laderas.
Terreno agrícola no aterrazado	AGNT	Tierras agrícolas no aterrazadas. Esto incluye las grandes áreas planas utilizadas para agricultura en seco o en húmedo, o para el pastoreo de ganado.
Otros	OTR	Todas las superficies que no pertenecen a ninguna de las categorías anteriores: agua, superficies impermeables (por ejemplo, carreteras, aeropuertos), áreas urbanas desarrolladas (por ejemplo, desarrollos puros y mixtos), playas o acantilados.

Un total de 963 polígonos en 1956, 1455 polígonos en 1989 y 838 polígonos en 2021 fueron fotointerpretados. Con objeto de construir los modelos clasificadores de tipo de uso de suelo, se calcularon estadísticas zonales para cada uno de los polígonos segmentados de las siguientes variables (ver con mayor detalle en RIBAS-COSTA et al., 2024c): media y desviación de la intensidad de gris (para las imágenes de 1956 y 1989) y de las bandas RGB (para la imagen de 2021), junto con la media de tres índices espectrales para esta última (Normalizada Green-Red Difference Index, Visible Band Difference Vegetation Index, y Green Leaf Index); variables de textura de segundo orden, computadas mediante los algoritmos Gray-Level Co-occurrence Matrix (contraste, correlación, varianza e inversa de la diferencia del momento); propiedades del terreno (pendiente, orientación, elevación, índice de posición topográfica y distancia al mar); y finalmente el área de cada polígono.

Una vez clasificados mediante la clasificación de 6 niveles antes descrita, se reclasificaron a una escala de 3 niveles: forestal arbolado (BD y BR se convirtió a FOR), agricultura (AGT y AGNT se convirtió a AGRO) y otras coberturas (el resto de los niveles se categorizaron como OTROS). Finalmente, y con objeto de reducir ruido en la modelización, se digitalizaron manualmente todas las zonas urbanas de mayor continuidad para cada imagen, así como la zona de Ses Salines (único cuerpo de agua interior).

3.3.3. Modelización y validación de las coberturas de suelo

Una vez construido el set de datos de entrenamiento, se generaron tres modelos de clasificación del tipo uso o cobertura de suelo. Para ello, se utilizaron algoritmos del tipo *random forest* (BREIMAN et al., 2017), muy utilizados para este tipo de funcionalidades en estudios basados en teledetección (ZHOU et al., 2021; MAXWELL et al., 2021). Los algoritmos *random forest* se construyeron mediante el paquete *ranger* de R (WRIGHT & ZIEGLER, 2017), utilizando el paquete *tuneRanger* (PROBST et al., 2018) para parametrizar los modelos y adaptarlos al set de datos utilizado en cada ortoimagen. Debido a que dicho set de datos no tenía el mismo

número de observaciones para cada clase de cobertura o uso del suelo, se aplicó un algoritmo *random forest* equilibrado, es decir, que tuviera en cuenta dichos pesos (MORE & RANA, 2017). Los modelos fueron validados mediante un proceso de validación cruzada (*cross-validation*) con 5 particiones, proceso en el que se obtuvieron los valores del estadístico Kappa y la precisión de la predicción.

3.3.4. Cálculo y validación de clases de edad

Una vez contruidos y validados los modelos para cada ortoimagen, se utilizaron para predecir los tipos de uso o cobertura del suelo en la totalidad de la isla. Teniendo en cuenta la presencia o ausencia de cobertura forestal arbolada en cada uno de los momentos estudiados (1956, 1989 y 2021) se pudo elaborar una clase de edad discreta a cada píxel (Tabla 2).

Tabla2: Metodología para la asignación de una clase de edad a la capa de edades final en función del valor de píxel en 1956, 1989 y 2021.

AÑO DE LA ORTOFOTO / CLASE DE EDAD	TIPO DE COBERTURA FORESTAL DICOTÓMICA			
1956	FOR	no-FOR	no-FOR	FOR
1989	FOR	FOR	no-FOR	no-FOR
2021	FOR	FOR	FOR	FOR
Mínima edad (años)	75	42	10	10
Máxima edad (años)	120	74	41	41
Edad media (años)	97,5	58,0	25,5	25,5
Clase de edad de la masa forestal arbolada	A	B	C	C

Para la definición de estos intervalos se tuvieron en cuenta dos parámetros: (1) la edad máxima que se puede suponer a los pinares existentes en la isla de Ibiza, que se estableció en 120 años en base a investigaciones anteriores (DEL RÍO et al., 2008; DI FILIPPO et al., 2021) y nuestra propia exploración de los datos de campo y conocimiento del área de interés; y (2) la cantidad de tiempo necesaria para que el territorio sea colonizado efectivamente por vegetación forestal, que se estableció en 10 años en base a la exploración de las ortofotos y de la experiencia en la isla.

Tras obtener la capa final de clases de edad basadas en teledetección, obtuvimos la clase de edad teórica de cada una de las 156 parcelas de campo por asignación del valor de píxel más común dentro de ellas (en un radio de 10 metros respecto al centro), y las comparamos con la edad medida en campo. Finalmente, empleamos la prueba de Diferencia Honesta Significativa de Tukey (HSD) (alfa = 0,05) para determinar si existían diferencias discernibles entre las edades medidas en el terreno al ser categorizadas según las clasificaciones de edad obtenidas a partir de nuestro enfoque. Además, se calculó el número de parcelas cuya edad media medida en campo estaba dentro del intervalo correspondiente a la clase de edad teledetectada.

Finalmente, el último paso de la metodología consistió en la delimitación de los incendios históricos ocurridos en la isla de Ibiza, con el fin de identificar con

mayor precisión la edad de la masa forestal regenerada en dichas localizaciones. Para ello, se utilizaron ortofotos históricas, mosaicos de Landsat 1 y Landsat 2 y los registros de la Conselleria de Medi Ambient i Territori (CMAT, 2015).

3.4. Elaboración de la cartografía de productividad forestal

Una vez listas y validadas las capas de altura dominante y volumen por un lado, y de clases de edad por otro, se combinaron ambas para la elaboración de una cartografía de productividad o calidad de estación para las masas forestales arboladas identificadas mediante la metodología anteriormente descrita. Al combinar la cartografía de alturas dominantes con la de las clases de edad, se obtiene la calidad de estación (*site index* en inglés SI), definido como la altura dominante que alcanza la masa forestal a la edad de referencia (SHARMA et al., 2002), mientras que, si se combina la cartografía de volumen maderable con la de las clases de edad, se obtiene el crecimiento medio de la masa en el momento de medición (en adelante MAI, por sus siglas en inglés).

La Ecuación 4 muestra la expresión utilizada para convertir la altura dominante y edad medidas (bien medida en campo, o bien teledetectada utilizando las metodologías presentadas en el apartado anterior) en SI.

$$SI = H_{dom} \cdot \left(\frac{1 - e^{-b \cdot EDAD_0}}{1 - e^{-b \cdot EDAD}} \right)^{\frac{1}{c}}$$

Ecuación 4
En la que

$$\begin{array}{l} SI \\ EDAD_0 \\ H_{dom} \\ EDAD \end{array}$$

Por otro lado, la Ecuación 5 muestra la expresión utilizada para convertir las existencias totales o volumen maderable (de nuevo, tanto para las parcelas de campo como para las variables teledetectadas a nivel de píxel) a crecimientos medios (MAI), siendo para ello necesario simplemente dividir el volumen obtenido entre la edad estimada.

$$MAI = \frac{VOL}{EDAD}$$

Ecuación 5

Para mejorar la calidad de las capas finales, se estableció un límite fisiológico de productividad para los pinares de *Pinus halepensis* Mill. en 26 m para SI y en 5 m³ ha⁻¹ año⁻¹ para MAI (MONTERO et al., 2001; CPF, 2013). Finalmente, para estudiar el error de las capas de productividad (tanto de SI como de MAI), utilizamos los



datos de campo para comparar con los valores obtenidos mediante la metodología presentada en este trabajo, calculando el coeficiente de determinación (R^2), el error cuadrático medio y el error cuadrático medio relativo (RMSE y RRMSE, Ecuaciones 2 y 3). Más información al respecto de esta metodología puede encontrarse en RIBAS-COSTA et al. (2025).

3.5. Integración de la cartografía de productividad en la priorización de la gestión

3.5.1. Definición de indicadores de prioridad de gestión forestal

Para definir la PGF, se utilizaron una serie de indicadores, entre los cuales se incluyó la recién creada cartografía de calidad de estación. El principal objetivo fue el de incluir la mayoría de los factores que influyen en la elaboración de políticas forestales en el área de estudio. Una vez integradas, el resultado sería una capa de PGF.

Los indicadores utilizados fueron los siguientes:

- **Riesgo de incendios (RIF):** a mayor riesgo, mayor prioridad para reducir la ignición y propagación del fuego. Se usó una capa generada por la Conselleria de Medi Ambient i Territori (CMAT, 2015).
- **Pendiente (PTE):** afecta la operatividad de maquinaria forestal, priorizando según capacidades y disponibilidad en el área.
- **Accesibilidad (ACC):** cuanto más alejado de viales de acceso, mayor coste y menor PGF asignado.
- **Estrés vegetal (ESVE):** causado por sequía, plagas o ambas. Se suele recomendar la gestión forestal para mejora del aprovechamiento hídrico de la masa (FERNANDES et al., 2016; MANRIQUE-ALBA et al., 2020). Se cartografió usando el índice NDVI comparando 2023-2024 con un periodo de referencia de 5 años.
- **Visibilidad del paisaje (VISI):** refleja zonas con mayor visibilidad desde núcleos urbanos y viales para mitigar impactos visuales negativos.
- **Calidad de estación (SI):** como indicador de productividad, se priorizó la gestión en áreas más productivas.

Finalmente, y siguiendo estudios similares (GORSEVSKI et al., 2012; GAMBOA et al., 2023; KRSNIK et al., 2024), todas las capas anteriores se combinaron mediante la aplicación de una metodología de decisión multicriterio.

3.5.2. Análisis de la Teoría de la Utilidad Multi-Atributo

La Teoría de la Utilidad Multi-Atributo (MAUT, por sus siglas en inglés), es un tipo de Método de Decisión Multi-Criterio (MDMC, por sus siglas en inglés) que evalúa la importancia de indicadores individuales y los combina en una única función de utilidad para facilitar la toma de decisiones. En este caso, se normalizaron (rango 0 – 1) las capas utilizando como máximo y mínimo el percentil 99 y 1 de sus distribuciones, respectivamente. El riesgo de incendio, la calidad de estación y el estrés vegetal se normalizaron directamente (más prioridad de gestión cuanto mayor es la variable), mientras que la accesibilidad y visibilidad se normalizaron inversamente (menor prioridad de gestión cuanto mayor es la variable). En cuanto a la pendiente, se estableció una discretización basada en la propuesta por TOLOSANA-ESTEBAN et al. (2004), en la que tiene mayor prioridad de gestión cuanto menor pendiente haya, hasta un máximo del 70%.

Se usó la Ecuación 6 para combinar indicadores, con coeficientes calculados como el promedio de las respuestas de 8 técnicos forestales de la Administración Forestal Balear. En una encuesta anónima, se les pidió valorar la importancia de cada

criterio, asignando un máximo de un tercio del total a un indicador, considerando un escenario hipotético de alta productividad para promover la gestión económica y ambiental.

$$PGF = 0,201 \cdot RIF + 0,156 \cdot PTE + 0,195 \cdot ACC + 0,111 \cdot ESVE + 0,090 \cdot VISI + 0,246 \cdot SI$$

Ecuación 6

Más información sobre este procedimiento puede encontrarse en RIBAS-COSTA et al. (2025).

4. Resultados

4.1. Modelos de altura dominante y volumen maderable

La cartografía de la altura dominante en pinares de *Pinus halepensis* Mill. se realizó utilizando el modelo presentado en la Ecuación 7, mientras que la Ecuación 8 se empleó para estimar el volumen maderable por hectárea. El proceso de validación mostró un coeficiente de determinación (R^2) de 0,685 para la altura dominante y de 0,691 para el volumen. El error cuadrático medio (RMSE) fue de 1,48 m para la altura dominante y de 27,40 m³ ha⁻¹ para el volumen. En términos relativos, esto equivale a un error relativo (RRMSE) del 11,41% para la altura y del 27,66% para el volumen. La Figura 3 muestra un ejemplo de ambas cartografías para una zona de la isla de Ibiza.

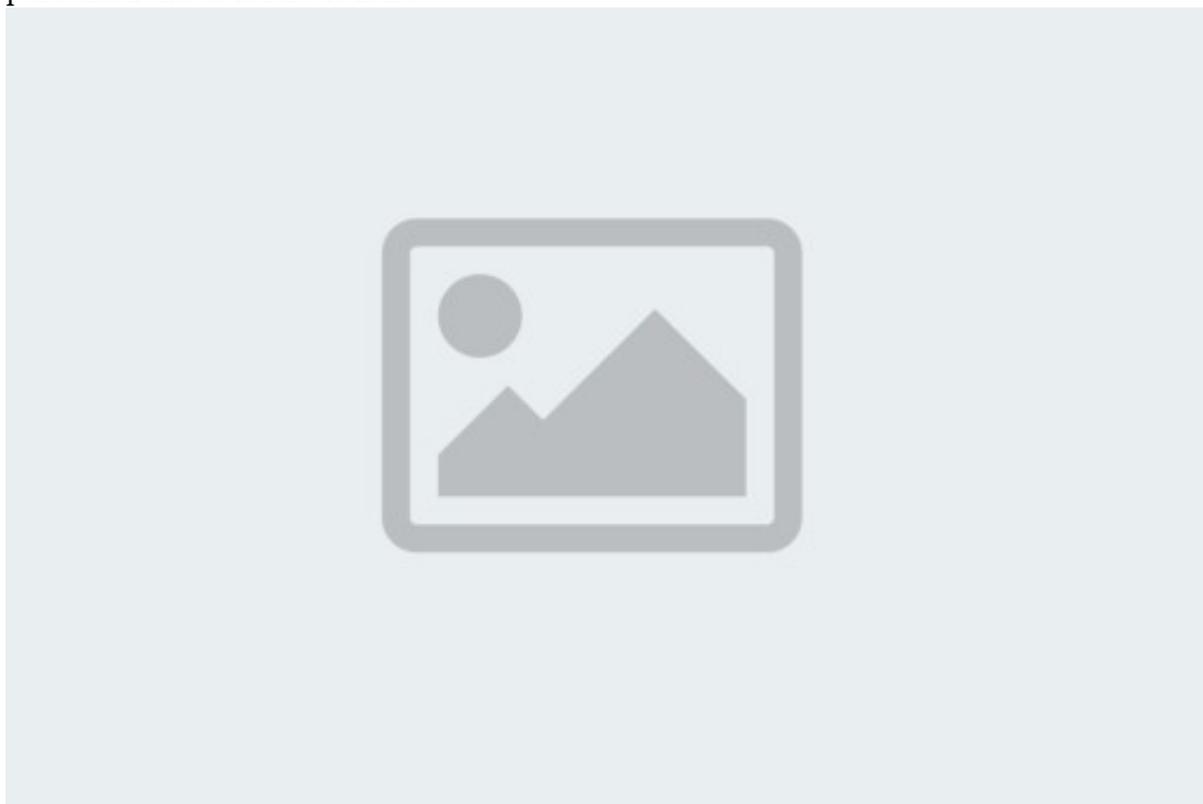


Figura3: Volumen maderable (1) y altura dominante (2) predicha para una zona del oeste de la isla de Ibiza.

4.2. Evolución forestal de las masas arboladas

El modelo *random forest* de mejor capacidad predictiva fue el de la ortoimagen de 1956, seguido de la ortoimagen de 2021. Finalmente, el modelo generado para la ortoimagen de 1989 fue la que peor capacidad predictiva obtuvo (Tabla 3). Los principales errores fueron confusiones de clasificación entre AGT y BR, AGNT y BD

en zonas llanas y AGT y BD en laderas. Una vez reclasificados los sistemas a 3 niveles (FOR, AGRO, y OTROS), la capacidad predictiva de éstos mejoró un 5% para el modelo de 1956, un 22% para el modelo de 1989 y un 11% para el modelo de 2021 (porcentajes calculados respecto al modelo del sistema de 6 niveles). La Figura 4 muestra las predicciones de estos modelos para una zona del sur de la isla de Ibiza.

Tabla3: Resultados de la validación tipocross-validation de 5 pliegues para los modelos random forest para cada ortoimagen. Los valores de incertidumbre se han calculado como una desviación estándar de los resultados obtenidos para cada pliegue.

AÑO / CLASES COBERTURA SUELO	SISTEMA DE 6 NIVELES DE COBERTURA DE SUELO		SISTEMA DE 3 NIVELES DE COBERTURA DE SUELO		
	Kappa	Precisión global (%)	Kappa	Precisión global (%)	
1956		0,761 ± 0,024	81,3 ± 1,92	0,791 ± 0,012	88,9 ± 0,46
1989		0,636 ± 0,045	74,0 ± 3,46	0,776 ± 0,046	89,4 ± 2,25
2021		0,659 ± 0,032	72,6 ± 2,54	0,729 ± 0,039	82,4 ± 2,44

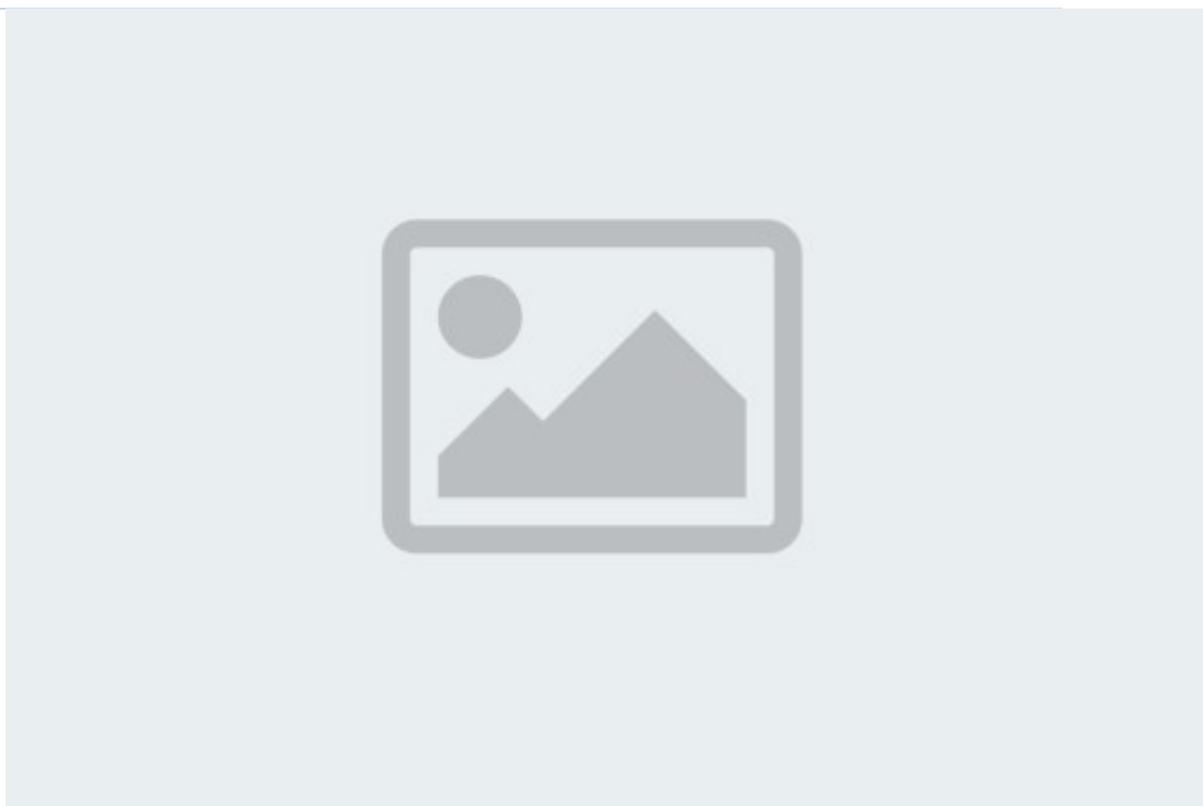


Figura4: Detalle de los mapas de cobertura o uso de suelo predichos (izquierda) y la ortofoto original (derecha) para una región del sudeste de la isla de Ibiza. Tierras agrícolas incluye las clases AGT, AGNT; el forestal arbolado BD y BR; mientras que otras tierras incluye el resto de las categorías (RP y OTR).

La combinación de la información sobre presencia o ausencia de clase forestal arbolada en cada una de las ortofotos permitió el cálculo de las clases de edad de una manera generalizada para las masas forestales de la isla (Figura 6.3), observando que 17,379 ha (58%) tenían entre 120 y 75 años, 6,120 ha (20%) entre

74 y 42 años y 6,680 ha (22%) entre 41 y 10 años. Al comparar la clase de edad discretizada con la edad medida en campo para cada una de las parcelas de inventario forestal, la media de las tres clases de edad fue significativamente distinta entre sí (valor $p < 0.0001$, Figura 5). Además, la diferencia entre las edades medidas en campo y el valor central de los intervalos fue de 13 años, y el 63,0% de las parcelas presentaron una edad media que coincidía con el intervalo de edades estimado por teledetección.

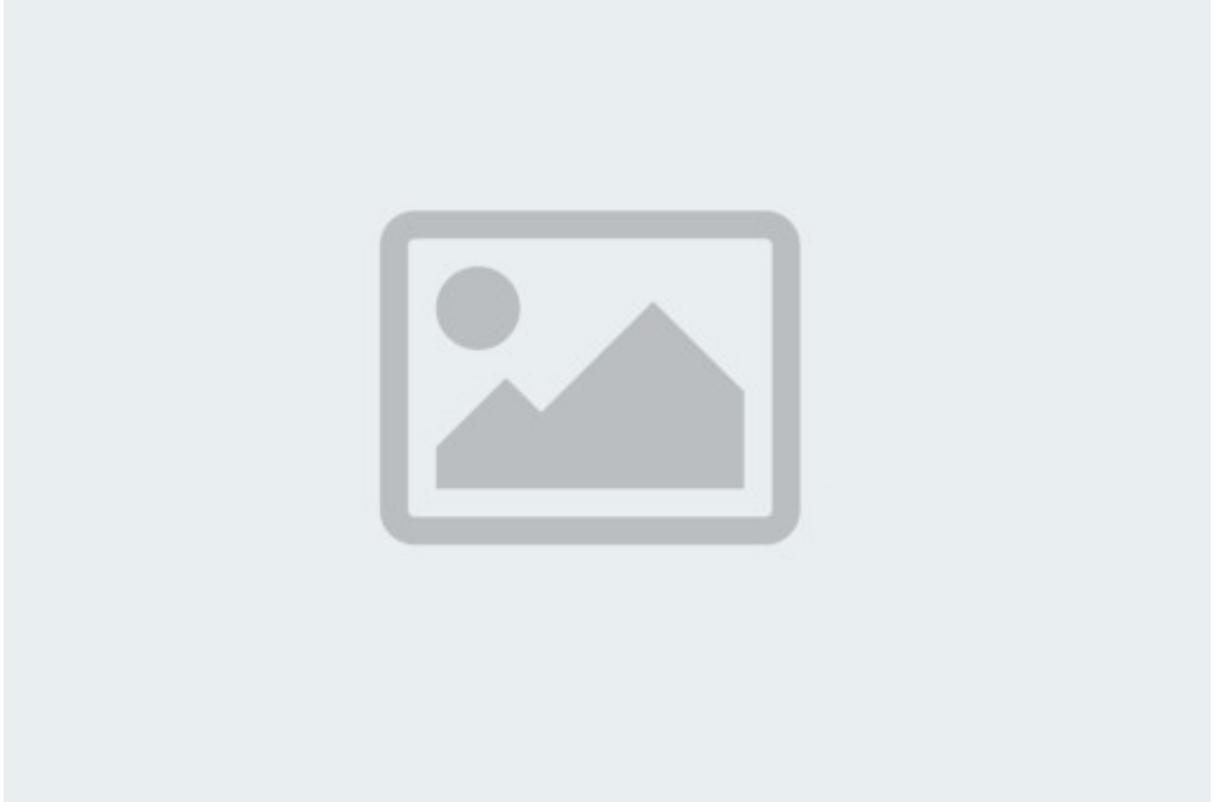


Figura 5: Diagramas de caja y bigotes para representar las diferencias entre las edades medidas en campo y las clases de edad teledetectadas. La línea oscura representa la mediana y las aristas los intervalos de confianza de ésta.

4.3. Cartografía de productividad y prioridad de gestión forestal

Una vez combinadas las capas de clases de edad teledetectadas con las capas de volumen maderable y altura dominante utilizando las expresiones presentadas anteriormente, se obtuvo por un lado una capa de crecimientos medios y por otro una capa de calidad de estación (Figura 6.1 y 6.2). Cuando se comparó la productividad obtenida en la capa basada en esta metodología con las estimaciones directas calculadas mediante los datos de campo del inventario forestal, se observó como la capa de crecimientos medios tenía un error del 43,5%, mientras que la capa de calidad de estación mostró un error del 20,4% (Figura 7).

Finalmente, y tras combinar todos los indicadores de PGF, se obtuvo la capa final, que se puede observar en la Figura 6.4. La cartografía de evolución forestal para 1956, 1989 y 2021, así como la capa de calidad de estación y la capa de PGF pueden consultarse en una aplicación web accesible desde el servidor de Google Earth Engine mediante el siguiente enlace: <https://ee-eivissa.projects.earthengine.app/view/foreiviz>.



Figura6: Cartografía de crecimiento medio anual (1), calidad de estación a los 80 años (2), clases de edad basadas en la metodología presentada (3) y PGF para la isla de Ibiza (4).



Figura7: Gráfico de observados (valores obtenidos de la combinación de las capas teledetectadas) contra predichos (valores obtenidos de los datos del inventario forestal) para las estimaciones de crecimientos medios (1) y calidad de estación (2).



Tanto el R2 como el RMSE y el RRMSE corresponden a todos los datos. El área gris corresponde al intervalo de confianza de la regresión a un alfa de 0,05.

5. Discusión

5.1. Modelos de altura dominante y volumen maderable

La capacidad predictiva de los modelos de altura dominante y volumen maderable resultó ligeramente inferior a la reportada en otros estudios, aunque se mantiene dentro de valores comparables, tanto en ecosistemas similares (DOMINGO et al., 2018; DOMINGO et al., 2019) como en contextos diferentes (CAO et al., 2019; PEARSE et al., 2019). El peor funcionamiento de los modelos presentados en este trabajo pudo deberse a que el ecosistema forestal en el que se realizó el estudio (bosques de *Pinus halepensis* Mill. naturales y sin gestión forestal) es intrínsecamente más variable que otro tipo de masas de repoblación y coetáneas. En el caso de la altura dominante, el uso de un percentil alto para modelar esta variable es un enfoque común (RITZ et al., 2022; RIBAS-COSTA et al., 2024b), dando lugar a errores similares al 11% obtenido en este trabajo. Para el caso de los modelos de volumen, las variables de altura media de los retornos y porcentaje de retornos por encima de 5 m fueron muy explicativas, como también lo fueron para otros estudios (LI et al., 2015; TORAÑO CAICOYA et al., 2015; LAURIN et al., 2020). Más desarrollo sobre los modelos y su funcionamiento puede encontrarse en RIBAS-COSTA et al. (2024a).

5.2. Evolución forestal de las masas arboladas

Por su parte, los modelos de clasificación de usos de suelo funcionaron bien, especialmente en el sistema de 3 clases de uso de suelo (>82% de precisión global). Otros estudios mostraron capacidades predictivas similares utilizando ortofotografía aérea histórica (VAN DER BROECK et al., 2022; NGUYEN et al., 2024), así como como ortofotografía aérea moderna, tanto normal (MAXWELL et al., 2019) como multiespectral (DORNIK et al., 2018). Curiosamente, la capacidad predictiva óptima se obtuvo en las ortofotos más antiguas, pudiendo ser consecuencia a un aumento de la complejidad de las imágenes más modernas al aumentar la calidad y resolución respecto a las antiguas (MAXWELL et al., 2019). En cualquier caso, las estimaciones de cobertura arbolada para la isla de Ibiza obtenidas en este trabajo son comparables con las obtenidas por otros estudios (MAGRAMA, 2012; JOINT RESEARCH CENTER, 2020; ROIG-COLL & KECHAGIA, 2022).

A pesar de que la utilización de ortofotografía histórica para obtener información valiosa en análisis procesos históricos, culturales, sociológicos, urbanos o naturales (PONS & RULLÁN, 2014; PINTO et al., 2019; KNUTH et al., 2021; MORFORD et al., 2024), el uso de esta fuente de información para relacionar la presencia/ausencia de masas forestales con su edad es un paso complejo. Pocos estudios utilizan la ortofotografía histórica para identificar expansión o reducción de las masas arboladas, y aún menos utilizan más de dos adquisiciones (RÓZYCKI et al., 2023; MORFORD et al., 2024; NGUYEN et al., 2024). Sin embargo, la utilización de datos de inventario forestal de campo para la validación de un sistema de clasificación de edades tal y como presentamos en este trabajo (y se desarrolla en RIBAS-COSTA et al., 2024c) es algo novedoso. En este caso, el error medio al validar con datos de edad extraídos usando barrena de Pressler en parcelas de inventario forestal (13 años) es muy comparable a los errores obtenidos en estudios que, mediante otras metodologías, tratan de obtener cartografía de edad de las masas forestales (KAYITAKIRE et al., 2006; VÉGA & ST-ONGE, 2009; FRATE et al., 2016; SÁNCHEZ-LÓPEZ et al., 2019; MALTAMO et al., 2020; SCHUMACHER et al., 2020; REYES-



PALOMEQUE et al., 2021).

5.3. Cartografía de productividad y prioridad gestión forestal

Los errores relativos de productividad forestal obtenidos en este trabajo (44% para crecimientos medios y 20% para calidad de estación) están en línea con los obtenidos en otros estudios, independientemente de las metodologías existentes para realizar mapas de calidad de estación. Estudios que sólo utilizaron una adquisición LiDAR y estimaciones de la edad de las masas, como GOPALAKRISHNAN et al. (2019) o RIBAS-COSTA et al. (2024b) reportaron errores entre 1,5 m y 3,5 m. Otros estudios que utilizan estimaciones de biomasa o altura dominante reportaron errores cercanos al 25% o a los 5,5 m, respectivamente (LEFSKY et al., 2005; TOMPALSKI et al., 2015). Por otro lado, aquellas metodologías que utilizan varias adquisiciones LiDAR y que por tanto son independientes de la edad de la masa forestal, reportan errores entre 0,31 m y 2,84 m, es decir, comparables con los obtenidos en este trabajo (NOORDERMEER et al., 2018; NOORDERMEER et al., 2020; SOCHA et al., 2020; GUERRA-HERNÁNDEZ et al., 2021).

Es importante mencionar también el efecto de sobreestimación que se puede observar especialmente en las parcelas más jóvenes (casi siempre sobre antiguas terrazas agrícolas abandonadas). Este efecto puede ser consecuencia de la utilización de unos modelos de calidad de estación (MONTERO et al., 2001) que no capturan bien la realidad de los bosques de pino carrasco de la isla de Ibiza, conocidos por ser más productivos que aquellos encontrados en el interior de la Península Ibérica, pues su crecimiento está fuertemente influenciado por las condiciones del suelo y del clima (DEL CASTILLO et al., 2015; BUEIS et al., 2017; GÓMEZ-SANZ et al., 2024). Aun así, errores en la clasificación de los usos de suelo para cada una de las ortoimágenes puede estar detrás de las exageraciones de productividad. Es importante señalar aquí también que el comportamiento de todas las capas presentadas en este trabajo en áreas de regeneración post-incendio probablemente necesite un análisis más detallado, puesto que ninguna parcela de inventario se tomó en este tipo de masas.

La integración de la calidad de estación en la zonificación de la prioridad de gestión es un procedimiento básico en la gestión de masas forestales más productivas (ROJO-ALBORECA, 2015). Sin embargo, en el caso de los pinares mediterráneos su integración suele ser más compleja, generalmente como consecuencia de diversos factores (bajo precios de venta de la madera y altos costes de mecanización, minifundismo y falta de asociacionismo, normativa ambiental en ocasiones demasiado estricta) lo que se traduce en una falta de tejido industrial que sustente la puesta en producción de las masas forestales de pino carrasco (ROJAS-BRIALES et al., 2018; ALCASENA et al., 2019). Aun así, la planificación forestal desempeña un papel fundamental en la gestión de los paisajes, transformándolos en paisajes culturales resilientes ante diversos tipos de riesgos (DELGADO-ARTÉS et al., 2022; GAMBOA et al., 2023; KRSNIK et al., 2024).

Los resultados obtenidos en la cartografía de PGF son coherentes con el conocimiento del territorio: las zonas más llanas y productivas son identificadas como de alta productividad, mientras que las zonas más alejadas de la red de caminos y normalmente coincidente con las zonas más altas de los montes y con mayores pendientes, se identifican como las menos prioritarias. Sin embargo, las zonas llanas de cerca del mar fueron identificadas como de prioridad elevada, cuando por calidad de la madera y valor ambiental no se realizaría ningún tipo de gestión forestal en la realidad. Esto es consecuencia de que no se incluyeron



ningún tipo de restricciones ambientales (proximidad al mar, limitaciones por espacios naturales protegidos, presencia de especies emblemáticas etc.), cuando en la realidad sí que habría que tener en cuenta todos estos factores a la hora de priorizar (y más especialmente, diseñar) la gestión forestal en unas zonas u otras. Una discusión más detallada al respecto puede encontrarse en RIBAS-COSTA et al. (2025).

6. Conclusiones

En este trabajo se han desarrollado tres metodologías basadas en teledetección para (1) cuantificar la cantidad de volumen maderable y la altura dominante de las masas de *Pinus halepensis* Mill. de la isla de Ibiza (Islas Baleares), (2) cartografiar la edad de dichas masas forestales en base a la presencia / ausencia de cobertura arbolada en una serie de ortofotografías históricas (1956 – 2021) mediante la creación de clases de edad, (3) la combinación de (1) y (2) para la elaboración de una novedosa cartografía de productividad forestal (tanto en forma de crecimientos medios como de calidad de estación), y (4) la integración de dicha cartografía de calidad de estación en un método de decisión multicriterio para proponer una cartografía de prioridad de gestión. Comprender el crecimiento forestal actual y potencial es clave para adaptar las prácticas de gestión, vinculadas tanto a cambios sociales como ambientales. Estas prácticas fortalecen el sector primario, promueven paisajes en mosaico resilientes a grandes incendios y generan bienes y servicios locales de alta calidad, apoyando la bioeconomía circular. El índice PGF presentado refleja este potencial y puede ayudar a los distintos actores a identificar las áreas más valiosas para cumplir sus objetivos, priorizando sus operaciones forestales de manera eficiente.

7. Agradecimientos

Este trabajo ha sido financiado por la Fundación ‘la Caixa’ (ID 100010434) mediante una beca INPhINIT retaining otorgada a Vicent Ribas (LCF/BQ/DR22/11950023), así como mediante el proyecto PID2021-127241OB-I00 financiado por MCIN/AEI /10.13039/501100011033 y por FEDER, UE. Agradecer a los coautores por su implicación y ayuda en el trabajo presentado. Cabe destacar la valiosa contribución de Miguel Soriano Talens, quien desempeñó el cargo de Ingeniero Forestal del Servei de Gestió Forestal del Govern de les Illes Balears durante más de una década, aportando su experiencia en la revisión y validación de la capa de prioridad de gestión forestal. Agradecer también a la empresa Terrapi World S.L. por posibilitar el uso de los datos de inventario forestal recopilados en distintos puntos de la isla para la elaboración de este trabajo.

8. Bibliografía

ALCASENA, F.J.; AGER, A.A.; BAILEY, J.D.; PINEDA, N.; VEGA-GARCÍA, C.; 2019. Towards a comprehensive wildfire management strategy for Mediterranean areas: Framework development and implementation in Catalonia, Spain. *J. of Environ. Manage.* 231: 303-320. <https://doi.org/10.1016/j.jenvman.2018.10.027>

ALMONACID-CABALLER, J.; PARDO-PASCUAL, J.; RUIZ, L.; 2017 Evaluating Fourier Cross-Correlation Sub-Pixel Registration in Landsat Images. *Rem. Sens.* 9(10): 1051. <https://doi.org/10.3390/rs9101051>

ANANDA, J.; HERATH, G.; 2009. A critical review of multi-criteria decision making methods with special reference to forest management and planning. *Ecol. Econ.* 68(10): 2535-2548. <https://doi.org/10.1016/j.ecolecon.2009.05.010>

ASSMAN, E.; 1970. The principles of forest yield study. Pergamon Press.



- BLASCHKE, T.; 2010. Object based image analysis for remote sensing. *ISPRS J. of Photogram. and Rem. Sens.* 65(1): 2-16. <https://doi.org/10.1016/j.isprsjprs.2009.06.004>
- BORRASS, L.; KLEINSCHMIT, D.; WINKEL, G.; 2017. The “German model” of integrative multifunctional forest management—Analysing the emergence and political evolution of a forest management concept. *For. Policy Econ.* 77: 16-23. <https://doi.org/10.1016/j.forpol.2016.06.028>
- BRAVO-OVIEDO, A.; MONTERO, G.; 2005. Site index in relation to edaphic variables in stone pine (*Pinus pinea* L.) stands in south west Spain. *Ann. For. Sci.* 62(1): 61-72. <https://doi.org/10.1051/forest:2004086>
- BREIMAN, L.; FRIEDMAN, J.H.; OLSHEN, R.A.; STONE, C.J.; 2017. *Classification and Regression Trees*. Apple Academic Press: Cambridge, MA, USA.
- BUEIS, T.; BRAVO, F.; PANDO, V.; TURRIÓN, M.B.; 2017. Site factors as predictors for *Pinus halepensis* Mill. productivity in Spanish plantations. *Ann. For. Sci.* 74: 6. <https://doi.org/10.1007/s13595-016-0609-7>
- CAO, L.; LIU, H.; FU, X.; ZHANG, Z.; SHEN, X.; RUAN, H.; 2019. Comparison of UAV LiDAR and digital aerial photogrammetry point clouds for estimating forest structural attributes in subtropical planted forests. *For.* 10(2): 145. <https://doi.org/10.3390/f10020145>
- CMAT – Conselleria d’Agricultura, Medi Ambient i Territori; 2015. IV Pla General de Defensa Contra Incendis Forestals de les Illes Balears. Govern de les Illes Balears, Tecnosylva SL.
- CPF – Centre de la Propietat Forestal; 2013. Pinedes de pi blanc. Tipologies i models de gestió. Col·lecció: Fitxes tècniques V Espècies i silvicultura. Generalitat de Catalunya, Departament d’Agricultura, Ramaderia, Pesca, Alimentació i Medi Natural. Santa Perpètua de Mogoda.
- DEL CASTILLO, J.; VOLTAS, J.; FERRIO, J.P.; 2015. Carbon isotope discrimination, radial growth, and NDVI share spatiotemporal responses to precipitation in Aleppo pine. *Trees* 29: 223–233. <https://doi.org/10.1007/s00468-014-1106-y>
- DEL RÍO, M.; CALAMA, R.; MONTERO, G.; 2008. Selvicultura de *Pinus halepensis* Mill. in “Compendio de Selvicultura Aplicada en España”, Serrada R., Montero G., Reque J.A. (Eds.). Instituto Nacional de investigación y Tecnología Agraria y Alimentaria. Madrid, Spain.
- DELGADO-ARTÉS, R.; GARÓFANO-GÓMEZ, V.; OLIVER-VILLANUEVA, J.; ROJAS-BRIALES, E.; 2022. Land use/cover change analysis in the Mediterranean region: a regional case study of forest evolution in Castelló (Spain) over 50 years. *Land Use Policy* 114: 105967. <https://doi.org/10.1016/j.landusepol.2021.105967>
- DI FILIPPO, A.; BALIVA, M.; BRUNETTI, M.; DI FIORE, L.; 2021. Long-Term Tree-Ring Response to Drought and Frost in Two *Pinus halepensis* Populations Growing under Contrasting Environmental Conditions in Peninsular Italy. *For.* 12(3): 305. <https://doi.org/10.3390/f12030305>
- DIÉGUEZ-ARANDA, U.; CASTEDO DORADO, F.; ÁLVAREZ GONZÁLEZ, J.G.; ROJO ALBORECA, A.; 2006. Dynamic growth model for Scots pine (*Pinus sylvestris* L.) plantations in Galicia (north-western Spain). *Ecol. Model.* 191(2): 225-242. <https://doi.org/10.1016/j.ecolmodel.2005.04.026>
- DOMINGO, D.; LAMELAS, M.T.; MONTEALEGRE, A.L.; GARCÍA-MARTÍN, A.; DE LA RIVA, J.; 2018. Estimation of total biomass in Aleppo pine forest stands applying parametric and nonparametric methods to low-density airborne laser scanning data. *Forests* 9(4): 158. <https://doi.org/10.3390/f9040158>
- DOMINGO, D.; MONTEALEGRE, A.L.; LAMELAS, M.T.; GARCÍA-MARTÍN, A.; DE LA RIVA, J.; RODRÍGUEZ, F.; ALONSO, R.; 2019. Quantifying forest residual biomass in *Pinus halepensis* Miller stands using airborne laser scanning data. *GISci. Remote*



- Sens.* 56(8): 1210–1232. <https://doi.org/10.1080/15481603.2019.1641653>
- DORNIK, A.; DRĂGUȚ, L.; URDEA, P.; 2018. Classification of Soil Types Using Geographic Object-Based Image Analysis and Random Forests. *Pedosphere* 28(6): 913-925. [https://doi.org/10.1016/S1002-0160\(17\)60377-1](https://doi.org/10.1016/S1002-0160(17)60377-1)
- FERNANDES, T.J.G.; DEL CAMPO, A.D.; HERRERA, R.; MOLINA, A.J.; 2016. Simultaneous assessment, through sap flow and stable isotopes, of water use efficiency (WUE) in thinned pines shows improvement in growth, tree-climate sensitivity and WUE, but not in WUEi. *For. Ecol. Manage.* 361: 298-308. <https://doi.org/10.1016/j.foreco.2015.11.029>
- FRATE, L.; CARRANZA, M.; GARFI, V.; FEBBRARO, M.; TONTI, D.; MARCHETTI, M.; OTTAVIANO, M.; SANTOPUOLI, G.; CHIRICI, G.; 2016. Spatially explicit estimation of forest age by integrating remotely sensed data and inverse yield modeling techniques. *iForest 867 – Biogeosci.* 9: 63–71. <https://doi.org/10.3832/ifor1529-008>
- GAMBOA, G.; OTERO, I.; BUENO, C.; ARILLA, E.; BALLART, H.; CAMPRUBÍ, L.; CANALETA, G.; TOLOSA, G.; CASTELLNOU, M.; 2023. Participatory multi-criteria evaluation of landscape values to inform wildfire management. *J. Environ. Manage.* 327: 116762. <https://doi.org/10.1016/j.jenvman.2022.116762>
- GÓMEZ-SANZ, V.; GASTÓN, A.; GARCÍA-VIÑAS, J.I.; SERRADA-HIERRO, R.; 2024. Site-scale soil conditions influencing the decline of Aleppo pine stands in Mediterranean Spanish woodland. *Plant Soil.* <https://doi.org/10.1007/s11104-024-06638-2>
- GONZÁLEZ-ÁVILA, S.; LÓPEZ-LEIVA, C.; BUNCE, R.G.H.; ELENA-ROSSELLÓ, R.; 2020. Changes and drivers in Spanish landscapes at the Rural-Urban Interface between 1956 and 2018. *Sci. Total Environ.* 714: 136858. <https://doi.org/10.1016/j.scitotenv.2020.136858>
- GOPALAKRISHNAN, R.; KAUFFMAN, J.S.; FAGAN, M.E.; COULSTON, J.W.; THOMAS, V.A.; WYNNE, R.H.; FOX, T.R.; QUIRINO, V.F.; 2019. Creating Landscape-Scale Site Index Maps for the Southeastern US Is Possible with Airborne LiDAR and Landsat Imagery. *For.* 10(3): 234. <https://doi.org/10.3390/f10030234>
- GORSEVSKI, P.V.; DONEVSKA, K.R.; MITROVSKI, C.D.; FRIZADO, J.P.; 2012. Integrating multi-criteria evaluation techniques with geographic information systems for landfill site selection: A case study using ordered weighted average. *Waste Manag.* 32(2): 287-296. <https://doi.org/10.1016/j.wasman.2011.09.023>
- GROMADA, K.; 2022. Unsupervised SAR Imagery Feature Learning with Median Filter-Based Loss Value. *Sensors* 22(17): 6519. <https://doi.org/10.3390/s22176519>
- 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 ALS data and environmental data. *For. Ecol. Manage.* 481: 118690. <https://doi.org/10.1016/j.foreco.2020.118690>
- HARRELL, F.E.; 2023. *rms: “Regression Modeling Strategies”*. R package version 6.5-0. <https://CRAN.R-project.org/package=rms>
- JOINT RESEARCH CENTRE; 2020. Global Map of Forest Cover for year 2020. EU observatory on deforestation and forest degradation. European Commission.
- KAHRIMAN, A.; SÖNMEZ, T.; GADOW, K. VON; 2018. Site index models for Calabrian pine in the central Mediterranean region of Turkey. *J. Sustain. For.* 37(5): 459–474. <https://doi.org/10.1080/10549811.2017.1421086>
- KAYITAKIRE, F.; HAMEL, C.; DEFOURNY, P.; 2006. Retrieving forest structure variables based on image texture analysis and IKONOS-2 imagery. *Rem. Sens. Environ.* 102: 390–401. <https://doi.org/10.1016/j.rse.2006.02.022>
- KHERCHOUCHE, D.; GOUBI, M.; SGHAIER, T.; BENTOUATI, A.; ZEGHICHI, K.;



- SLIMANI, S; 2024. Dominant height growth modeling of Aleppo pine (*Pinus halepensis* Mill.) in Beni Imloul forest, northern Algeria. *Ann. Silvicult. Res.* 49(1): 28–38. <https://doi.org/10.12899/asr-2471>
- KNUTH, F.; SHEAN, D.; BHUSHAN, S.; SCHWAT, E.; ALEXANDROV, O.; MCNEIL, C.; DEHECQ, A.; FLORENTINE, C.; O'NEEL, S; 2023. Historical Structure from Motion (HSfM): Automated processing of historical aerial photographs for long-term topographic change analysis. *Rem. Sens. Environ.* 285: 113379. <https://doi.org/10.1016/j.rse.2022.113379>
- KRSNIK, G.; BUSQUETS OLIVÉ, E.; PIQUÉ NICOLAU, M.; LARRAÑAGA, A.; TERÉS, J.A.; GARCÍA-GONZALO, J.; GONZÁLEZ OLABARRIA, J.R; 2024. Spatial multi-criteria analysis for prioritising forest management zones to prevent large forest fires in Catalonia (NE Spain). *Environ. Chall.* 15: 100959. <https://doi.org/10.1016/j.envc.2024.100959>
- KWON, S.; JUNG, H.; BAEK, W.; KIM, D; 2017. Classification of Forest Vertical Structure in South Korea from Aerial Orthophoto and Lidar Data Using an Artificial Neural Network. *Appl. Sci.* 7(10): 1046. <https://doi.org/10.3390/app7101046>
- LANGENKAMP, J.; RIENOW, A; 2023. Exploring the Use of Orthophotos in Google Earth Engine for Very High-Resolution Mapping of Impervious Surfaces: A Data Fusion Approach in Wuppertal, Germany. *Rem. Sens.* 15(7): 1818. <https://doi.org/10.3390/rs15071818>
- LAURIN, G.V.; PULETTI, N.; GROTTI, M.; STEREŃCZAK, K.; MODZELEWSKA, A.; LISIEWICZ, M.; SADKOWSKI, R.; KUBERSKI, Ł.; CHIRICI, G.; PAPALE, D; 2020. Species dominance and above ground biomass in the Białowieża Forest, Poland, described by airborne hyperspectral and lidar data. *Int. J. Appl. Earth Obs. Geoinf.* 97: 102178. <https://doi.org/10.1016/j.jag.2020.102178>
- LEFSKY, M.; TURNER, D.; GUZY, M.; COHEN, W; 2005. Combining lidar estimates of aboveground biomass and Landsat estimates of stand age for spatially extensive validation of modeled forest productivity. *Rem. Sens. Environ.* 95(4): 549-558. <https://doi.org/10.1016/j.rse.2004.12.022>
- LI, L.; GUO, Q.; TAO, S.; KELLY, M.; XU, G; 2015. Lidar with multi-temporal MODIS provide a means to upscale predictions of forest biomass. *ISPRS J. Photogramm. Remote Sens.* 102: 198–208. <https://doi.org/10.1016/j.isprsjprs.2015.02.007>
- MAGRAMA - Ministerio de Agricultura, Alimentación y Medio Ambiente; 2012. 4th Spanish national forest inventory. Dirección General de Desarrollo Rural y Política Forestal, Área de Inventario y Estadísticas Forestales.
- MALTAMO, M.; KINNUNEN, H.; KANGAS, A.; KORHONEN, L; 2020. Predicting stand age in managed forests using National Forest Inventory field data and airborne laser scanning. *For. Ecosys.* 7: 44. <https://doi.org/10.1186/s40663-020-00254-z>
- MALTMAN, J.C.; HERMOSILLA, T.; WULDER, M.A.; COOPS, N.C.; WHITE, J.C; 2023. Estimating and mapping forest age across Canada's forested ecosystems. *Rem. Sens. Environ.* 290: 113529. <https://doi.org/10.1016/j.rse.2023.113529>
- MANRIQUE-ALBA, A.; BEGUERÍA, S.; MOLINA, A.J.; GONZÁLEZ-SANCHIS, M.; TOMÀS-BURGUERA, M.; DEL CAMPO, A.D.; COLANGELO, M.; CAMARERO, J.J.; 2020. Long-term thinning effects on tree growth, drought response and water use efficiency at two Aleppo pine plantations in Spain. *Sci. Total Environ.* 728: 138536. <https://doi.org/10.1016/j.scitotenv.2020.138536>
- MAXWELL, A.E.; STRAGER, M.P.; WARNER, T.A.; RAMEZAN, C.A.; MORGAN, A.N.; PAULEY, C.E.; 2018. Large-area, high spatial resolution land cover mapping using random forests, GEOBIA, and NAIP orthophotography: Findings and recommendations. *Rem. Sens.* 11(12): 1409. <https://doi.org/10.3390/rs11121409>
- MERLO, M.; ROJAS-BRIALES, E.; 2000. Public goods and externalities linked to



- Mediterranean forests: Economic nature and policy. *Land Use Policy*, 17(3): 197–208. [https://doi.org/10.1016/S0264-8377\(00\)00017-X](https://doi.org/10.1016/S0264-8377(00)00017-X)
- MONTERO, G.; CAÑELLAS, I.; RUÍZ-PEINADO, R.; 2001. Growth and yield models for *Pinus halepensis* Mill. *Investigaciones Agrarias: Sistemas y Recursos Forestales*, 10(1): 179–201. <https://doi.org/10.5424/720>
- MORE, A.S.; RANA, D.P.; 2017. Review of random forest classification techniques to resolve data imbalance. 1st International Conference on Intelligent Systems and Information Management (ICISIM), Aurangabad, India, 72-78. <https://doi.org/10.1109/ICISIM.2017.8122151>
- MOREIRA, F.; ASCOLI, D.; SAFFORD, H.; ADAMS, M.A.; MORENO, J.M.; PEREIRA, J.M.C.; CATRY, F.X.; ARMESTO, J.; BOND, W.; GONZÁLEZ, M.E.; 2020. Wildfire management in Mediterranean-type regions: Paradigm change needed. *Environ. Res. Lett.* 15(1): 011001. <https://doi.org/10.1088/1748-9326/ab541e>
- MORFORD, S.L.; ALLRED, B.W.; JENSEN, E.R.; MAESTAS, J.D.; MUELLER, K.R.; PACHOLSKI, C.L.; SMITH, J.T.; TACK, J.D.; TACKETT, K.N.; NAUGLE, D.E.; 2024. Mapping tree cover expansion in Montana, U.S.A. rangelands using high-resolution historical aerial imagery. *Rem. Sens. Ecol. Conserv.* 10(1): 91–105. <https://doi.org/10.1002/rse2.357>
- NGUYEN, T.; KELLENBERGER, B.; TUIA, D.; 2022. Mapping forest in the Swiss Alps treeline ecotone with explainable deep learning. *Rem. Sens. Environ.* 281: 113217. <https://doi.org/10.1016/j.rse.2022.113217>
- NOORDERMEER, L.; BOLLANDSÅS, O.M.; GOBAKKEN, T.; NÆSSET, E.; 2018. Direct and indirect site index determination for Norway spruce and Scots pine using bitemporal airborne laser scanner data. *For. Ecol. Manage.* 428: 104-114. <https://doi.org/10.1016/j.foreco.2018.06.041>
- NOORDERMEER, L.; GOBAKKEN, T.; NÆSSET, E.; BOLLANDSÅS, O.M.; 2020. Predicting and mapping site index in operational forest inventories using bitemporal airborne laser scanner data. *For. Ecol. Manage.* 457: 117768. <https://doi.org/10.1016/j.foreco.2019.117768>
- PEARSE, G.D.; WATT, M.S.; DASH, J.P.; STONE, C.; CACCAMO, G.; 2019. Comparison of models describing forest inventory attributes using standard and voxel-based lidar predictors across a range of pulse densities. *Int. J. Appl. Earth Obs. Geoinf.* 78: 341–351. <https://doi.org/10.1016/j.jag.2018.10.008>
- PEMÁN GARCÍA, J.; IRIARTE GOÑI, I.; LARIO LEZA, F.J. (eds.); 2017. *La restauración forestal de España: 75 años de una ilusión*. Ministerio de Agricultura y Pesca, Alimentación y Medio Ambiente. Sociedad Española de Ciencias Forestales. Madrid. ISBN: 978-84-491-1495-3
- PINTO, A.T.; GONÇALVES, J.A.; BEJA HONRADO, J.P.; 2019. From archived historical aerial imagery to informative orthophotos: A framework for retrieving the past in long-term socioecological research. *Rem. Sens.* 11(11): 1388. <https://doi.org/10.3390/rs11111388>
- PONS, A.; RULLAN, O.; 2014. The expansion of urbanization in the Balearic Islands (1956–2006). *J. Mar. Isl. Cult.* 3: 77–88. <https://doi.org/10.1016/j.imic.2014.11.004>
- PROBST, P.; WRIGHT, M.N.; BOULESTEIX, A.L.; 2019. Hyperparameters and tuning strategies for random forest. *Wiley Interdisciplinary Reviews: Data Min. Knowl. Discov.* 9, e1301. <https://doi.org/10.1002/WIDM.1301>
- REYES-PALOMEQUE, G.; DUPUY, J.; PORTILLO-QUINTERO, C.; ANDRADE, J.; TUN-DZUL, F.; HERNÁNDEZ-STEFANONI, J.; 2020. Mapping forest age and characterizing vegetation structure and species composition in tropical dry forests. *Ecol. Indic.* 120: 106955. <https://doi.org/10.1016/j.ecolind.2020.106955>



RIBAS-COSTA, V.A.; COOK, R.L.; GASTÓN, A.; 2024a. Modeling structural traits of Aleppo pine (*Pinus halepensis* Mill.) forests with low-density LiDAR. *Euro. J. Rem. Sens.* 57(1): 2344569 <https://doi.org/10.1080/22797254.2024.2344569>

RIBAS-COSTA, V.A.; GASTÓN, A.; COOK, R.L.; 2024b. Modeling dominant height with USGS 3DEP LiDAR to determine site index in even-aged loblolly pine (*Pinus taeda* L.) plantations in the southeastern US. *Forestry: An Intl. J. of For. Res.*: cpae034 <https://doi.org/10.1093/forestry/cpae034>

RIBAS-COSTA, V.A.; TRLICA, A.; GASTÓN, A.; 2024c. Mapping forest age in the pre-satellite era using historical aerial photographs and machine learning. Publicado en *J. For. Res.* (in press).

RIBAS-COSTA, V.A.; TRLICA, A.; GASTÓN, A.; 2025. Integrating forest productivity maps with supplemental data to optimize forest management priority: a case study in Ibiza (Spain). En revisión en *J. of Environ. Manage.*

RITZ, A.L.; THOMAS, V.A.; WYNNE, R.H.; GREEN, P.C.; SCHROEDER, T.A.; ALBAUGH, T.J.; BURKHART, H.E.; CARTER, D.R.; COOK, R.L.; CAMPOE, O.C.; RUBILAR, R.A.;

RAKESTRAW, J.; 2022. Assessing the utility of NAIP digital aerial photogrammetric point clouds for estimating canopy height of managed loblolly pine plantations in the southeastern United States. *Int. J. Appl. Earth Obs. Geoinf.*, 113: 103012.

<https://doi.org/10.1016/j.jag.2022.103012>

ROIG-COLL, S.; KECHAIGA, A.; 2022. A land of extremes: The dance between intensive farming and farmland abandonment, in *Resources, Strategies and Potentialities for Food System Sustainability in the Mediterranean Area*. Bertoret, N.; Bertoret, E. (Eds.). Ajuntament de València, CEMAS. València, Spain.

ROJAS-BRIALES, E.; DELGADO-ARTÉS, R.; CABRERA-BONET, M.; 2018. Human desertification and disempowerment of rural territories. In: *Forestry in the Midst of Global Changes*. CRC Press, pp. 101–134.

ROJO-ALBORECA, A.; 2015. El reto de la ordenación de los montes privados en España. *Cuad. Soc. Esp. Cienc. For.*, 39: 275-297.

RÓŻYCKI, S.; KARWEL, A.K.; KURCZYŃSKI, Z.; 2023. German Extermination Camps on WWII reconnaissance photographs. Orthorectification process for archival aerial images of cultural heritage sites. *Rem. Sens.*, 15(10): 2587.

<https://doi.org/10.3390/rs15102587>

SÁNCHEZ-LÓPEZ, N.; BOSCHETTI, L.; HUDAK, A.T.; 2020. Reconstruction of the disturbance history of a temperate coniferous forest through stand-level analysis of airborne LiDAR data. *Forestry: An Intl. J. of For. Res.*, 93(1), 38-55.

<https://doi.org/10.1093/forestry/cpz048>

SCHUMACHER, J.; HAUGLIN, M.; ASTRUP, R.; BREIDENBACH, J.; 2020. Mapping forest age using National Forest Inventory, airborne laser scanning, and Sentinel-2 data. *For. Ecosyst.*, 7: 60. <https://doi.org/10.1186/s40663-020-00274-9>

SHARMA, M.; AMATEIS, R.; BURKHART, H.; 2002. Top height definition and its effect on site index determination in thinned and unthinned loblolly pine plantations. *Forest Ecol. Manage.*, 168(1-3): 163–175. [https://doi.org/10.1016/S0378-1127\(01\)00737-X](https://doi.org/10.1016/S0378-1127(01)00737-X)

SHIMIZU, K.; MURAKAMI, W.; FURUICHI, T.; ESTOQUE, R.C.; 2023. Mapping land use/land cover changes and forest disturbances in Vietnam using a Landsat temporal segmentation algorithm. *Rem. Sens.*, 15(3): 851.

<https://doi.org/10.3390/rs15030851>

SOCHA, J.; HAWRYŁO, P.; STEREŃCZAK, K.; MIŚCICKI, S.; TYMIŃSKA-CZABAŃSKA, L.; MŁOCEK, W.; GRUBA, P.; 2020. Assessing the sensitivity of site index models developed using bi-temporal airborne laser scanning data to different top height



- estimates and grid cell sizes. *Int. J. Appl. Earth Obs. Geoinf.*, 91: 102129. <https://doi.org/10.1016/j.jag.2020.102129>
- SOLBERG, S.; KVAALEN, H.; PULITI, S.; 2019. Age-independent site index mapping with repeated single-tree airborne laser scanning. *Scand. J. For. Res.*, 34(8): 763–770. <https://doi.org/10.1080/02827581.2019.1616814>
- TADESE, M.; KUMAR, L.; KOECH, R.; KOGO, B.K.; 2020. Mapping of land-use/land-cover changes and its dynamics in Awash River Basin using remote sensing and GIS. *Rem. Sens. Appl.*, 19: 100352. <https://doi.org/10.1016/j.rsase.2020.100352>
- TASSI, A.; VIZZARI, M.; 2020. Object-oriented LULC classification in Google Earth Engine combining SNIC, GLCM, and machine learning algorithms. *Rem. Sens.*, 12(22): 3776. <https://doi.org/10.3390/rs12223776>
- TOLOSANA-ESTEBAN, E.; GONZÁLEZ, G. DE LINARES, V.M.; VIGNOTE PEÑA, S.; 2004. *El aprovechamiento maderero*. Fundación Conde del Valle Salazar (ISBN: 84-86793-97-7) – Ediciones Mundi-Prensa (ISBN: 84-8476-203-3). Madrid.
- TOMPALSKI, P.; COOPS, N.C.; WHITE, J.C.; WULDER, M.A.; PICKELL, P.D.; 2015. Estimating forest site productivity using airborne laser scanning data and Landsat time series. *Can. J. Rem. Sens.*, 41(3): 232–245. <https://doi.org/10.1080/07038992.2015.1068686>
- TORAÑO CAICOYA, A.; KUGLER, F.; PRETZSCH, H.; PAPATHANASSIOU, K.; 2015. Forest vertical structure characterization using ground inventory data for the estimation of forest aboveground biomass. *Can. J. For. Res.*, 46(1): 25–38. <https://doi.org/10.1139/cjfr-2015-0052>
- VADELL, E.; PEMÁN, J.; VERKERK, P.J.; ERDOZAIN, M.; DE-MIGUEL, S.; 2022. Forest management practices in Spain: Understanding past trends to better face future challenges. *For. Ecol. and Manage.*, 524: 120526. <https://doi.org/10.1016/j.foreco.2022.120526>
- VALLS-DONDERIS, P.; VALLÉS-PLANELLAS, M.; GALIANA, F.; 2015. Criteria and indicators for sustainable forestry under Mediterranean conditions applicable in Spain at the forest management unit scale. *For. Sys.*, 24(1): 1-21. <https://doi.org/10.5424/fs/2015241-05542>
- VAN DER BROECK, W.A.J.; GOEDEMEÉ, T.; LOOPMANS, M.; 2022. Multiclass land cover mapping from historical orthophotos using domain adaptation and spatio-temporal transfer learning. *Rem. Sens.*, 14(23): 5911. <https://doi.org/10.3390/rs14235911>
- VÉGA, C.; ST-ONGE, B.; 2009. Mapping site index and age by linking a time series of canopy height models with growth curves. *For. Ecol. Manag.*, 257(3): 951-959. <https://doi.org/10.1016/j.foreco.2008.10.029>
- WINKEL, G.; JUMP, A.; 2014. Perspectives on forest conservation: Building evidence at the frontier between policy and conservation science. *Biodivers. Conserv.*, 23: 3359–3372. <https://doi.org/10.1007/s10531-014-0824-1>
- WRIGHT, M.N.; ZIEGLER, A.; 2017. Ranger: A fast implementation of random forests for high dimensional data in C++ and R. *J. Stat. Softw.*, 77(1): 1-17. <https://doi.org/10.18637/jss.v077.i01>
- XIMÉNEZ DE EMBÚN, I.; OSEÑALDE, J.; CEBALLOS, L.; 1939. Plan general para la repoblación forestal de España. Organismo Autónomo Parques Nacionales (Ed.), Tres trabajos forestales, Ministerio de Medio Ambiente, Madrid, pp. 431-445.
- ZHOU, H.; FU, L.; SHARMA, R.P.; LEI, Y.; GUO, J.; 2020. A hybrid approach of combining random forest with texture analysis and VDVI for desert vegetation mapping based on UAV RGB data. *Rem. Sens.*, 13(10): 1891. <https://doi.org/10.3390/rs13101891>

